

วิธีการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking สามารถเพิ่มความแม่นยำของการทำนายสัญญาณการ
ซื้อขายสกุลเงินดิจิทัลได้หรือไม่



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาการประกันภัย ภาควิชาสถิติ
คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2566

Will Stacking Method Improve Cryptocurrency Trading Signal Prediction Accuracy?



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Insurance
Department of Statistics
Faculty Of Commerce And Accountancy
Chulalongkorn University
Academic Year 2023

หัวข้อวิทยานิพนธ์	วิธีการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking สามารถเพิ่มความแม่นยำของการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลได้หรือไม่
โดย	นายศรารุณี ทองเชื้อ
สาขาวิชา	การประกันภัย
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ดร.อิสริยะ สัตกุลพิบูลย์

คณะพาณิชย์ศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับวิทยานิพนธ์ฉบับนี้
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณะบดีคณะพาณิชย์ศาสตร์และการ
บัญชี
(ศาสตราจารย์ ดร.วิเลิศ ภูริวัชร)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.วิฐูรา พึ่งพาพงศ์)
..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ดร.อิสริยะ สัตกุลพิบูลย์)
..... กรรมการ
(รองศาสตราจารย์ ดร.อัษฎาพร ทรัพย์สมบูรณ์)
..... กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.สัมพันธ์ เนตยานันท์)

ศราวุฒิ ทองเชื้อ : วิธีการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking สามารถเพิ่มความแม่นยำของการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลได้หรือไม่. (Will Stacking Method Improve Cryptocurrency Trading Signal Prediction Accuracy?) อ.ที่ปรึกษาหลัก : ดร.อิสริยะ สัตกุลพิบูลย์

ปัจจุบันการลงทุนในตลาดสกุลเงินดิจิทัลได้รับความสนใจจากนักลงทุนจำนวนมาก เนื่องจากเป็นสินทรัพย์ที่สามารถให้ผลตอบแทนสูง ในทางกลับกันสามารถทำให้เกิดความสูญเสียสูงเช่นกัน การลงทุนในตลาดสกุลเงินดิจิทัลจึงต้องอาศัยเครื่องมือวิเคราะห์ที่มีประสิทธิภาพในการจัดการลงทุน การเรียนรู้ของเครื่องเป็นหนึ่งในเครื่องมือวิเคราะห์ที่ช่วยให้นักลงทุนตัดสินใจได้ดีขึ้น งานวิจัยนี้ได้ศึกษาทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยเปรียบเทียบวิธีการใช้ตัวแบบป่าสุ่ม ตัวแบบการถดถอยโลจิสติก และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking และการวิเคราะห์ทางเทคนิคจาก 50 ตัวบ่งชี้ทางเทคนิค สำหรับสกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาดสูงสุด 20 อันดับแรกข้อมูลความถี่ 1 วัน และ 1 สัปดาห์ ซึ่งจากการศึกษาพบว่าตัวแบบป่าสุ่มให้ค่าความถูกต้องระหว่าง 0.4423-0.7115 ตัวแบบการถดถอยโลจิสติกให้ค่าความถูกต้องระหว่าง 0.4615-0.6346 และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking ให้ค่าความถูกต้องระหว่าง 0.4423-0.6538 โดยภาพรวมตัวแบบการถดถอยโลจิสติกเหมาะสมสำหรับสกุลเงินดิจิทัลส่วนใหญ่ อีกทั้งการสร้างตัวแบบด้วยการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking สามารถช่วยเพิ่มประสิทธิภาพสำหรับการทำนายของตัวแบบ นอกจากนี้ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา การประกันภัย

ปีการศึกษา 2566

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6380328926 : MAJOR INSURANCE

KEYWORD: Cryptocurrency Random Forest Logistic Regression Technical Analysis
Stacking Method

Sarawut Tongchue : Will Stacking Method Improve Cryptocurrency Trading
Signal Prediction Accuracy?. Advisor: ISARIYA SUTTAKULPIBOON, Ph.D.

Currently, investing in the cryptocurrency market has attracted the attention of many investors because it is an asset that can provide high returns. On the other hand, it can cause high losses as well. Investing in the digital currency market requires efficient analytical machines to manage investments. Machine Learning is one of the analysis tools that helps investors make better decisions. This research study predicts cryptocurrency trading signals by comparing Random Forest, Logistic Regression and Stacking Methods and technical analysis of 50 technical indicators. For the top 20 cryptocurrencies with the highest market capitalization conditions, daily frequency data and weekly frequency data. The study found that the Random Forest model provides an accuracy between 0.4423-0.7115 The Logistic Regression model provides an accuracy between 0.4615-0.6346 and the Stacking Method gives an accuracy between 0.4423-0.6538 Overall, the Logistic Regression model is suitable for most cryptocurrencies. Moreover, creating a model using the Stacking Method can help increase the efficiency of the model's predictions. In addition, weekly frequency data gives better results than daily frequency data.

Field of Study: Insurance

Student's Signature

Academic Year: 2023

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดีจากความช่วยเหลือและความอนุเคราะห์ของ อาจารย์ ดร.อิสริยะ สัตกุลพิบูลย์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ซึ่งท่านได้ให้ความรู้และคำปรึกษาต่าง ๆ ซึ่งเป็นประโยชน์อย่างมากต่อการทำวิทยานิพนธ์ อีกทั้งยังช่วยแก้ปัญหา คอยติดตามการทำวิทยานิพนธ์ และส่งเสริมให้กำลังใจเสมอมา ผู้วิจัยขอกราบขอบพระคุณท่านอาจารย์มา ณ โอกาสนี้

ขอกราบขอบพระคุณ รองศาสตราจารย์ ดร.วิฐุรา พึ่งพาพงศ์ ประธานกรรมการสอบวิทยานิพนธ์ รองศาสตราจารย์ ดร.อัษฎพร ททรัพย์สมบูรณ์ กรรมการสอบวิทยานิพนธ์ และ ผู้ช่วยศาสตราจารย์ ดร.สัมพันธ์ เนตยานันท์ กรรมการภายนอก ที่ให้ความกรุณาเป็นกรรมการในการสอบวิทยานิพนธ์ กรุณาให้คำแนะนำ และชี้ให้เห็นถึงความผิดพลาด เพื่อนำไปปรับปรุงและแก้ไขวิทยานิพนธ์ให้ดีขึ้นและมีประสิทธิภาพมากยิ่งขึ้น

ขอกราบขอบพระคุณคณาจารย์ในจุฬาลงกรณ์มหาวิทยาลัยทุกท่านที่ให้ความรู้แก่ผู้วิจัย และขอกราบขอบพระคุณบุคลากรทุกท่านที่อำนวยความสะดวกและการประสานงานต่าง ๆ รวมถึงผู้ให้การสนับสนุนการทำวิทยานิพนธ์ทุกท่าน

สุดท้ายนี้ขอกราบขอบพระคุณ บิดา มารดา ญาติพี่น้องของผู้วิจัย ที่สนับสนุนและให้ความช่วยเหลือเสมอมา รวมทั้งเพื่อน ๆ ที่มีส่วนเกี่ยวข้องกับการทำวิทยานิพนธ์ ตลอดจนกำลังใจให้การทำวิทยานิพนธ์ครั้งนี้สำเร็จลุล่วงด้วยดี

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ศราวุฒิ ทองเชื้อ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	1
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา (Background and Problem Review).....	1
1.2 วัตถุประสงค์ของการวิจัย (Objectives).....	2
1.3 ขอบเขตของการวิจัย (Scope of the Study).....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
บทที่ 3 วิธีการดำเนินการวิจัย	14
3.1 ข้อมูล.....	14
3.2 ตัวบ่งชี้ทางเทคนิค (Technical indicator).....	15
3.3 ตัวแบบ (Models)	30
3.4 การกำหนดตัวแปรสำหรับตัวแบบ.....	32
3.5 การคัดเลือกคุณสมบัติ (Feature Selection).....	33
3.6 การปรับแต่งค่าไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning).....	34
3.7 การวัดประสิทธิภาพของตัวแบบ (Model Evaluation).....	35
บทที่ 4 ผลการศึกษา.....	38
4.1 ผลการวิเคราะห์ข้อมูลเชิงการตรวจสอบ (Exploratory Data Analysis (EDA))	38

4.2 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC)	42
4.3 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ethereum (ETH).....	44
4.4 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB).....	46
4.5 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ripple (XRP)	48
4.6 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Cardano (ADA)	50
4.7 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE).....	52
4.8 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล TRON (TRX)	54
4.9 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Polygon (MATIC).....	56
4.10 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC).....	58
4.11 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC).....	60
4.12 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO)	62
4.13 ผลการศึกษาตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่ให้ความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงินดิจิทัล	66
บทที่ 5 สรุปผลการวิจัย.....	67
5.1 สรุปผลการศึกษา	67
5.2 อภิปรายผลการศึกษา	70
5.3 ข้อเสนอแนะ	71
บรรณานุกรม.....	72
ประวัติผู้เขียน.....	75

สารบัญตาราง

ตารางที่ 1 แสดงการเปรียบเทียบข้อดี และข้อเสียของแต่ละกระบวนการของการเรียนรู้ของเครื่อง (Machine Learning)	3
ตารางที่ 2 แสดงสรุปการศึกษางานวิจัยการทำนายข้อมูลตลาดหุ้นและตลาดสกุลเงินดิจิทัล	8
ตารางที่ 3 แสดงข้อมูลสกุลเงินดิจิทัลที่มีมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก	14
ตารางที่ 4 แสดงค่าสถิติเชิงพรรณนา (Descriptive Statistics) ข้อมูลสำหรับการสอน (Training set)	38
ตารางที่ 5 แสดงค่าสถิติเชิงพรรณนา (Descriptive Statistics) ชุดข้อมูลสำหรับทดสอบ (Test set)	39
ตารางที่ 6 แสดงร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลชุดข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set).....	40
ตารางที่ 7 แสดงร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลความถี่ 1 วัน และความถี่ 1 สัปดาห์.....	41
ตารางที่ 8 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) ความถี่ 1 วัน	42
ตารางที่ 9 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) ความถี่ 1 สัปดาห์	43
ตารางที่ 10 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) ความถี่ 1 วัน	44
ตารางที่ 11 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) ความถี่ 1 สัปดาห์	45
ตารางที่ 12 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) ความถี่ 1 วัน	46
ตารางที่ 13 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) ความถี่ 1 สัปดาห์	47
ตารางที่ 14 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ripple (XRP) ความถี่ 1 วัน.....	48
ตารางที่ 15 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ripple (XRP) ความถี่ 1 สัปดาห์	49
ตารางที่ 16 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Cardano (ADA) ความถี่ 1 วัน.....	50
ตารางที่ 17 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Cardano (ADA) ความถี่ 1 สัปดาห์	51
ตารางที่ 18 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) ความถี่ 1 วัน	52

ตารางที่ 19 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) ความถี่ 1 สัปดาห์..... 53

ตารางที่ 20 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล TRON (TRX) ความถี่ 1 วัน..... 54

ตารางที่ 21 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล TRON (TRX) ความถี่ 1 สัปดาห์..... 55

ตารางที่ 22 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) ความถี่ 1 วัน 56

ตารางที่ 23 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) ความถี่ 1 สัปดาห์ 57

ตารางที่ 24 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) ความถี่ 1 วัน 58

ตารางที่ 25 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) ความถี่ 1 สัปดาห์ 59

ตารางที่ 26 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) ความถี่ 1 วัน.... 60

ตารางที่ 27 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) ความถี่ 1 สัปดาห์
..... 61

ตารางที่ 28 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 วัน..... 62

ตารางที่ 29 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์... 63

ตารางที่ 30 แสดงตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) มากที่สุดสำหรับชุดข้อมูลสำหรับทดสอบ
(Test set)..... 64

ตารางที่ 31 แสดงตัวแบบที่ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดสำหรับชุดข้อมูลสำหรับทดสอบ
(Test set)..... 65

ตารางที่ 32 แสดงตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable
importance) 5 อันดับแรกในตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงิน
ดิจิทัล 66

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา (Background and Problem Review)

ในช่วงทศวรรษที่ผ่านมาการเติบโตของตลาดการซื้อขายสกุลเงินดิจิทัลมีการเติบโตแบบทวีคูณ โดยมีมูลค่าซื้อขายสูงถึงหลายหมื่นถึงแสนล้านบาท ซึ่งเคยมีมูลค่าซื้อขายสูงสุดประมาณ 2.52 แสนล้านบาทในเดือนพฤศจิกายน พ.ศ.2564 การลงทุนในตลาดสกุลเงินดิจิทัลได้รับความสนใจจากนักลงทุนจำนวนมากเพราะเป็นสินทรัพย์ที่สามารถให้ผลตอบแทนสูง ซึ่งอาจสูงกว่าการลงทุนในตลาดอื่น ๆ ในทางกลับกันสามารถทำให้เกิดความสูญเสียสูงเช่นกัน เนื่องจากมีความผันผวนสูง การลงทุนในตลาดสกุลเงินดิจิทัลจึงต้องอาศัยเครื่องมือวิเคราะห์ที่มีประสิทธิภาพในการจัดการลงทุน

นักลงทุนลงทุนในตลาดสกุลเงินดิจิทัลเป็นสินทรัพย์ทางเลือกที่เกิดขึ้นใหม่ในรูปแบบต่าง ๆ ผ่านกลยุทธ์การซื้อขายหลากหลาย โดยถือไว้เพื่อคาดหวังกำไรในระยะกลางถึงระยะยาว หรือโดยซื้อขายที่ความถี่สูง โดยเฉพาะอย่างยิ่งในการซื้อขายความถี่สูง นักลงทุนพยายามหาจุดเข้าและออกที่เหมาะสมที่สุดในอนุกรมเวลาทางการเงินโดยมีจุดประสงค์เพื่อให้ได้ผลตอบแทนสูงโดยมีความเสี่ยงต่ำ โดยใช้ประโยชน์จากวิธีการทางเทคนิคและกลยุทธ์การเรียนรู้ของเครื่อง (Machine Learning) (Monsalve et al., 2020)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นหนึ่งในเครื่องมือวิเคราะห์ที่มีประสิทธิภาพในการจัดการลงทุน โดยมีการใช้กันอย่างแพร่หลายในภาคการเงินเพื่อสร้างกลยุทธ์ที่ช่วยให้นักลงทุนตัดสินใจได้ดีขึ้น ในปัจจุบันการเรียนรู้ของเครื่อง (Machine Learning) มีกระบวนการมากมายซึ่งแต่ละกระบวนการที่ใช้สำหรับทำนายมีข้อดี และข้อเสียที่แตกต่างกัน นอกจากการเรียนรู้ของเครื่อง (Machine Learning) แล้วการวิเคราะห์ทางเทคนิค (Technical Analysis) เป็นอีกหนึ่งเครื่องมือที่ถูกใช้ทำนายในการลงทุนที่ได้รับความนิยมโดยมีงานวิจัยการทำนายข้อมูลตลาดหุ้นและตลาดสกุลเงินดิจิทัลในปัจจุบันจำนวนมากที่แสดงให้เห็นว่า ตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) มีประสิทธิภาพสูงสำหรับทำนายการซื้อขายในตลาดหุ้นและตลาดสกุลเงินดิจิทัล โดยให้ผลการทำนายแม่นยำกว่ากระบวนการอื่น ๆ และตัวบ่งชี้ทางเทคนิคที่แตกต่างกันส่งผลต่อความแม่นยำของการทำนายอย่างมีนัยสำคัญ เช่น Ozer and Sakar (2022), Gradojevic et al., (2021), Parray et al., (2020) และ Vo and Bremm (2020) และอีกหนึ่งปัจจัยที่ส่งผลต่อการทำนายอย่างมีนัยสำคัญ คือ ความถี่ของข้อมูล อ้างอิงจาก Grobys et al., (2020) และ Ortu et al., (2022)

นอกจากนี้เพื่อเพิ่มประสิทธิภาพสำหรับการทำนายของตัวแบบ การสร้างตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification เป็นวิธีที่ช่วยเพิ่มความแม่นยำของตัวแบบได้ ซึ่งมีงานวิจัย

ที่แสดงให้เห็นถึงการเพิ่มประสิทธิภาพสำหรับการทำนาย โดยใช้การสร้างตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification เช่น Ye et al., (2022), Dzeroski and Zenko (2004) อีกทั้งพบว่าเป็นวิธีที่ใช้ในงานวิจัยจำนวนมาก แต่ยังไม่พบได้น้อยสำหรับทำนายข้อมูลตลาดสกุลเงินดิจิทัลอ้างอิงจาก Ganaie et al., (2022)

จากเหตุผลข้างต้นทำให้เราสนใจศึกษาการซื้อขายสกุลเงินดิจิทัลโดยเปรียบเทียบวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และการวิเคราะห์ทางเทคนิค (Technical Analysis) สำหรับความถี่ที่แตกต่างกัน เพื่อแสดงให้เห็นถึงประสิทธิภาพของตัวแบบและสร้างกลยุทธ์การลงทุนให้ได้อัตราผลตอบแทนที่สูงขึ้น

1.2 วัตถุประสงค์ของการวิจัย (Objectives)

ทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และการวิเคราะห์ทางเทคนิค (Technical Analysis) สำหรับสกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก

1.3 ขอบเขตของการวิจัย (Scope of the Study)

งานวิจัยนี้ใช้ข้อมูลการซื้อขายสกุลเงินดิจิทัลจากฐานข้อมูล Coinmarketcap.com โดยใช้สกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก ข้อมูลระหว่าง เดือนมกราคม พ.ศ.2559 ถึง เดือนมิถุนายน พ.ศ.2565

1.4 ประโยชน์ที่คาดว่าจะได้รับ

งานวิจัยนี้สามารถทำให้ผู้ที่สนใจศึกษาเกี่ยวกับตลาดสกุลเงินดิจิทัลเห็นถึงประสิทธิภาพของการเรียนรู้ของเครื่อง (Machine Learning) ในส่วนของตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และการใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) สำหรับทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล เพื่อหาจุดซื้อขายสกุลเงินดิจิทัลที่เหมาะสมในการลงทุนให้ได้อัตราผลตอบแทนสูงขึ้น อีกทั้งผู้สนใจศึกษาสามารถนำความรู้ที่ได้ไปประยุกต์ใช้ในการลงทุนสำหรับสินทรัพย์อื่น ๆ ได้อย่างมีประสิทธิภาพ

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การซื้อขายในตลาดหุ้นเป็นกิจกรรมที่นักลงทุนต้องอาศัยข้อมูลที่รวดเร็วและแม่นยำในการตัดสินใจอย่างมีประสิทธิภาพ ปัจจุบันมีการศึกษาจำนวนมากเกี่ยวกับการทำนายตลาดหุ้นโดยใช้การวิเคราะห์ทางเทคนิค (Technical Analysis) โดยผลการศึกษาทบทวนงานวิจัยที่เกี่ยวข้องกับการทำนายตลาดหุ้นระหว่างช่วง พ.ศ.2550 ถึง พ.ศ.2561 พบว่าร้อยละ 66 ของงานวิจัยการทำนายตลาดหุ้นใช้การวิเคราะห์ทางเทคนิค (Technical Analysis) เพื่อเป้าหมายเพิ่มผลกำไรสูงสุดและลดความเสี่ยง Nti et al., (2019) นอกจากการทำนายตลาดหุ้นแล้ว การวิเคราะห์ทางเทคนิค (Technical Analysis) สามารถใช้ในการทำนายตลาดแลกเปลี่ยนเงินตราต่างประเทศและตลาดซื้อขายล่วงหน้า ซึ่งให้ผลกำไรดีกว่าตลาดหุ้นอีกด้วย Park (2007)

ในตลาดการเงินปัจจุบันการเรียนรู้ของเครื่อง (Machine Learning) เป็นเครื่องมือวิเคราะห์ที่ช่วยจัดการการลงทุนได้อย่างมีประสิทธิภาพ ทั้งในตลาดหุ้น พันธบัตร ตราสารอนุพันธ์ การแลกเปลี่ยนเงินตราต่างประเทศ และสินค้าโภคภัณฑ์ โดยการเรียนรู้ของเครื่อง (Machine Learning) มีกระบวนการมากมายในปัจจุบันซึ่งแต่ละกระบวนการที่ใช้สำหรับทำนายมีข้อดี และข้อเสียที่แตกต่างกัน Obthong et al., (2020) ดังตารางที่ 1

ตารางที่ 1 แสดงการเปรียบเทียบข้อดี และข้อเสียของแต่ละกระบวนการของการเรียนรู้ของเครื่อง (Machine Learning)

กระบวนการ (Methods)	ข้อดี (Advantages)	ข้อเสีย (Disadvantages)
Artificial Neural network (ANNs)	<ul style="list-style-type: none"> - ประสิทธิภาพสูงสำหรับรูปแบบไม่เชิงเส้น - ความแม่นยำสูงสำหรับข้อมูลกลุ่ม - แข็งแกร่งต่อตัวรบกวนและข้อมูลที่สูญหาย 	<ul style="list-style-type: none"> - ตัวแบบที่ได้เป็นการเรียนรู้ข้อมูลที่ตีความแต่ไม่สามารถนำไปใช้กับข้อมูลที่ไม่เคยพบมาก่อนได้ดี (Overfitting) - อ่อนไหวต่อการเลือกพารามิเตอร์
Autoregressive integrated moving average model (ARIMA)	<ul style="list-style-type: none"> - ทำงานได้ดีสำหรับอนุกรมเวลาเชิงเส้น - เป็นตัวแบบที่มีประสิทธิภาพมากที่สุดในสังคมศาสตร์ - สำหรับการทำนายระยะสั้นให้ความแข็งแกร่งและประสิทธิภาพมากกว่าตัวแบบที่ซับซ้อน 	<ul style="list-style-type: none"> - ทำงานได้ไม่ดีสำหรับอนุกรมเวลาไม่เชิงเส้น - ตัวแบบสำหรับข้อมูลชุดหนึ่งจะไม่เหมาะสมสำหรับข้อมูลชุดอื่น - ใช้เวลานานสำหรับข้อมูลขนาดใหญ่ - ต้องตั้งค่าพารามิเตอร์และขึ้นอยู่กับสมมติฐานของผู้ใช้ที่อาจเป็นเท็จ
Classification and Regression Trees (CART)	<ul style="list-style-type: none"> - สามารถสร้างตัวแบบไม่เชิงเส้นได้ดี - ผลลัพธ์ตีความได้ง่าย 	<ul style="list-style-type: none"> - ไม่เสถียรแม้ข้อมูลที่เปลี่ยนแปลงเล็กน้อย
Genetic Algorithms (Gas)	<ul style="list-style-type: none"> - เหมาะสำหรับข้อมูลอนุกรมเวลาที่มีตัว 	<ul style="list-style-type: none"> - อ่อนไหวต่อการเลือกพารามิเตอร์

	<p>รบกวน</p> <ul style="list-style-type: none"> - เหมาะสำหรับปัญหาที่ยากเป็นพิเศษเมื่อให้ข้อมูลน้อย หรือไม่มีเลย เหมาะสำหรับข้อมูลขนาดใหญ่ - เหมาะสำหรับแก้ปัญหาการกำหนดพารามิเตอร์ที่เหมาะสมสำหรับ ANNs 	
Group Method of Data Handling (GMDH)	<ul style="list-style-type: none"> - เหมาะสำหรับจัดการข้อมูลที่ไม่ถูกต้อง มีตัวรบกวน หรือข้อมูลขนาดเล็ก - มีความแม่นยำสูงและง่ายกว่า ANNs แบบดั้งเดิม 	<ul style="list-style-type: none"> - ไม่สามารถพิจารณาความสัมพันธ์การนำเข้า-ส่งออก เนื่องจากมีขีดจำกัด - ไม่มีประสิทธิภาพสำหรับตัวแบบไม่เชิงเส้น
Gaussian Processes (GP)	<ul style="list-style-type: none"> - การใช้งานการคำนวณยืดหยุ่นและง่าย - แข็งแกร่งพอที่จะสร้างตัวแบบอัตโนมัติ 	<ul style="list-style-type: none"> - สร้างตัวแบบกล่องดำ (black box) ซึ่งตีความยาก - อาจมีราคาแพงในการคำนวณ
Generalized Regression Neural Network (GRNN)	<ul style="list-style-type: none"> - ใช้งานง่ายเนื่องจากขั้นตอนฝึกอบรมที่เร็วกว่า ANNs รุ่นอื่นๆ - สามารถคำนวณแบบเรียลไทม์ - ไม่จำเป็นต้องฝึกอบรมกระบวนการซ้ำ สามารถประมาณฟังก์ชันได้โดยตรง - การฝึกอบรมอย่างรวดเร็ว - ให้ความแม่นยำสูงทั้งฟังก์ชันการถดถอยเชิงเส้นและไม่เชิงเส้นบนพื้นฐานทฤษฎีการประมาณค่าเคอร์เนล 	<ul style="list-style-type: none"> - ต้องการพื้นที่หน่วยความจำมากขึ้นในการจัดเก็บ - อาจมีราคาแพงในการคำนวณเพราะมีขนาดใหญ่
Hidden Markov Model (HMM)	<ul style="list-style-type: none"> - พื้นฐานทางสถิติที่แข็งแกร่ง - สามารถสร้างตัวแบบข้อมูลระดับสูง 	<ul style="list-style-type: none"> - ต้องตั้งค่าพารามิเตอร์และขึ้นอยู่กับสมมติฐานของผู้ใช้ที่อาจเป็นเท็จ - ใช้เวลานานในการประมวลผลสำหรับข้อมูลขนาดใหญ่
K Nearest Neighbour (KNN)	<ul style="list-style-type: none"> - แข็งแกร่งต่อตัวรบกวน - มีประสิทธิภาพมากหากข้อมูลการฝึกอบรมมีขนาดใหญ่ 	<ul style="list-style-type: none"> - ต้องกำหนดจำนวนที่ใกล้เคียงที่สุดก่อน - อาจมีราคาแพงในการคำนวณ - ข้อจำกัดของหน่วยความจำ - อ่อนไหวต่อโครงสร้างภายในของข้อมูล
Logistic Regression (LR)	<ul style="list-style-type: none"> - ประสิทธิภาพสูงสำหรับรูปแบบไม่เชิงเส้น 	<ul style="list-style-type: none"> - อ่อนไหวต่อค่าผิดปกติ - สมมติฐานที่แข็งแกร่ง
Long Short-Term Memory (LSTM)	<ul style="list-style-type: none"> - สามารถวิเคราะห์และใช้ประโยชน์จากการโต้ตอบและรูปแบบที่อยู่ในกระบวนการเรียนรู้ด้วยตนเอง 	<ul style="list-style-type: none"> - ไม่มีกลไกในการจัดทำดัชนีหน่วยความจำขณะเขียนและอ่านข้อมูลจำนวนเซลล์หน่วยความจำที่เชื่อมโยงกับขนาดของเมท

	- จัดจำข้อมูลระยะยาวได้ดี	ริกซ์น้ำหนักที่เกิดซ้ำ
Monte Carlo Simulation (MCS)	- มีความยืดหยุ่นสูงและไม่มีขีดจำกัดสำหรับการวิเคราะห์ - สามารถใช้กับตัวแบบระบบที่ซับซ้อน - ความน่าจะเป็นของตัวแปรสุ่มทุกประเภทสามารถสร้างตัวแบบได้ - ใช้เวลาคำนวณน้อยกว่าสำหรับหาผลลัพธ์	- ไม่มีการเชื่อมโยงระหว่างข้อมูลและพารามิเตอร์ - ทิศทางเดียว - ไม่สามารถทำแบบย้อนหลัง (backward reasoning)
Multilayer Perceptron (MLP)	- สามารถทำนายปัญหาที่ท้าทายได้อย่างแม่นยำ	- ลู่เข้าค่อนข้างช้า - ค่าขั้นต่ำในท้องถิ่นอาจส่งผลกระทบต่อกระบวนการฝึกอบรม - ปรับขนาดได้ยาก
Particle Swarm Optimization (PSO)	- ใช้งานง่าย - ปรับแต่งพารามิเตอร์น้อยมาก	- ไม่มีพื้นฐานทางคณิตศาสตร์ที่มั่นคงสำหรับการวิเคราะห์การพัฒนาในอนาคตของทฤษฎีที่เกี่ยวข้อง
Radial Basis Function Neural Networks (RBF)	- แข็งแกร่งต่อตัวรบกวน - มีเสถียรภาพมากและมีลักษณะทั่วไป - มีความสามารถในการปรับตัวและการเรียนรู้ที่ครอบคลุม - มีเพียงชั้นเดียวที่ซ่อนอยู่ทำให้เรียนรู้ได้เร็วกว่า MLP	- กระบวนการจัดประเภทช้ากว่า MLP
Random Forest (RF)	- วิธีการทำนายที่แข็งแกร่ง มีการจัดประเภทปัญหา และมีคุณสมบัติเป็นตัวแบบแบบสุ่ม - จัดการค่าที่หายไปโดยอัตโนมัติ - ทำงานได้ดีกับตัวแปรทั้งไม่ต่อเนื่อง และต่อเนื่อง	- ต้องใช้กำลังและทรัพยากรในการคำนวณมาก
Recurrent neural networks (RNN)	- มีประโยชน์มากในการแสดงความสัมพันธ์เวลาที่เกิดขึ้นระหว่างการนำเข้า และส่งออกในโครงข่ายประสาทเทียม	- ฝึกอบรมยาก
Support Vector Machine (SVM)	- สามารถให้วิธีที่ดีและมีความสามารถในการทำนายอย่างแม่นยำ - ทำงานได้ดีกับการจัดหมวดหมู่ประเภทต่างๆ	- อ่อนไหวต่อค่าผิดปกติ - อ่อนไหวต่อการเลือกพารามิเตอร์
Support Vector Regression (SVR)	- มีประสิทธิภาพในการทำนายอนุกรมเวลาทางการเงิน - เหมาะอย่างยิ่งที่จะจัดการกับการนำเข้า	- อ่อนไหวต่อพารามิเตอร์อิสระที่กำหนดโดยผู้ใช้

	หลายตัว - ให้ความแม่นยำในการทำนายสูง - มีความสามารถในการจัดการปัญหา Overfitting	
--	---	--

จากตารางจะเห็นว่าแต่ละกระบวนการมีข้อดี-ข้อเสียที่แตกต่างกันขึ้นอยู่กับปัจจัยต่าง ๆ ซึ่งจากการศึกษางานวิจัยการทำนายข้อมูลตลาดหุ้นและตลาดสกุลเงินดิจิทัลในปัจจุบันมีงานวิจัยจำนวนมากที่แสดงให้เห็นว่าตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) มีประสิทธิภาพสูงสำหรับทำนายการซื้อขายในตลาดหุ้นและตลาดสกุลเงินดิจิทัล โดยให้ผลการทำนายแม่นยำกว่ากระบวนการอื่น ๆ และตัวบ่งชี้ทางเทคนิคที่แตกต่างกันส่งผลต่อความแม่นยำของการทำนายอย่างมีนัยสำคัญ อ้างอิงจาก Ozer and Sakar (2022) ได้ศึกษาการซื้อขายสกุลเงินดิจิทัลซึ่งใช้กลยุทธ์การซื้อขาย 3 กลยุทธ์ ประกอบด้วย 1) กลยุทธ์การเรียนรู้ของเครื่อง (Machine Learning) 2) กลยุทธ์ตัวแบบพื้นฐาน (Simple Technical Strategy) และ 3) กลยุทธ์การซื้อและถือ (Buy and Hold Strategy) โดยกำหนดตัวแปรตามเป็นการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัล และตัวแปรอิสระเป็นค่าของราคาซื้อขายสกุลเงินดิจิทัล ซึ่งประเมินผลโดยใช้อัตราผลตอบแทนเฉลี่ย (Average ROI) และจากการศึกษาการซื้อขายสกุลเงินดิจิทัล 3 สกุลเงินดิจิทัลพบว่าการใช้กลยุทธ์การเรียนรู้ของเครื่อง (Machine Learning) ให้อัตราผลตอบแทนเฉลี่ย (Average ROI) มากกว่ากลยุทธ์ตัวแบบพื้นฐาน (Simple Technical Strategy) และกลยุทธ์การซื้อและถือ (Buy and Hold Strategy) ในการศึกษาที่ใช้กลยุทธ์การเรียนรู้ของเครื่อง (Machine learning) 6 วิธี ประกอบด้วย 1) Logistic Regression 2) k-Nearest Neighbor (KNN) 3) Support Vector Machines (SVM) 4) Random Forest (RF) 5) Extreme Gradient Boosting (XGBoost) และ 6) CatBoost ซึ่งวิธีการใช้ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) ให้อัตราผลตอบแทนเฉลี่ยสูงสุดสำหรับข้อมูลความถี่ 4 ชั่วโมง และวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้อัตราผลตอบแทนเฉลี่ยสูงสุดสำหรับข้อมูลความถี่ 1 วัน นอกจากนี้ ยังพบว่าการซื้อขายในความถี่ 4 ชั่วโมงให้อัตราผลตอบแทนมากกว่าในความถี่ 1 วัน

อีกทั้งก่อนหน้านี้ Gradojevic et al., (2021) ได้ศึกษาการทำนายราคาสกุลเงินดิจิทัลโดยวิธีการใช้ตัวแบบ 4 ตัวแบบ ประกอบด้วย 1) ตัวแบบ Artificial neural network ทางการเงิน (ANNs in finance) 2) ตัวแบบ Feedforward deep artificial neural network (FF-D-ANN) 3) ตัวแบบ Support vector machine (SVM) และ 4) Random Forest (RF) โดยการใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) 5 ตัวบ่งชี้ ประกอบด้วย 1) Moving Average Crossover 2) Moving average convergence divergence (MACD) 3) Rate of Change (ROC) 4) ดัชนีความแกร่งเชิงสัมพัทธ์ (Relative strength index (RSI)) 5) Williams %R 6) On balance volume

และ 7) Fear and Greed โดยกำหนดตัวแปรตามเป็นร้อยละของการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัล และแปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator) ซึ่งประเมินผลโดยใช้ค่าประมาณค่าเฉลี่ยของความผิดพลาดจากการทำนายกำลังสอง (Mean Square Prediction) จากการศึกษาการซื้อขายสกุลเงินดิจิทัลบิตคอยน์ (Bitcoin) พบว่าการใช้ตัวบ่งชี้ที่ต่างกันส่งผลทำนายอย่างมีนัยสำคัญ และการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ผลลัพธ์ที่ดีที่สุด และ Parray et al., (2020) ได้ศึกษาการทำนายราคาหุ้นโดยวิธีการใช้ ตัวแบบ Machine Learning 3 ตัวแบบ คือ 1) ตัวแบบ Support vector machine (SVM) 2) ตัวแบบ Perceptron และ 3) ตัวแบบ Logistic Regression (LR) โดยการใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) 4 ตัวบ่งชี้ ประกอบด้วย 1) Exponential moving average (EMA) 2) Moving average convergence divergence (MACD) 3) ดัชนีความแกร่งเชิงสัมพันธ์ (Relative strength index (RSI)) และ 4) Average True Range (ATR) โดยกำหนดตัวแปรตามเป็นการเปลี่ยนแปลงของราคาซื้อขายหุ้น และแปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator) ซึ่งประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score จากการศึกษาการซื้อขายหุ้นพบว่าการใช้ตัวแบบ Support vector machine (SVM) และตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) ให้ผลลัพธ์ใกล้เคียงกัน และดีกว่าตัวแบบ Perceptron อย่างเห็นได้ชัด

นอกจากนี้ Vo and Bremm (2020) ได้ศึกษาการซื้อขายสกุลเงินดิจิทัลด้วยความถี่สูงโดยวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบ Deep Learning โดยการใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) 5 ตัวบ่งชี้ ประกอบด้วย 1) ดัชนีความแกร่งเชิงสัมพันธ์ (Relative strength index (RSI)) 2) Stochastic oscillator 3) Williams %R 4) Moving average convergence divergence (MACD) และ 5) On balance volume (OBV) โดยกำหนดตัวแปรตามเป็นสัญญาณซื้อขายสกุลเงินดิจิทัล และแปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator) ซึ่งประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score จากการศึกษาการซื้อขายสกุลเงินดิจิทัลบิตคอยน์ (Bitcoin) พบว่าดัชนีความแกร่งเชิงสัมพันธ์ (Relative strength index (RSI)) ส่งผลต่อการทำนายมากที่สุด โดยการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ผลลัพธ์ดีกว่าตัวแบบ Deep Learning และการซื้อขายด้วยความถี่สูงให้ผลลัพธ์ดีกว่าการซื้อขายด้วยความถี่ต่ำ

จากการศึกษาข้างต้นจะเห็นว่าอีกหนึ่งปัจจัยที่ส่งผลต่อการทำนาย คือ ความถี่ของข้อมูล ซึ่งสอดคล้องกับ Grobys et al., (2020) ซึ่งได้ศึกษาการซื้อขายสกุลเงินดิจิทัล โดยการใช้กลยุทธ์ค่าเฉลี่ยเคลื่อนที่ Variable Moving Average oscillator (VMA) จากการศึกษาการซื้อขายสกุลเงิน

ดิจิทัล 11 สกุลเงินดิจิทัลพบว่าการใช้ค่าเฉลี่ยเคลื่อนที่ระยะสั้นให้ผลตอบแทนเฉลี่ยมากกว่าการใช้ค่าเฉลี่ยเคลื่อนที่ระยะยาว และ Ortu et al., (2022) ได้ศึกษาการทำนายราคาสกุลเงินดิจิทัลโดยวิธีการใช้ ตัวแบบ Deep Learning โดยการใช้ตัวบ่งชี้ 3 กลุ่ม คือ 1) กลุ่มตัวบ่งชี้เทคนิค ซึ่งประกอบด้วย ราคาปิด ราคาเปิด ราคาต่ำสุด ราคาสูงสุด ปริมาณการซื้อขาย 2) กลุ่มตัวบ่งชี้การซื้อขาย ประกอบด้วย 8 ตัวบ่งชี้ คือ 2.1) Moving average (MA) 2.2) Exponential moving average (EMA) 2.3) Stochastic oscillator 2.4) Moving average convergence divergence (MACD) 2.5) Bollinger bands 2.6) ดัชนีความแกร่งเชิงสัมพัทธ์ (Relative strength index (RSI)) 2.7) Fibonacci retracement levels และ 2.8) Average directional index และ 3) กลุ่มตัวบ่งชี้โซเชียล โดยกำหนดตัวแปรตามเป็นราคาซื้อขายสกุลเงินดิจิทัล และแปรอิสระเป็นค่าของตัวบ่งชี้ ซึ่งประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score จากการศึกษาการทำนายราคาสกุลเงินดิจิทัลพบว่าการทำนายราคาบิตคอยน์ (Bitcoin) และอีเธอร์ (Ethereum) ด้วยข้อมูลความถี่ 1 ชั่วโมง ตัวแบบที่ใช้ตัวบ่งชี้ทั้ง 3 กลุ่มให้ผลลัพธ์ที่ดีที่สุด สำหรับการทำนายราคาบิตคอยน์ (Bitcoin) ด้วยข้อมูลความถี่ 1 วัน ตัวแบบที่ใช้ตัวบ่งชี้ทางเทคนิค และตัวบ่งชี้โซเชียลมีเดียให้ผลลัพธ์ที่ดีที่สุด สำหรับการทำนายอีเธอร์ (Ethereum) ด้วยข้อมูลความถี่ 1 วัน ตัวแบบที่ใช้ตัวบ่งชี้เทคนิคให้ผลลัพธ์ที่ดีที่สุด อีกทั้งสำหรับข้อมูลความถี่ 1 วัน การใช้ตัวบ่งชี้ทางเทคนิคส่งผลต่อประสิทธิภาพที่ดีกว่า

จากการศึกษางานวิจัยการทำนายข้อมูลตลาดหุ้นและตลาดสกุลเงินดิจิทัลสามารถสรุปได้ดังตารางที่ 2

ตารางที่ 2 แสดงสรุปการศึกษางานวิจัยการทำนายข้อมูลตลาดหุ้นและตลาดสกุลเงินดิจิทัล

ผู้ศึกษา	ข้อมูล	ตัวแบบ	ตัวบ่งชี้	สรุปผลการศึกษา
Ozer and Sakar (2022)	Bitcoin (BTC) Ethereum (ETH) และ Litecoin (LTC) 1 กรกฎาคม 2560 ถึง 30 เมษายน 2564 ความถี่ 4 ชั่วโมง และ 1 วัน แปรตามเป็นการ เปลี่ยนแปลงของราคา ซื้อขายสกุลเงินดิจิทัล ตัวแปรอิสระเป็นค่าของ ราคาซื้อขายสกุลเงิน	1) Logistic Regression (LR) 2) k-Nearest Neighbor (KNN) 3) Support Vector Machines (SVM) 4) Random Forest (RF) 5) Extreme Gradient Boosting (XGBoost) 6) CatBoost	1) Relative strength index (RSI)	ประเมินผลโดยใช้อัตรา ผลตอบแทนเฉลี่ย (Average ROI) สรุปได้ว่า Logistic Regression (LR) ให้อัตรา ผลตอบแทนเฉลี่ยสูงสุดสำหรับ ข้อมูลความถี่ 4 ชั่วโมง และ Random Forest (RF) ให้ อัตราผลตอบแทนเฉลี่ยสูงสุด สำหรับข้อมูลความถี่ 1 วัน การซื้อขายในความถี่ 4 ชั่วโมง ให้อัตราผลตอบแทนเฉลี่ย

	ดิจิทัล			มากกว่าในเวลาที่ 1 วัน
Gradojevic et al., (2021)	Bitcoin (BTC) 11 พฤษภาคม 2558 ถึง 7 มีนาคม 2562 ความถี่ 1 ชั่วโมง ตัวแปรตามเป็นร้อยละของการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัล แปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator)	1) Artificial neural network ทางการเงิน (ANNs in finance) 2) Feedforward deep artificial neural network (FF-D-ANN) 3) Support vector machine (SVM) 4) Random Forest (RF)	1) Moving Average Crossover 2) Moving average convergence divergence (MACD) 3) Rate of Change (ROC) 4) Relative strength index (RSI) 5) Williams %R 6) On balance volume 7) Fear and Greed	ประเมินผลโดยใช้ค่าประมาณค่าเฉลี่ยของความผิดพลาดจากการทำนายกำลังสอง (Mean Square Prediction) สรุปได้ว่า การใช้ตัวบ่งชี้ที่แตกต่างกันส่งผลต่อความแม่นยำของการทำนายอย่างมีนัยสำคัญ และการใช้ Random Forest (RF) ให้ผลลัพธ์ที่ดีที่สุด
Parray et al., (2020)	หุ้น National Stock Exchange Fifty (NSEI) 1 มกราคม 2556 ถึง 31 ธันวาคม 2561 ตัวแปรตามเป็นการเปลี่ยนแปลงของราคาซื้อขายหุ้น แปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator)	1) Support vector machine (SVM) 2) Perceptron 3) Logistic Regression (LR)	1) Exponential moving average (EMA) 2) Moving average convergence divergence (MACD) 3) Relative strength index (RSI) 4) Average True Range (ATR)	ประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score สรุปได้ว่า Support vector machine (SVM) และ Logistic Regression (LR) ให้ผลลัพธ์ที่ใกล้เคียงกัน และดีกว่า Perceptron อย่างเห็นได้ชัด
Vo and Bremm (2020)	Bitcoin (BTC) 1 มกราคม 2555 ถึง 31 พฤษภาคม 2560 ความถี่ 1 นาที 5 นาที 15 นาที 30 นาที 1 ชั่วโมง 1.5 ชั่วโมง 2 ชั่วโมง 2.5 ชั่วโมง 3 ชั่วโมง 6 ชั่วโมง 12 ชั่วโมง 1 วัน 2 วัน 7 วัน 14 วัน 30	1) Random Forest (RF) 2) Deep Learning (DL)	1) Relative strength index (RSI) 2) Stochastic oscillator 3) Williams %R 4) Moving average convergence divergence (MACD) 5) On balance volume (OBV)	ประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score สรุปได้ว่า ดัชนี Relative strength index (RSI) ส่งผลต่อการทำนายมากที่สุด โดยการใช้ตัวแบบป่าสุ่ม Random Forest (RF) ให้ผลลัพธ์ดีกว่าตัวแบบ Deep Learning และ

	วัน 60 วัน และ 90 วัน ตัวแปรตามเป็นสัญญาณ ซื้อขายสกุลเงินดิจิทัล แปรอิสระเป็นค่าของตัว บ่งชี้ทางเทคนิค (Technical indicator)			การซื้อขายด้วยความถี่สูงให้ ผลลัพธ์ดีกว่าการซื้อขายด้วย ความถี่ต่ำ
Grobys et al., (2020)	Bitcoin (BTC) Ripple (XRP) Litecoin (LTC) Ethereum (ETH) Dogecoin (DOGE) Peercoin (PPC) BitShares (BTS) Stellar Lumen (XLM) Nxt (NXT) MaidSafeCoin (MAID) และ Namecoin (NMC) 1 มกราคม 2559 ถึง 31 พฤษภาคม 2561 ความถี่ 20 วัน 50 วัน 100 วัน 150 วัน และ 200 วัน		Variable Moving Average oscillator (VMA)	การใช้ค่าเฉลี่ยเคลื่อนที่ระยะ สั้นให้ผลตอบแทนเฉลี่ย มากกว่าการใช้ค่าเฉลี่ย เคลื่อนที่ระยะยาว
Ortu et al., (2022)	Bitcoin (BTC) และ Ethereum (ETH) มกราคม 2560 ถึง มกราคม 2564 ความถี่ 1 ชั่วโมง และ 1 วัน ตัวแปรตามเป็นราคาซื้อ ขายสกุลเงินดิจิทัล แปรอิสระเป็นค่าของตัว บ่งชี้	1) Multi-Layer Perceptron (MLP) 2) Convolution Neural Network (CNN) 3) Long Short Term Memory neural network (LSTM) 4) Attention Long Short Term Memory (ALSTM)	1) กลุ่มตัวบ่งชี้เทคนิค ประกอบด้วย ราคาปิด ราคาเปิด ราคาต่ำสุด ราคาสูงสุด ปริมาณ การซื้อขาย 2) กลุ่มตัวบ่งชี้การซื้อ ขาย ประกอบด้วย 2.1) Moving average (MA) 2.2) Exponential moving average (EMA) 2.3) Stochastic	ประเมินผลโดยใช้ค่าความ ถูกต้อง (Accuracy) ค่าความ แม่นยำ (Precision) ค่าความ ไว (Recall) และค่าสถิติ F1 score สรุปได้ว่า สำหรับการทำนาย ราคา Bitcoin และ Ethereum ด้วยข้อมูลความถี่ 1 ชั่วโมง ตัวแบบที่ใช้ตัวบ่งชี้ ทั้ง 3 กลุ่มให้ผลลัพธ์ที่ดีที่สุด สำหรับการทำนายราคา Bitcoin ด้วยข้อมูลความถี่ 1 วัน ตัวแบบที่ใช้ตัวบ่งชี้ทาง

			oscillator 2.4) Moving average convergence divergence (MACD) 2.5) Bollinger bands 2.6) Relative strength index (RSI) 2.7) Fibonacci retracement levels 2.8) Average directional index 3) กลุ่มตัวบ่งชี้เซเชี่ยล มีเดีย	เทคนิค และตัวบ่งชี้เซเชี่ยล มีเดียให้ผลลัพธ์ที่ดีที่สุด สำหรับการทำนาย Ethereum ด้วยข้อมูลความถี่ 1 วัน ตัว แบบที่ใช้ตัวบ่งชี้เทคนิคให้ ผลลัพธ์ที่ดีที่สุด อีกทั้งสำหรับ ข้อมูลความถี่ 1 วันการใช้ตัว บ่งชี้ทางเทคนิคส่งผลต่อ ประสิทธิภาพที่ดีกว่า
--	--	--	--	--

นอกจากนี้เพื่อเพิ่มประสิทธิภาพสำหรับการทำนายของตัวแบบ การสร้างตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification เป็นวิธีที่ช่วยเพิ่มความแม่นยำของตัวแบบได้ ซึ่งม้งานวิจัยที่แสดงให้เห็นถึงการเพิ่มประสิทธิภาพสำหรับการทำนาย โดยใช้การสร้างตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification อ้างอิงจาก Dzeroski and Zenko (2004) ได้ศึกษาการเปรียบเทียบวิธีการ Stacking Classification และวิธีการเลือกที่ดีที่สุด (Selecting the best classifier) โดยทำการทดลองกับชุดข้อมูล 30 ชุดที่ถูกใช้อย่างกว้างขวางในการศึกษาเปรียบเทียบอื่นๆ จากการศึกษาพบว่าวิธีการ Stacking Classification มีประสิทธิภาพมากกว่าวิธีการเลือกที่ดีที่สุด (Selecting the best classifier) และสำหรับข้อมูลตลาดสกุลเงินดิจิทัล Ye et al., (2022) ได้ศึกษาการทำนายราคาสกุลเงินดิจิทัลบิทคอยน์ (Bitcoin) โดยใช้วิธีการ Stacking Classification สำหรับตัวแบบ Long short-term memory (LSTM) และจำลอง Gate recurrent unit (GRU) และใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) 6 ตัวบ่งชี้ ประกอบด้วย 1) Moving average convergence divergence (MACD) 2) Simple moving average (SMA) 3) Stop and reverse (SAR) 4) On balance volume (OBV) 5) Relative strength index (RSI) และ 6) Money flow index (MFI)) โดยกำหนดตัวแปรตามเป็นราคาซื้อขายสกุลเงินดิจิทัล และแปรอิสระเป็นค่าของตัวบ่งชี้ ซึ่งประเมินผลโดยใช้ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error) ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error) และค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน (Mean Absolute Percentage Error) จากการศึกษาพบว่าการสร้างตัวแบบโดยใช้วิธีการ Stacking Classification ให้ผลลัพธ์ที่ดีที่สุด ซึ่งดีกว่าการสร้างตัวแบบโดยใช้ Long short-term memory (LSTM) หรือ Gate recurrent unit (GRU) เพียงอย่างเดียวอย่างหนึ่ง และการใช้ตัวบ่งชี้ทางเทคนิคช่วยเพิ่มประสิทธิภาพสำหรับการทำนายได้ นอกจากนี้พบว่าวิธีการ Stacking Classification เป็นวิธี

ที่ใช้ในงานวิจัยจำนวนมาก แต่ยังพบได้น้อยสำหรับทำนายข้อมูลตลาดสกุลเงินดิจิทัล อ้างอิงจาก Ganaie et al., (2022)

จากการศึกษาเหล่านี้ เราเห็นว่าตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) มีศักยภาพที่สำคัญสำหรับทำนายการซื้อขายในตลาดหุ้นและตลาดสกุลเงินดิจิทัล โดยเฉพาะสกุลเงินดิจิทัลบิตคอยน์ (Bitcoin) อีกทั้งการซื้อขายด้วยความถี่ที่แตกต่างกัน และตัวบ่งชี้ทางเทคนิคที่แตกต่างกันส่งผลต่อความแม่นยำของแต่ละสกุลเงินดิจิทัล ดังนั้น เพื่อการศึกษาที่ครอบคลุมมากขึ้น งานวิจัยนี้จะศึกษาการซื้อขายสกุลเงินดิจิทัลที่มีมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก ข้อมูลระหว่าง มกราคม พ.ศ.2559 ถึง มิถุนายน พ.ศ.2565 โดยเปรียบเทียบวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สำหรับข้อมูลความถี่ 1 วัน และ 1 สัปดาห์ และใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) ให้ครอบคลุมทุกประเภท โดยประกอบด้วย 50 ตัวบ่งชี้ คือ 1) Welles Wilder's Directional Movement Index 2) Aroon 3) Average True Range 4) Bollinger Bands 5) Commodity Channel Index 6) Chaikin Accumulation 7) Chaikin Volatility 8) Close Location Value 9) Chaikin Money Flow 10) Chande Momentum Oscillator 11) Donchian Channel (Upper) 12) Donchian Channel (Middle) 13) Donchian Channel (Lower) 14) Volatility (German and Klass-Yang and Zhang) 15) Arms' Ease of Movement Value 16) Guppy Multiple Moving Averages 17) Keltner Channels 18) Know Sure Thing 19) Volatility (German and Klass) 20) Moving average convergence divergence 21) Money Flow Index 22) On Balance Volume 23) Construct volatility bands around prices 24) Rate of Change 25) Volatility (Parkinson) 26) Relative Strength Index 27) Volatility (Rogers and Satchell) 28) Stochastic oscillator (Stow %D) 29) Parabolic Stop-and-Reverse 30) Simple moving average 31) Exponential moving average 32) Weighted moving average 33) Double-exponential moving average 34) Elastic, volume-weighted moving average 35) Zero lag exponential moving average 36) Volume-weighted moving average 37) Volatility (Yang and Zhang) 38) Stochastic oscillator (Fast %D) 39) Hull moving average 40) Arnaud Legoux moving average 41) Signal to Noise Ratio 42) Stochastic oscillator (Fast %K) 43) Trend Detection Index 44) Triple Smoothed Exponential Oscillator 45) The Ultimate Oscillator 46) Vertical Horizontal Filter 47) Volatility (Close) 48) Williams Accumulation 49) William's %R 50) Zig Zag ซึ่งจะวัดประสิทธิภาพของตัวแบบจากการสร้าง Confusion Matrix โดยใช้ค่าความถูกต้อง

(Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score ในการประเมินผล และการสร้างกราฟ Receiver Operator Characteristics (ROC)



บทที่ 3

วิธีการดำเนินการวิจัย

3.1 ข้อมูล

การศึกษานี้ได้รวบรวมข้อมูลการซื้อขายของสกุลเงินดิจิทัลจากฐานข้อมูล Coinmarketcap.com ซึ่งเป็นแหล่งข้อมูลราคาและปริมาณของสกุลเงินดิจิทัลที่เป็นที่นิยมในการศึกษา และมีงานวิจัยที่ใช้ข้อมูลในแหล่งข้อมูลดังกล่าวจำนวนมาก เช่น Gkillas and Katsiampa (2018) โดยใช้ข้อมูลสกุลเงินดิจิทัลที่มีมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก ข้อมูลระหว่าง มกราคม พ.ศ.2559 ถึง มิถุนายน พ.ศ.2565 โดยใช้ข้อมูลความถี่ที่แตกต่างกัน 2 แบบ ได้แก่ ข้อมูลความถี่ 1 วัน และ 1 สัปดาห์

ตารางที่ 3 แสดงข้อมูลสกุลเงินดิจิทัลที่มีมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก

อันดับ	สกุลเงินดิจิทัล	อันดับ	สกุลเงินดิจิทัล
1	Bitcoin (BTC)	11	Solana (SOL)
2	Ethereum (ETH)	12	Litecoin (LTC)
3	United States Dollar Tether (USDT)	13	Polkadot (DOT)
4	Binance Coin (BNB)	14	Toncoin (TON)
5	USD Coin (USDC)	15	Dai (DAI)
6	Ripple (XRP)	16	Binance USD (BUSD)
7	Cardano (ADA)	17	Avalanche (AVAX)
8	Dogecoin (DOGE)	18	Wrapped Bitcoin (WBTC)
9	TRON (TRX)	19	Shiba Inu coin (SHIB)
10	Polygon (MATIC)	20	UNUS SED LEO (LEO)

ข้อมูลที่ใช้ในการศึกษาจะแบ่งออกเป็น 2 ชุด คือ ชุดข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set) โดยชุดข้อมูลสำหรับการสอน (Training set) จะเป็นข้อมูลระหว่าง มกราคม พ.ศ.2559 ถึง มิถุนายน พ.ศ.2564 และชุดข้อมูลสำหรับทดสอบ (Test set) จะเป็นข้อมูลระหว่าง กรกฎาคม พ.ศ.2564 ถึง มิถุนายน พ.ศ.2565

เนื่องจากสกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก มีสกุลเงินดิจิทัล 4 สกุลเงินดิจิทัลที่จัดอยู่ในหมวดของ Stablecoin ซึ่งคือ สกุลเงินดิจิทัลที่มีความมั่นคงสูง การเปลี่ยนแปลงของราคาน้อยมาก และเป็นตัวกลางในการซื้อขายแลกเปลี่ยนสกุลเงินดิจิทัลอื่นๆ ได้แก่ United States Dollar Tether (USDT) USD Coin (USDC) Dai (DAI) และ Binance USD (BUSD) และมีข้อมูลสกุลเงินดิจิทัล 5 สกุลเงินดิจิทัลที่มีข้อมูลย้อนหลังน้อยกว่า 2 ปี

คือ Solana (SOL) Polkadot (DOT) Toncoin (TON) Avalanche (AVAX) และ Shiba Inu coin (SHIB) จึงไม่ได้ศึกษาเพื่อทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลเหล่านี้

3.2 ตัวบ่งชี้ทางเทคนิค (Technical indicator)

งานวิจัยนี้เราจะศึกษาโดยใช้ตัวบ่งชี้ทางเทคนิคให้ครอบคลุมทุกประเภท ซึ่งได้แก่ ตัวบ่งชี้บอกแนวโน้ม ตัวบ่งชี้บอกโมเมนตัม ตัวบ่งชี้วัดปริมาณการซื้อขาย ตัวบ่งชี้วัดความผันผวน และตัวบ่งบอกแนวรับและแนวต้าน โดยประกอบด้วย 50 ตัวบ่งชี้จากแพ็คเกจ TTR ในโปรแกรม R Ulrich (2022) ดังต่อไปนี้

1) Welles Wilder's Directional Movement Index เป็นตัวบ่งชี้ที่ได้รับการพัฒนาโดย Wilder (1978) ซึ่งมีสูตรดังนี้

Directional movement index (DM)

$$DM_t = DM(+) = H_t - H_{t-1} > L_{t-1} - L_t = H_t - H_{t-1}$$

กรณีอื่นๆ $DM(+) = 0$

$$DM_t = DM(-) = L_{t-1} - L_t > H_t - H_{t-1} = L_{t-1} - L_t$$

กรณีอื่นๆ $DM(-) = 0$

$$TR_t = \text{Max}[|H_t - L_t|, |H_t - C_{t-1}|, |L_t - C_{t-1}|]$$

$$DI(+)=\frac{100DM(+)}{TR} \text{ และ } DI(-)=\frac{100DM(-)}{TR}$$

สำหรับ 14 ช่วงระยะเวลาแรก $DI(\pm) = \sum_{t=1}^{14} DI(\pm)/13$

Direction index (DX)

$$DX_t = [(DI(+)-DI(-))/(DI(+)+DI(-))]$$

โดยที่ Subsequent $DI(\pm) = (DI(\pm) 14 \text{ ช่วงระยะเวลาก่อนหน้า} - DI(\pm) \text{ ค่าเฉลี่ย } 14 \text{ ช่วงระยะเวลา} + DI(\pm) \text{ ปัจจุบัน})$

Average directional index (ADX)

$$ADX = \left\{ \begin{array}{l} 1st \ ADX = \frac{1}{14} \sum_{t=1}^{14} \ DX_t \\ Subsequent \ ADX = \frac{1}{14} ((13ADX_{t-1}) + DX_t) \end{array} \right\}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

2) **Aroon** เป็นตัวบ่งชี้ทางเทคนิคแบบ range bound ซึ่งคือ ชุดของสองการวัดที่แยกกันที่ถูกออกแบบมาเพื่อวัดจำนวนช่วงเวลาที่ได้ผ่านไป ตั้งแต่ราคามีการทำราคาสูงหรือต่ำในช่วงเวลา n เช่น 14 วัน **Aroon_Up** จะนำจำนวนวันตั้งแต่ราคามีการทำราคาสูงสุด 14 วัน และนำมาคำนวณออกมาเป็นตัวเลขระหว่าง 0 กับ 100 โดย 14 วัน **Aroon_Down** จะทำเหมือนกัน ยกเว้นแต่จะทำการคำนวณตามจำนวนวันตั้งแต่ราคามีการทำราคาต่ำสุด 14 วัน ตัวเลขนี้ถูกออกแบบมาให้วัดความแข็งแกร่งของแนวโน้ม (ถ้ามี) หากตัวเลขยังมีค่าใกล้ 100 แนวโน้มจะยิ่งแข็งแกร่งเท่านั้น Aroon ไม่ได้เป็นเพียงตัวระบุแนวโน้มที่ดีเท่านั้น มันยังเป็นเครื่องมือที่เป็นประโยชน์ในการระบุช่วงเวลาการพักตัวของราคาเช่นกัน ซึ่งมีสูตรดังนี้

$$Aroon_Up = 100 \times \frac{n - n_H}{n}$$

$$Aroon_Down = 100 \times \frac{n - n_L}{n}$$

เมื่อ n คือ จำนวนช่วงระยะเวลา

n_H คือ จำนวนช่วงระยะเวลาที่ผ่านมา ตั้งแต่ราคามีการทำราคาสูงสุดในช่วงระยะเวลา n

n_L คือ จำนวนช่วงระยะเวลาที่ผ่านมา ตั้งแต่ราคามีการทำราคาต่ำสุดในช่วงระยะเวลา n

3) **Average True Range** เป็นค่าเฉลี่ยเคลื่อนที่ของช่วงที่แท้จริง ซึ่งมีสูตรดังนี้

$$TR_t = \text{Max}[|H_t - L_t|, |H_t - C_{t-1}|, |L_t - C_{t-1}|]$$

$$ATR_n = \left(\frac{1}{n}\right) \sum_{t=1}^n TR_t$$

เมื่อ TR_t คือ ช่วงที่แท้จริง

H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_{t-1} คือ ราคาปิด ณ เวลา $t - 1$

n คือ จำนวนช่วงระยะเวลา

4) **Bollinger Bands** เป็นเครื่องมือวิเคราะห์ทางเทคนิคที่มีชื่อเสียง โดยมีความผันผวนเป็นตัวแปรสำคัญในการตัดสินใจซื้อขาย ได้รับการพัฒนาโดย Bollinger (1980) ซึ่งมีสูตรดังนี้

$$TP = \frac{H_t + L_t + C_t}{3}$$

$$MidBand = SMA_n(TP)$$

$$UpperBand = MidBand + F \times \sigma(TP)$$

$$LowerBand = MidBand - F \times \sigma(TP)$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

SMA_n คือ *Simple Moving Average* สำหรับ n ช่วงระยะเวลา

5) Commodity Channel Index เป็นเครื่องมือทางเทคนิคที่ใช้ประเมินทิศทาง และ ความแข็งแกร่งของแนวโน้มราคาในปัจจุบันเทียบกับราคาเฉลี่ยในอดีต เพื่อใช้ดูว่าราคาอยู่ในภาวะขายมากเกินไป (Oversold) หรือ ภาวะซื้อมากเกินไป (Overbought) ซึ่งมีสูตรดังนี้

$$CCI = \frac{Typical Price - MA_n(C_t)}{0.0015 \times Mean Deviation}$$

$$Typical Price = \sum Periods(H_t + L_t + C_t)/3$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

MA_t คือ *Moving Average* สำหรับ t ช่วงระยะเวลา

6) Chaikin Accumulation

$$CLV = \left(\frac{(C_t - L_t) - (H_t - C_t)}{(H_t - L_t)} \right)$$

$$AD_t = AD_{t-1} + CLV \times V_t$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

7) Chaikin Volatility

$$EMAHL_n = EMA_n(H_t - L_t)$$

$$ChaikinVolatility = \frac{(EMAHL_n - EMAHL_{n-k})}{EMAHL_{n-k} \times 100}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

EMA_n คือ *exponential moving average* สำหรับ n ช่วงระยะเวลา

8) Close Location Value

$$CLV = \left(\frac{(C_t - L_t) - (H_t - C_t)}{(H_t - L_t)} \right)$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

9) Chaikin Money Flow

$$CLV = \left(\frac{(C_t - L_t) - (H_t - C_t)}{(H_t - L_t)} \right)$$

$$CMF_t = \frac{\sum_{t-k}^t (CLV \times V)}{\sum_{t-k}^t V}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

10) Chande Momentum Oscillator

ถ้า $C_t > C_{t-1}$ แล้ว $up = C_t - C_{t-1}$ และ $down = 0$

ถ้า $C_t < C_{t-1}$ แล้ว $up = 0$ และ $down = C_{t-1} - C_t$

$$ups_t = \sum_{t-k}^t up$$

$$downs_t = \sum_{t-k}^t down$$

$$CMO = 100 \times \frac{(ups - downs)}{(ups + downs)}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

11) Donchian Channel (Upper) เป็นตัวบ่งชี้ที่เกิดจากแถบบนและล่างรอบแถบกลาง แถบบนคือราคาสูงสุดในช่วงเวลา N ในขณะที่แถบล่างคือราคาต่ำสุดในช่วงเวลา N พื้นที่ระหว่างแถบบนและแถบล่างแสดงถึงช่องดอนเซียน ซึ่งมีสูตรดังนี้

$$Middle Channel = (UC_n + LC_n)/2$$

เมื่อ UC_n คือ ราคาสูงสุด สำหรับ n ช่วงระยะเวลา

LC_n คือ ราคาต่ำสุด สำหรับ n ช่วงระยะเวลา

12) Donchian Channel (Middle) เป็นตัวบ่งชี้ที่เกิดจากแถบบนและล่างรอบแถบกลาง แถบบนคือราคาสูงสุดในช่วงเวลา N ในขณะที่แถบล่างคือราคาต่ำสุดในช่วงเวลา N พื้นที่ระหว่างแถบบนและแถบล่างแสดงถึงช่องดอนเซียน ซึ่งมีสูตรดังนี้

$$Middle Channel = (UC_n + LC_n)/2$$

เมื่อ UC_n คือ ราคาสูงสุด สำหรับ n ช่วงระยะเวลา

LC_n คือ ราคาต่ำสุด สำหรับ n ช่วงระยะเวลา

13) Donchian Channel (Lower) เป็นตัวบ่งชี้ที่เกิดจากแถบบนและล่างรอบแถบกลาง แถบบนคือราคาสูงสุดในช่วงเวลา N ในขณะที่แถบล่างคือราคาต่ำสุดในช่วงเวลา N พื้นที่ระหว่างแถบบนและแถบล่างแสดงถึงช่องดอนเซียน ซึ่งมีสูตรดังนี้

$$Middle Channel = (UC_n + LC_n)/2$$

เมื่อ UC_n คือ ราคาสูงสุด สำหรับ n ช่วงระยะเวลา

LC_n คือ ราคาต่ำสุด สำหรับ n ช่วงระยะเวลา

14) Volatility (German and Klass-Yang and Zhang) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและ

คำนวณขึ้นอยู่กับราคาที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\sigma = \sqrt{\frac{N}{n} \sum \left[\left(\log \frac{O_t}{C_{t-1}} \right)^2 + \frac{1}{2} \left(\log \frac{H_t}{L_t} \right)^2 - (2 \times \log 2 - 1) \left(\log \frac{C_t}{O_t} \right)^2 \right]}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

O_t คือ ราคาเปิด ณ เวลา t

15) Arms' Ease of Movement Value

$$MidpointMove = \left(\frac{H_t - L_t}{2} \right) - \left(\frac{H_{t-1} - L_{t-1}}{2} \right)$$

$$BoxRatio = \frac{V_t \div 10000}{H_t - L_t}$$

$$EMV = \frac{MidpointMove}{BoxRatio}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

16) Guppy Multiple Moving Averages เป็นตัวบ่งชี้ที่ส่งสัญญาณแนวโน้มการเปลี่ยนแปลงเมื่อกลุ่มสั้นและยาวของค่าเฉลี่ยเคลื่อนที่ตัดกัน มีแนวโน้มขึ้นเมื่อมีค่าเฉลี่ยเคลื่อนที่ระยะสั้นมากกว่าค่าเฉลี่ยระยะยาว และมีแนวโน้มลงเมื่อมีค่าเฉลี่ยเคลื่อนที่ระยะยาวมากกว่าค่าเฉลี่ยระยะสั้น ซึ่งมีสูตรดังนี้

$$EMA_n = EMA_{n-1}(C_t) + SF_n \times (C_n - EMA_{n-1}(C_t))$$

$$SF_n = \frac{2}{(n + 1)}$$

เมื่อ EMA_0 คำนวณจาก SMA_n

SF_n คือ ค่าของตัวถ่วงน้ำหนัก

C_t คือ ราคาปิด ณ เวลา t

17) Keltner Channels

$$\text{Keltner Channel Middle Line} = EMA_n(C_t)$$

$$\text{Keltner Channel Upper Band} = EMA_n(C_t) + 2 * ATR_n$$

$$\text{Keltner Channel Lower Band} = EMA_n(C_t) - 2 * ATR_n$$

เมื่อ EMA_n คือ *exponential moving average* สำหรับ n ช่วงระยะเวลา

ATR_n คือ *Average True Range* สำหรับ n ช่วงระยะเวลา

18) Know Sure Thing เป็นตัวบ่งชี้บอกแนวโน้มที่ถูกพัฒนาขึ้นมาโดย Martin Pring เพื่อที่จะช่วยในการอ่านค่าการเปลี่ยนแปลงของราคาที่ย่างขึ้น

19) Volatility (German and Klass) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและคำนวณขึ้นอยู่กับการที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังมักเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\sigma = \sqrt{\frac{N}{n} \sum \left[\frac{1}{2} \left(\log \frac{H_t}{L_t} \right)^2 - (2 \times \log 2 - 1) \left(\log \frac{C_t}{O_t} \right)^2 \right]}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

O_t คือ ราคาเปิด ณ เวลา t

20) Moving average convergence divergence (MACD) เป็นตัวบ่งชี้บอกทิศทางแนวโน้มของราคา โดยแสดงถึงความสัมพันธ์ระหว่างค่าเฉลี่ยเคลื่อนที่ 2 ช่วงระยะเวลา ซึ่งมีสูตรดังนี้

$$MACD = EMA_p(C_t) - EMA_q(C_t)$$

เมื่อ EMA_p คือ *exponential moving average* สำหรับ p ช่วงระยะเวลา

EMA_q คือ *exponential moving average* สำหรับ q ช่วงระยะเวลา

21) Money Flow Index

$$\text{TypicalPrice}_t = \frac{H_t + L_t + C_t}{3}$$

$$\text{MoneyFlow}_t = \text{TypicalPrice}_t \times V_t$$

ถ้า $\text{TypicalPrice}_t > \text{TypicalPrice}_{t-1}$

แล้ว $\text{PositiveMoneyFlow}_t = \text{PositiveMoneyFlow}_{t-1} + \text{MoneyFlow}_t$

นอกเหนือจากนั้น $\text{NegativeMoneyFlow}_t = \text{NegativeMoneyFlow}_{t-1} + \text{MoneyFlow}_t$

$$\text{MoneyRatio}_t = \frac{\sum_{t-k}^t \text{PositiveMoneyFlow}}{\sum_{t-k}^t \text{NegativeMoneyFlow}}$$

$$\text{MoneyFlowIndex}_t = 100 - \left(\frac{100}{1 + \text{MoneyRatio}_t} \right)$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

22) On Balance Volume (OBV) เป็นตัวบ่งชี้บอกการเปลี่ยนแปลงปริมาณการซื้อขาย ซึ่งมีสูตรดังนี้

ถ้า $C_t = C_{t-1}$ แล้ว $OBV_t = OBV_{t-1}$

ถ้า $C_t < C_{t-1}$ แล้ว $OBV_t = OBV_{t-1} - V_t$

ถ้า $C_t > C_{t-1}$ แล้ว $OBV_t = OBV_{t-1} + V_t$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

23) Construct volatility bands around prices เป็นฟังก์ชันที่ใช้ค่าเฉลี่ยเคลื่อนที่เพื่อกรองความถี่ที่สูงและสัญญาณรบกวนออก ซึ่งทำให้แถบค่อนข้างเสถียรมากขึ้นต่อความผันผวน เพื่อให้ฟังก์ชันตอบสนองต่อราคาปรับเปลี่ยน

24) Rate of Change คือ ร้อยละของการเปลี่ยนแปลงราคาระหว่างราคาปัจจุบันกับราคาในช่วงเวลาก่อนหน้า ซึ่งมีสูตรดังนี้

$$ROC_t^k = (C_t - C_{t-k})/C_{t-k}$$

เมื่อ ROC_t^k คือ ร้อยละของการเปลี่ยนแปลงราคา ณ เวลา t กับราคาใน k ช่วงระยะเวลาก่อนหน้า

C_t คือ ราคาปิด ณ เวลา t

25) Volatility (Parkinson) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและคำนวณขึ้นอยู่กับราคาที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังมักเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\sigma = \sqrt{\frac{N}{4n \times \log 2} \sum \left[\left(\log \frac{H_t}{L_t} \right)^2 \right]}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

O_t คือ ราคาเปิด ณ เวลา t

26) ดัชนีความแกร่งเชิงสัมพัทธ์ (Relative strength index (RSI)) เป็นดัชนีที่ใช้กันทั่วไปในการวิเคราะห์ทางเทคนิค เนื่องจากใช้งานและตีความง่าย ได้รับการพัฒนาโดย Wilder (1978) ซึ่งมีสูตรดังนี้

$$RSI = 100 - \frac{100}{1 + RS_n}$$

เมื่อ RS_n คือ อัตราส่วนระหว่างค่าเฉลี่ยของอัตราผลตอบแทนที่เป็นบวก (Average gain) กับค่าเฉลี่ยของอัตราผลตอบแทนที่เป็นลบ (Average loss) ย้อนหลัง n ช่วงระยะเวลา

27) Volatility (Rogers and Satchell) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและคำนวณขึ้นอยู่กับราคา

ที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังมักเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\sigma = \sqrt{\frac{N}{n} \sum [\log \frac{H_t}{C_t} \times \log \frac{H_t}{O_t} + \log \frac{L_t}{C_t} \times \log \frac{L_t}{O_t}]}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

O_t คือ ราคาเปิด ณ เวลา t

28) Stochastic oscillator (Stow %D) เป็นตัวบ่งชี้ที่แสดงถึงการเปลี่ยนแปลงทิศทางของราคา ได้รับการพัฒนาโดย Lane (1950) ซึ่งมีสูตรดังนี้

$$SO = 100 \left(\frac{C_t - l_p}{h_p - l_p} \right)$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

h_p คือ ราคาสูงสุดย้อนหลัง p ช่วงระยะเวลา

29) Parabolic Stop-and-Reverse เป็นตัวบ่งชี้ทางเทคนิคบอกแนวโน้ม ซึ่งมีสูตรดังนี้

$$\text{แนวโน้มขาขึ้น } SAR_n = (H_n - SAR_{n-1}) \times af + SAR_{n-1}$$

$$\text{แนวโน้มขาลง } SAR_n = (L_n - SAR_{n-1}) \times af + SAR_{n-1}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

af คือ ค่าของความเร่งของปัจจัยการเปลี่ยนแปลงราคา

30) ค่าเฉลี่ยเคลื่อนที่อย่างง่าย (Simple Moving Average (SMA)) เป็นตัวบ่งชี้ทางเทคนิคบอกแนวโน้มที่ง่ายและเป็นที่ยอมรับมากที่สุดในการวิเคราะห์ทางเทคนิค ซึ่งมีสูตรดังนี้

$$SMA_n = \frac{1}{n} \sum_{t=1}^n C_t$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

31) ค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียล (Exponential moving average (EMA)) โดยมีการใช้ตัวถ่วงน้ำหนัก ซึ่งมีสูตรดังนี้

$$EMA_n = EMA_{n-1}(C_t) + SF_n \times (C_n - EMA_{n-1}(C_t))$$

$$SF_n = \frac{2}{(n + 1)}$$

เมื่อ EMA_0 คำนวณจาก SMA_n

SF_n คือ ค่าของตัวถ่วงน้ำหนัก

C_t คือ ราคาปิด ณ เวลา t

32) Weighted Moving Average (WMA) คือ ค่าเฉลี่ยเคลื่อนที่ที่คำนวณโดยกำหนดน้ำหนักที่สูงขึ้นให้กับราคาปัจจุบัน ซึ่งมีสูตรดังนี้

$$WMA_n = \frac{C_t \times n + C_{t-1} \times (n - 1) + C_{t-2} \times (n - 2) \cdots C_{t-(n-1)} \times 1}{n \times \frac{n + 1}{2}}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

33) Double-exponential moving average

$$DEMA_n(C_t) = 2 \times EMA_n C_t - EMA_n(EMA_n(C_t))$$

เมื่อ EMA_n คือ exponential moving average สำหรับ n ช่วงระยะเวลา

C_t คือ ราคาปิด ณ เวลา t

34) Elastic, volume-weighted moving average เป็นตัวบ่งชี้ที่ใช้ค่าเฉลี่ยเคลื่อนที่ (MA) และปริมาณซื้อขาย (Volume) มาวิเคราะห์ โดยการวิเคราะห์จะมีลักษณะคล้ายการวิเคราะห์ค่าเฉลี่ยเคลื่อนที่ปกติ แต่จะให้น้ำหนักกับจุดที่มีปริมาณซื้อขายจำนวนมากเป็นพิเศษ

35) Zero lag exponential moving average

$$K = \frac{2}{n + 1}$$

$$lag = \frac{n - 1}{2}$$

$$ZLEMA_n(C_t) = K \times (2 \times C_0 - C_{n-lag}) + (1 - K) \times ZLEMA_{n-1}(C_t)$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

36) Volume-weighted moving average เป็นตัวบ่งชี้ที่ใช้ค่าเฉลี่ยเคลื่อนที่ (MA) และปริมาณซื้อขาย (Volume) มาวิเคราะห์ โดยการวิเคราะห์จะมีลักษณะคล้ายการวิเคราะห์ค่าเฉลี่ยเคลื่อนที่ปกติ แต่จะให้น้ำหนักกับจุดที่มีปริมาณซื้อขายจำนวนมากเป็นพิเศษ ซึ่งมีสูตรดังนี้

$$VWMA_n(C_t) = \frac{(C_1 \times V_1) + (C_2 \times V_2) + \dots + (C_n \times V_n)}{V_1 + V_2 + \dots + V_n}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

V_t คือ ปริมาณการซื้อขาย ณ เวลา t

37) Volatility (Yang and Zhang) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและคำนวณขึ้นอยู่กับการซื้อขายที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังมักเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\begin{aligned} \sigma^2 &= \sigma_o^2 + k\sigma_c^2 + (1 - k)\sigma_{rs}^2 \\ \sigma_o^2 &= \frac{N}{n-1} \sum \left(\log \frac{O_t}{C_{t-1}} - \mu_o \right)^2 \\ \mu_o &= \frac{1}{n} \sum \log \frac{O_t}{C_{t-1}} \\ \sigma_c^2 &= \frac{N}{n-1} \sum \left(\log \frac{C_t}{O_t} - \mu_c \right)^2 \\ \mu_c &= \frac{1}{n} \sum \log \frac{C_t}{O_t} \\ \sigma_{rs}^2 &= \frac{N}{n} \sum \left(\log \frac{H_t}{C_t} \times \log \frac{H_t}{O_t} + \log \frac{L_t}{C_t} \times \log \frac{L_t}{O_t} \right) \\ k &= \frac{\alpha - 1}{\alpha + \frac{n+1}{n-1}} \end{aligned}$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

O_t คือ ราคาเปิด ณ เวลา t

38) Stochastic oscillator (Fast %D) เป็นตัวบ่งชี้ที่แสดงถึงการเปลี่ยนแปลงทิศทางของราคา ได้รับการพัฒนาโดย Lane (1950) ซึ่งมีสูตรดังนี้

$$SO = 100 \left(\frac{C_t - l_p}{h_p - l_p} \right)$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

h_p คือ ราคาสูงสุดย้อนหลัง p ช่วงระยะเวลา

l_p คือ ราคาต่ำสุดย้อนหลัง p ช่วงระยะเวลา

39) Hull moving average ได้รับการพัฒนาโดย Alan Hull เพื่อลดความล่าช้าและเพิ่มการตอบสนองในขณะเดียวกันก็ช่วยลดเสียงรบกวน ซึ่งมีสูตรดังนี้

$$HMA_n = WMA \left(\sqrt{2 \times WMA_n \left(C_t \right)} - WMA_n \left(C_t \right) \right)$$

เมื่อ WMA_n คือ *weighted moving average* สำหรับ n ช่วงระยะเวลา

C_t คือ ราคาปิด ณ เวลา t

40) Arnaud Legoux moving average

$$ALMA_n = \frac{C_1 \times W_1 + C_2 \times W_2 + \dots + C_n \times W_n}{W_1 + W_2 + \dots + W_n}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

41) Signal to Noise Ratio

$$SNR_n = \frac{|C_t - C_{t-n}|}{ATR_n}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

ATR_n คือ *average true range* สำหรับ n ช่วงระยะเวลา

42) Stochastic oscillator (Fast %K) เป็นตัวบ่งชี้ที่แสดงถึงการเปลี่ยนแปลงทิศทางของราคา ได้รับการพัฒนาโดย Lane (1950) ซึ่งมีสูตรดังนี้

$$SO = 100 \left(\frac{C_t - l_p}{h_p - l_p} \right)$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

h_p คือ ราคาสูงสุดย้อนหลัง p ช่วงระยะเวลา

l_p คือ ราคาต่ำสุดย้อนหลัง p ช่วงระยะเวลา

43) Trend Detection Index เป็นตัวบ่งชี้ที่บอกแนวโน้มของราคา ได้รับการพัฒนาโดย M.H. Pee ใช้วัดความแข็งแกร่งของแนวโน้มและสร้างสัญญาณการซื้อขาย โดยอยู่บนพื้นฐานของสมมติฐานที่ว่าราคาจะดำเนินต่อไปในทิศทางก่อนหน้าเมื่อแนวโน้มแข็งแกร่ง

44) Triple Smoothed Exponential Oscillator

$$M_n = EMA_n(EMA_n(EMA_n(C_t)))$$

$$TRIX = 100 \times \frac{M_n - M_{n-1}}{M_n}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

EMA_n คือ *exponential moving average* สำหรับ n ช่วงระยะเวลา

45) The Ultimate Oscillator ถูกคิดค้นโดย Larry William ในปี 1976 จะใช้ค่าช่วงระยะเวลาที่แตกต่างกัน 3 ช่วงระยะเวลา (7, 14, 28) เพื่อวิเคราะห์แนวโน้มของกราฟ ซึ่งมีสูตรดังนี้

$$Average_n = \frac{\sum_{t=1}^n C_t - \text{Min}(L_t, C_{t-1})}{\text{Max}(H_t, C_{t-1}) - \text{Min}(L_t, C_{t-1})}$$

$$UO = \left[\frac{(Average_7 \times 4) + (Average_{14} \times 2) + Average_{28}}{4 + 2 + 1} \right] \times 100$$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

46) Vertical Horizontal Filter

$$VHF_n = \frac{h_n - l_n}{\sum_{t=1}^n |C_t - C_{t-1}|}$$

เมื่อ h_n คือ ราคาสูงสุดย้อนหลัง n ช่วงระยะเวลา

L_n คือ ราคาต่ำสุดย้อนหลัง n ช่วงระยะเวลา

C_t คือ ราคาปิด ณ เวลา t

47) Volatility (Close) ตัวบ่งชี้ความผันผวนเป็นเครื่องมือวิเคราะห์ทางเทคนิคที่พิจารณาการเปลี่ยนแปลงของราคาในช่วงเวลาที่กำหนด การเปลี่ยนแปลงราคาที่เร็วขึ้นความผันผวนมากขึ้น การเปลี่ยนแปลงราคาที่ช้าลงทำให้ความผันผวนลดลง สามารถวัดและคำนวณขึ้นอยู่กับราคาที่ผ่านมาและสามารถใช้สำหรับการระบุแนวโน้ม นอกจากนี้ยังมักเป็นสัญญาณว่าตลาดมีการซื้อหรือขายมากเกินไป ซึ่งมีสูตรดังนี้

$$\sigma = \sqrt{\frac{N}{n-2} \sum_{t=1}^{n-1} (r_t - \bar{r})^2}$$

$$r_t = \log\left(\frac{C_t}{C_{t-1}}\right)$$

$$\bar{r} = \frac{r_1 + r_2 + \dots + r_{n-1}}{n-1}$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

48) Williams Accumulation

ถ้า $C_t > C_{t-1}$ แล้ว $AD_t = AD_{t-1} + (C_t - \min(L_t, C_{t-1}))$

ถ้า $C_t < C_{t-1}$ แล้ว $AD_t = AD_{t-1} + (\max(H_t, C_{t-1}) - C_t)$

ถ้า $C_t = C_{t-1}$ แล้ว $AD_t = AD_{t-1}$

เมื่อ H_t คือ ราคาสูงสุด ณ เวลา t

L_t คือ ราคาต่ำสุด ณ เวลา t

C_t คือ ราคาปิด ณ เวลา t

49) William's %R เป็นตัวบ่งชี้ที่แสดงถึงการเปลี่ยนแปลงทิศทางของราคา โดยแสดงความสัมพันธ์ระหว่างราคาปัจจุบันกับราคาต่ำสุด และราคาสูงสุด ซึ่งมีสูตรดังนี้

$$\%R = \left(\frac{C_t - l_p}{h_p - l_p}\right)(-100)$$

เมื่อ C_t คือ ราคาปิด ณ เวลา t

h_p คือ ราคาสูงสุดย้อนหลัง p ช่วงระยะเวลา

l_p คือ ราคาต่ำสุดย้อนหลัง p ช่วงระยะเวลา

50) Zig Zag เป็นตัวบ่งชี้ที่ช่วยระบุจุดต่ำสุดหรือสูงสุดของราคาในแต่ละสวิงที่ผ่านมา (High, Low) โดยกรองความผันผวนของสวิงย่อย ๆ ออก ทำให้สามารถมองเห็นแต่ละสวิงเมื่อขยายกราฟ ออกมาพิจารณาในภาพใหญ่ได้ง่ายขึ้น

3.3 ตัวแบบ (Models)

งานวิจัยนี้เราจะศึกษาโดยใช้ตัวแบบ 3 ประเภท คือ ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ซึ่งมีรายละเอียดดังต่อไปนี้

1) ตัวแบบป่าสุ่ม (Random Forest (RF))

ตัวแบบป่าสุ่ม (Random Forest (RF)) เป็นเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ที่สร้างตัวแบบด้วยวิธีการ Decision Tree ขึ้นมาหลายๆตัวแบบโดยวิธีการสุ่มตัวแปร จากนั้นนำผลแต่ละตัวแบบมารวมกันพร้อมนับจำนวนผลที่จำนวนซ้ำกันมากที่สุดออกมาเป็นผลลัพธ์สุดท้าย

วิธีการ Decision Tree เป็นเทคนิคที่ให้ผลลัพธ์ในลักษณะโครงสร้างของต้นไม้ ภายในต้นไม้ประกอบด้วย โหนด (node) ซึ่งแต่ละโหนดจะมีเงื่อนไขของคุณลักษณะที่ทดสอบ กิ่ง (branch) แสดงค่าที่เป็นไปได้ของคุณลักษณะที่ถูกเลือกทดสอบ และใบ (leaf) แสดงกลุ่มของข้อมูล (class) ซึ่งเป็นผลลัพธ์ที่ได้จากการทำนาย โดยสามารถสรุปเป็นขั้นตอนได้ดังต่อไปนี้

1. ทำการสุ่มเลือก feature และ data จากชุดข้อมูลทั้งหมดที่มี
2. สร้างต้นไม้ตัดสินใจจากชุดข้อมูลตัวอย่างแต่ละชุด และหาค่าพยากรณ์จากต้นไม้แต่ละต้น
3. เลือกจำนวนต้นไม้ตัดสินใจที่ต้องการ จากนั้นทำซ้ำในขั้นตอน 1 และ 2 ในการสร้างต้นไม้
4. หาค่าพยากรณ์ โดยค่าพยากรณ์ที่ได้จะเป็นการให้ต้นไม้ตัดสินใจแต่ละต้นหาค่าพยากรณ์ของใครของมันจากนั้นค่าพยากรณ์สุดท้าย ในกรณีที่ปัญหาเป็นเพื่อการจำแนก (Classification) จะใช้วิธีผลโหวตมากที่สุด (Majority vote) โดยค่าพยากรณ์ของต้นไม้ตัดสินใจต้นที่ได้รับค่าผลโหวตมากที่สุด จะถูกเลือกให้เป็นค่าพยากรณ์ของปัญหา

2) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR))

ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) เป็นตัวแบบการจำแนกประเภทที่ใช้กันอย่างแพร่หลาย ซึ่งถือได้ว่าเป็นโครงข่ายประสาทเทียมชั้นเดียว (Single layer neural network) ที่มีตัวแปรตอบสนองแบบไบนารี (binary) การวิเคราะห์การถดถอยโลจิสติกเป็นการประมาณค่าความน่าจะเป็นของการเกิดเหตุการณ์ มีตัวแบบมาจากฟังก์ชันโลจิสติก กรณีตัวแปรอิสระเพียงตัวเดียวฟังก์ชันโลจิสติกจะแสดงความน่าจะเป็นของเหตุการณ์ที่มีรูปดังต่อไปนี้

$$Prob(event) = \frac{e^{(\beta_0 + \beta_1 X)}}{1 + e^{(\beta_0 + \beta_1 X)}}$$

เมื่อ β_0 คือ ค่าคงที่

β_1 คือ ค่าสัมประสิทธิ์ของตัวแปรอิสระ

X คือ ตัวแปรอิสระ

e คือ ลอการิทึมธรรมชาติ

ในกรณีที่มีตัวแปรทำนายหลายตัว (n) ฟังก์ชันโลจิสติกจะแสดงในรูปดังนี้

$$Prob(event) = \frac{e^Z}{1 + e^Z}$$

เมื่อ Z คือ Linear Combination ที่อยู่ในรูป

$$Z = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n$$

และความน่าจะเป็นของการไม่เกิดเหตุการณ์จะประมาณได้จากสมการ

$$Prob(no event) = 1 - Prob(event)$$

การสร้างตัวแบบหรือสมการถดถอยโลจิสติก กระทำโดยการประมาณค่าสัมประสิทธิ์จากชุดสังเกตที่เก็บวัดมาได้ โดยใช้วิธีการประมาณความน่าจะเป็นสูงสุด (Maximum Likelihood Estimation)

ปัจจุบันซอฟต์แวร์การคำนวณทางวิทยาศาสตร์ส่วนใหญ่มีแพ็คเกจที่ได้รับการพัฒนาอย่างดีสำหรับการถดถอยโลจิสติกและอัลกอริธึมการจำแนกประเภทการเรียนรู้ของเครื่อง (Machine Learning) อื่นๆด้วย ข้อได้เปรียบหลักของการถดถอยโลจิสติกเกิดจากการเทียบเคียงและความเร็วในการนำไปใช้ เนื่องจากจำนวนพารามิเตอร์ที่จะประมาณได้น้อยกว่าจึงมีแนวโน้มที่จะเกิดปัญหาการใส่มากเกินไปเมื่อเทียบกับโครงข่ายประสาทเทียม (Akyildirim et al., 2020)

3) ตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification

การเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification เป็นตัวแบบการเรียนรู้แบบกลุ่ม โดยรวมตัวจำแนกข้อมูลการทำนายที่แตกต่างมากกว่า 1 ประเภทมารวมกันไว้ มีขั้นตอนการทำนายมากกว่า 1 ชั้น และมีการใช้ K-Fold Cross Validation เพื่อสร้างการรวมการถ่วงน้ำหนักที่ดีที่สุดของการทำนาย

ในงานวิจัยนี้ใช้ตัวแบบการเรียนรู้ด้วยเทคนิค Stacking โดยใช้ตัวจำแนกข้อมูล คือความน่าจะเป็นจากการทำนายของตัวแบบป่าสุ่ม (Random Forest (RF)) และความน่าจะเป็นจากการทำนายของตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) ซึ่งเป็นการนำความน่าจะเป็นจากการทำนายที่ได้ในแต่ละตัวแบบมาสร้างข้อมูล input แล้วส่งต่อผลลัพธ์ให้ตัวจำแนกตัวต่อไปเรียนรู้ และมีการใช้ K-Fold Cross Validation ซึ่งจะสร้างตัวแบบการเรียนรู้ด้วยเทคนิค Stacking ในรูปแบบของสมการถดถอยโลจิสติก โดยสามารถเขียนได้ดังสมการต่อไปนี้

$$y^* = \frac{e^{(\beta_0 + \beta_1 y_1^* + \beta_2 y_2^*)}}{1 + e^{(\beta_0 + \beta_1 y_1^* + \beta_2 y_2^*)}}$$

เมื่อ β_0 คือ ค่าคงที่

β_1, β_2 คือ ค่าสัมประสิทธิ์ของตัวแปรอิสระ

y_1^* คือ ความน่าจะเป็นจากการทำนายของตัวแบบป่าสุ่ม

y_2^* คือ ความน่าจะเป็นจากการทำนายของตัวแบบการถดถอยโลจิสติก

3.4 การกำหนดตัวแปรสำหรับตัวแบบ

สำหรับการทำนายการซื้อขายสกุลเงินดิจิทัลที่โดยเปรียบเทียบวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สำหรับข้อมูลความถี่ 1 วัน และ 1 สัปดาห์ และใช้ตัวบ่งชี้ 50 ตัวบ่งชี้ เรากำหนดให้ตัวแปรตามเป็นการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัล และตัวแปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator) โดยสามารถเขียนได้ดังต่อไปนี้

กำหนดให้ Y แทน ตัวแปรตาม โดย $Y = \begin{cases} 1 & \text{เมื่อ ราคาสูงขึ้นในช่วงเวลาถัดไป} \\ 0 & \text{เมื่อ ราคาต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไป} \end{cases}$

X แทน ตัวแปรอิสระ โดย X_i เป็นค่าของตัวบ่งชี้แต่ละตัวจากทั้งหมด 50 ตัวบ่งชี้

3.5 การคัดเลือกคุณสมบัติ (Feature Selection)

การคัดเลือกคุณสมบัติเป็นเทคนิคที่ช่วยลดจำนวนตัวแปรที่จะใช้ในตัวแบบ อาจทำเพื่อเลือกตัวแปรที่ดีที่สุดเพียงตัวเดียว หรือเลือกกลุ่มของตัวแปรที่มีความสำคัญต่อการทำนาย กระบวนการคัดเลือกคุณสมบัติเป็นกระบวนการที่สำคัญเพื่อให้การสร้างตัวแบบทำนายมีประสิทธิภาพและเร็วขึ้น

1) วิธีการถดถอยแบบบริดจ์ (Ridge regression) Hoerl, Kennard (1970) ได้เสนอวิธีการถดถอยแบบบริดจ์ขึ้นมา ซึ่งวิธีการดังกล่าวเป็นอีกหนึ่งวิธีที่นิยมใช้เพื่อแก้ไขปัญหาความสัมพันธ์เชิงเส้นพหุโดยจะเป็นการปรับค่าสัมประสิทธิ์การถดถอยให้เข้าสู่ศูนย์แต่ไม่เท่ากับศูนย์ ดังนั้นตัวประมาณทุกตัวที่ได้จะมีขนาดเล็ก และตัวประมาณที่ได้จะมีความเสถียรในความถูกต้องของการทำนาย แต่วิธีการถดถอยแบบบริดจ์ยังขาดคุณสมบัติการคัดเลือกตัวแปรเข้าสู่ตัวแบบ ซึ่งส่งผลทำให้ยากต่อการอธิบายผลลัพธ์

2) วิธีการถดถอยลาสโซ่ (Lasso regression) Tibshirani (1996) ได้นำเสนอวิธีการถดถอยลาสโซ่ขึ้นมา โดยวิธีการถดถอยดังกล่าวมีคุณสมบัติที่เป็นได้ทั้งการประมาณค่าสัมประสิทธิ์การถดถอยและการคัดเลือกตัวแปรเข้าสู่ตัวแบบได้ในคราวเดียวกัน นั่นคือตัวประมาณที่ได้จากวิธีการถดถอยลาสโซ่ส่วนใหญ่จะมีค่าเท่ากับศูนย์และบางส่วนที่ไม่เท่ากับศูนย์ แต่วิธีการถดถอยลาสโซ่นั้นยังมีข้อจำกัดในการคัดเลือกตัวแปรอิสระบางประการ นั่นคือ วิธีดังกล่าวสามารถคัดเลือกตัวแปรอิสระเข้าสู่ตัวแบบได้สูงสุดเท่ากับขนาดตัวอย่าง และในกรณีที่เกิดปัญหาความสัมพันธ์เชิงเส้นพหุ วิธีดังกล่าวจะมีแนวโน้มที่จะคัดเลือกตัวแปรอิสระเข้าสู่ตัวแบบเพียงแค่ตัวเดียวจากกลุ่มตัวแปรอิสระที่มีความสัมพันธ์เชิงเส้นต่อกัน

3) วิธีการถดถอยอีลาสติคเน็ต (Elastic Net regression) Zou, Hastie (2005) ได้นำเสนอวิธีการถดถอยอีลาสติคเน็ตขึ้นมา โดยที่วิธีดังกล่าวมีคุณสมบัติเช่นเดียวกับวิธีการถดถอยลาสโซ่ นั่นคือ สามารถประมาณค่าสัมประสิทธิ์การถดถอยและคัดเลือกตัวแปรอิสระเข้าสู่ตัวแบบได้ในคราวเดียวกัน ซึ่งวิธีการถดถอยอีลาสติคเน็ตเป็นการรวมกันระหว่างวิธีการถดถอยแบบบริดจ์และวิธีการถดถอยลาสโซ่ อีกทั้งวิธีนี้ยังเหมาะสมสำหรับการวิเคราะห์ในกรณีที่ตัวแปรอิสระมีความสัมพันธ์เชิงเส้นกันสูง และเหมาะสำหรับการวิเคราะห์ที่มีจำนวนตัวแปรอิสระมากกว่าขนาดตัวอย่างมาก ๆ

จากการศึกษาเราจะใช้การคัดเลือกคุณสมบัติด้วยวิธีการถดถอยอีลาสติคเน็ต (Elastic Net regression) ซึ่งเป็นวิธีที่เหมาะสมสำหรับการวิเคราะห์ในกรณีที่ตัวแปรอิสระมีความสัมพันธ์เชิงเส้นกันสูง และเหมาะสำหรับการวิเคราะห์ที่มีจำนวนตัวแปรอิสระมากกว่าขนาดตัวอย่างมาก ๆ

3.6 การปรับแต่งค่าไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning)

Hyperparameter คือ พารามิเตอร์ต่างๆที่ผู้ใช้สามารถกำหนดเองได้ก่อนที่ตัวแบบจะทำการเรียนรู้ ซึ่งจะควบคุมโครงสร้างตัวแบบ ฟังก์ชันรวมถึงประสิทธิภาพโดยตรง การปรับ Hyperparameter จะช่วยให้ข้อมูลสามารถปรับแต่งประสิทธิภาพของตัวแบบเพื่อให้ได้ผลลัพธ์ที่ดีที่สุดได้ กระบวนการนี้เป็นส่วนสำคัญของการเรียนรู้ของเครื่อง (Machine Learning) และการเลือกค่า Hyperparameter ที่เหมาะสมถือเป็นสิ่งสำคัญที่จะทำให้ประสบความสำเร็จ โดยวิธีการค้นหาไฮเปอร์พารามิเตอร์ มี 3 วิธี ได้แก่

1) Manual Search เป็นเทคนิคที่เราจะเลือกค่า Hyperparameter ของตัวแบบจากประสบการณ์และความคิดเห็นส่วนบุคคล โดยจะทำการสร้างตัวแบบขึ้นมาจากค่าที่เลือกและวัดความแม่นยำไปเรื่อย ๆ จนกว่าจะได้ค่าความแม่นยำที่พึงพอใจ

2) Grid Search หรือการค้นหาแบบกริด เป็นเทคนิคที่ใช้ในการหาค่า Hyperparameter ที่เข้าใจง่ายและตรงไปตรงมา ด้วยการลองใช้พารามิเตอร์ที่กำหนดไว้ล่วงหน้าทุกชุด และประเมินประสิทธิภาพหรือความแม่นยำของตัวแบบแต่ละชุด จะเป็นการลองสร้างตัวแบบจากค่าของ Hyperparameter ทุกชุด รูปแบบของการทำงานจะคล้ายกริด โดยค่าทั้งหมดจะอยู่ในรูปของเมทริกซ์ (Matrix) พารามิเตอร์แต่ละชุดจะถูกนำมาพิจารณาและสังเกตความถูกต้อง เมื่อชุดของ Hyperparameter ทั้งหมดได้รับการประเมินแล้ว ตัวแบบที่มีชุดพารามิเตอร์ที่ให้ความแม่นยำสูงสุดจะถือว่าดีที่สุด

3) Random Search วิธีการทำงานของ Random Search คล้ายคลึงกับการทำ Grid Search แต่แทนที่จะลองใช้พารามิเตอร์ที่กำหนดไว้ล่วงหน้าในกริดทุกชุด Random Search จะทำการสุ่มเลือกค่าพารามิเตอร์จากกริดที่สร้างขึ้น ดังนั้นการทำ Random Search จะไม่รับประกันว่าเราจะได้ตัวแบบที่มีประสิทธิภาพที่สุดเหมือนกับ Grid Search แต่วิธีนี้มีประสิทธิภาพสูงในการใช้งานจริงเนื่องจากใช้เวลาในการสร้างโมเดลที่น้อยมาก

จากการศึกษาเราจะใช้การปรับแต่งค่าไฮเปอร์พารามิเตอร์ด้วยวิธี Grid Search เพื่อที่จะให้ได้ตัวแบบที่มีชุดพารามิเตอร์ที่ให้ความแม่นยำสูงสุด แต่อาจจะใช้วิธี Random Search หากใช้เวลามากเกินไป

สำหรับ Grid Search เราจะเพิ่มการทำ Cross-Validation สำหรับการสร้างตัวแบบเข้าไปด้วย ซึ่งโดยทั่วไปแล้วขั้นตอนในการสร้างตัวแบบการเรียนรู้ของเครื่อง (Machine Learning) เราจะแบ่งข้อมูลออกเป็น 2 ส่วน ได้แก่ ข้อมูลสำหรับสร้างตัวแบบ (Training Data) และข้อมูลสำหรับทดสอบตัวแบบ (Test Data) เพื่อที่จะทดสอบประสิทธิภาพของตัวแบบกับชุดข้อมูลที่ไม่เคยเห็นมา

ก่อน สำหรับการทำให้ Cross-Validation นั้นเราเป็นการแบ่งข้อมูลของ Training Data ออกเป็น N ส่วนเพื่อป้องกันการเกิด Overfit ของโมเดล ซึ่ง 1 ในวิธีที่ใช้กันมากที่สุดคือ K-Fold Validation

K-Fold Validation จะแบ่งข้อมูล Training Data ออกเป็น N ส่วน จากนั้นจะสร้างตัวแบบด้วย N-1 ส่วน และทดสอบตัวแบบกับส่วนที่เหลือ ในการวนซ้ำแต่ละครั้งเราจะเปลี่ยนส่วนของที่ใช้ในการทดสอบตัวแบบ เมื่อเราสร้างตัวแบบครบ N ครั้ง อัลกอริทึมจะทำการหาค่าเฉลี่ยของผลของการสร้างตัวแบบ เพื่อให้ได้ผลลัพธ์ที่มีประสิทธิภาพที่สุด การใช้ Cross-Validation สำคัญมากต่อการทำ Hyperparameter Optimization เนื่องจากเราสามารถหลีกเลี่ยงการใช้ Hyperparameter บางตัวซึ่งทำงานได้ดีกับ Training Data แต่ไม่ส่งผลดีต่อ Test Data

3.7 การวัดประสิทธิภาพของตัวแบบ (Model Evaluation)

จากการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลที่โดยเปรียบเทียบวิธีการใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สำหรับข้อมูลความถี่ 1 วัน และ 1 สัปดาห์ และใช้ตัวบ่งชี้ทางเทคนิค (Technical indicator) 50 ตัวบ่งชี้ เราควรที่จะต้องมีการทดสอบการทำนายของแบบจำลองว่าให้ความถูกต้องเพียงใด โดยใช้ข้อมูลการสำรวจเหตุการณ์จริงจำนวนหนึ่งมาเปรียบเทียบกับสิ่งที่ตัวแบบทำนายได้ ตัวแบบที่มีตัวแปรอิสระที่เราจัดกลุ่มไม่ว่าจะเป็นลำดับหรือไม่ก็ตามมักจะมีผลต่อประสิทธิภาพของสมการในการทำนายเหตุการณ์ ในทำนองเดียวกันจุดที่เรากำหนดเป็นค่าเกณฑ์หรือค่าที่ตัดเหตุการณ์ (cut off) บางครั้งสามารถส่งผลให้การทำนายเหตุการณ์ที่เกิดขึ้นได้ถูกต้องซึ่งถือว่าผลการทำนายออกมาเป็นบวก (หรือเชิงบวก) แต่บางครั้งก็มีผลการทำนายเป็นลบได้ในทำนองเดียวกันกรณีที่ไม่มีเหตุการณ์นั้นเกิดขึ้นจริงผลการทำนายของตัวแบบก็อาจให้ผลเป็นบวกหรือเป็นลบก็ได้เช่นกัน ดังนั้นในการทดสอบ จึงมีตัวสถิติหลายตัวที่ใช้อธิบายประสิทธิภาพของแบบจำลอง โดยต้องนำข้อมูลผลการทดสอบมาสร้าง Confusion Matrix เพื่อการประเมินดังรูปต่อไปนี้

		ค่าอ้างอิง (เป็นจริง)		รวม
		ราคาสูงขึ้น	ราคาต่ำลงหรือเท่าเดิม	
ผลการทำนายจากตัวแบบ	ราคาสูงขึ้น	True Positive (TP)	False Positive (FP)	TP+FP
	ราคาต่ำลงหรือเท่าเดิม	False Negative (FN)	True Negative (TN)	FN+TN
รวม		TP+FN	FP+TN	TP+FP+FN+TN

โดยสามารถหาค่าจากเมตริกสามารถนำมาคำนวณหาค่าความไว (sensitivity) ความจำเพาะ (specificity) ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) ค่าสถิติ F1 score ค่าทำนายเป็นบวก (Positive Predictive Value) ค่าทำนายเป็นลบ (Negative Predictive Value) อัตราส่วนความน่าจะเป็นเชิงบวก (Positive Likelihood Ratio) และอัตราส่วนความน่าจะเป็นเชิงลบ (Negative Likelihood Ratio) ได้ดังสูตรต่อไปนี้

$$\text{Sensitivity} = \text{TP}/(\text{TP}+\text{FN})$$

$$\text{Specificity} = \text{TN}/(\text{FP}+\text{TN})$$

$$\text{Accuracy} = (\text{TP}+\text{TN})/(\text{TP}+\text{FP}+\text{FN}+\text{TN})$$

$$\text{Precision} = \text{TP}/(\text{TP}+\text{FP})$$

$$\text{Recall} = \text{TP}/(\text{TP}+\text{FN})$$

$$\text{F1 score} = 2 * [(\text{Precision} * \text{Recall}) / (\text{Precision} + \text{Recall})]$$

$$\text{Positive Predictive Value} = \text{TP}/(\text{TP}+\text{FP})$$

$$\text{Negative Predictive Value} = \text{TN}/(\text{FN}+\text{TN})$$

$$\text{Positive Likelihood Ratio} = \text{Sensitivity}/(1 - \text{Specificity})$$

$$\text{Negative Likelihood Ratio} = (1-\text{Sensitivity})/\text{Specificity}$$

เมื่อ Sensitivity คือ ความน่าจะเป็นที่ผลการทำนายจะเป็นบวกเมื่อเหตุการณ์ที่สนใจนั้นเกิดขึ้นจริง (TP แสดงเป็นเปอร์เซ็นต์)

Specificity คือ ความน่าจะเป็นที่ผลการทำนายจะเป็นลบเมื่อเหตุการณ์ที่สนใจนั้นไม่เกิดขึ้น (TN แสดงเป็นเปอร์เซ็นต์)

Positive Predictive Value คือ ความน่าจะเป็นที่เกิดเหตุการณ์ที่สนใจเมื่อผลทดสอบออกมาเป็นบวก (แสดงเป็นเปอร์เซ็นต์)

Negative Predictive Value คือ ความน่าจะเป็นที่ไม่เกิดเหตุการณ์ที่สนใจเมื่อผลทดสอบออกมาเป็นลบ (แสดงเป็นเปอร์เซ็นต์)

Positive Likelihood Ratio คือ อัตราส่วนระหว่างความน่าจะเป็นของผลการทดสอบที่เป็นบวกเมื่อเกิดเหตุการณ์ที่สนใจ กับ ความน่าจะเป็นของผลการทดสอบที่เป็นบวกเมื่อไม่เกิดเหตุการณ์ที่สนใจ

Negative Likelihood Ratio คือ อัตราส่วนระหว่างความน่าจะเป็นของผลการทดสอบที่เป็นลบเมื่อเกิดเหตุการณ์ที่สนใจ กับ ความน่าจะเป็นของผลการทดสอบที่เป็นลบเมื่อไม่เกิดเหตุการณ์ที่สนใจ

ซึ่งในการวัดประสิทธิภาพของตัวแบบเราจะเลือกข้อมูลชุดสอน (Training Set) และข้อมูลชุดทดสอบ (Testing Set) โดยใช้การเลือกสุ่มข้อมูลแบบความเที่ยงตรง K กลุ่ม (K-Fold Cross Validation) โดยจะเลือกสุ่มข้อมูลออกเป็น K ชุดเท่ากัน ในการทดลองครั้งแรกข้อมูลชุดที่ 1 เป็นข้อมูลทดสอบ และข้อมูลที่เหลือเป็นข้อมูลชุดสอน ในการทดลองครั้งที่สองข้อมูลชุดที่ 2 เป็นข้อมูลทดสอบ และข้อมูลที่เหลือเป็นข้อมูลชุดสอน ทำจนกระทั่งข้อมูลทุกชุดได้ถูกนำมาเป็นข้อมูลชุดทดสอบ ซึ่งมีการทดลองทั้งหมด K ครั้ง

การวัดประสิทธิภาพของแบบจำลองโดยใช้การสร้างกราฟ Receiver Operator Characteristics (ROC) จากค่าความไวและค่าความจำเพาะ ROC เป็นตัวประเมินที่ช่วยให้เราสามารถเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองได้ ROC สร้างจากค่าที่มีความถูกต้องเชิงบวก (true positive rate) กับค่าที่ความถูกต้องเชิงลบ (true negative rate) ณ ค่า threshold ที่กำหนด (cut off value) โดย ROC จะมีค่าพื้นที่ใต้เส้นกราฟ (AUC) อยู่ระหว่าง 0-1 ซึ่งหากค่าเข้าใกล้ 1 มากยิ่งดี เพราะบ่งบองถึงตัวแบบนั้นมีประสิทธิภาพ

ซึ่งในงานวิจัยนี้จะวัดประสิทธิภาพของตัวแบบใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) ค่าสถิติ F1 score และค่าพื้นที่ใต้เส้นกราฟ (AUC)

บทที่ 4

ผลการศึกษา

การศึกษานี้มีวัตถุประสงค์เพื่อทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบถดถอยอีลาสติคเน็ต (Elastic Net Regression) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และการวิเคราะห์ทางเทคนิค (Technical Analysis) สำหรับสกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก โดยมีรายละเอียดผลการศึกษาดังนี้

4.1 ผลการวิเคราะห์ข้อมูลเชิงการตรวจสอบ (Exploratory Data Analysis (EDA))

ตารางที่ 4 แสดงค่าสถิติเชิงพรรณนา (Descriptive Statistics) ข้อมูลสำหรับการสอน (Training set)

สกุลเงินดิจิทัล	Training set					
	ค่าต่ำสุด	ค่าสูงสุด	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ความเบ้ (Skewness)	ความโด่ง (Kurtosis)
Bitcoin (BTC)	364.3310	63,501.4580	9,717.3590	12,617.2649	2.5312	6.0923
Ethereum (ETH)	0.9371	4,168.7010	406.2244	606.0222	2.9177	9.4460
Binance Coin (BNB)	0.0999	675.6841	51.1761	114.4384	3.4387	11.5460
Ripple (XRP)	0.0051	3.3778	0.3319	0.3648	2.9214	13.6151
Cardano (ADA)	0.0185	2.3091	0.2511	0.4033	2.4385	5.0943
Dogecoin (DOGE)	0.0001	0.6848	0.0181	0.0717	5.4086	31.1522
TRON (TRX)	0.0014	0.2206	0.0324	0.0275	2.5176	8.1866
Polygon (MATIC)	0.0031	2.4544	0.1542	0.3846	3.2850	10.4285
Litecoin (LTC)	2.9968	386.4508	69.8859	67.7494	1.5675	2.5486
Wrapped Bitcoin (WBTC)	3,395.9790	63,436.5800	16,594.7769	15,787.4432	1.5906	1.1553
UNUS SED LEO (LEO)	0.8162	3.8905	1.3781	0.5154	1.7766	3.2828

ตารางที่ 5 แสดงค่าสถิติเชิงพรรณนา (Descriptive Statistics) ชุดข้อมูลสำหรับทดสอบ (Test set)

สกุลเงินดิจิทัล	Test set					
	ค่าต่ำสุด	ค่าสูงสุด	ค่าเฉลี่ย	ส่วนเบี่ยงเบนมาตรฐาน	ความเบ้ (Skewness)	ความโด่ง (Kurtosis)
Bitcoin (BTC)	19,017.6420	67,556.8300	42,955.0357	10,594.4322	0.0785	-0.0987
Ethereum (ETH)	993.6368	4,812.0876	3,028.5527	880.8382	-0.1933	-0.4118
Binance Coin (BNB)	197.0430	654.3150	414.1944	102.6236	0.2797	-0.3295
Ripple (XRP)	0.3081	1.3894	0.8040	0.2560	-0.0680	-0.7006
Cardano (ADA)	0.4555	2.9682	1.3774	0.6447	0.5779	-0.5612
Dogecoin (DOGE)	0.0530	0.3414	0.1772	0.0669	0.1838	-0.7643
TRON (TRX)	0.0506	0.1236	0.0776	0.0169	0.5336	-0.8215
Polygon (MATIC)	0.3467	2.8768	1.4204	0.5215	0.0997	-0.2007
Litecoin (LTC)	43.3003	278.0075	136.9404	47.7140	0.1809	-0.1955
Wrapped Bitcoin (WBTC)	19,028.4360	67,549.2280	42,908.7491	10,552.0281	0.0732	-0.0747
UNUS SED LEO (LEO)	2.3511	7.5010	4.1701	1.2643	0.4069	-1.4487

จากตารางแสดงค่าสถิติเชิงพรรณนา (Descriptive Statistics) ข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ความเบ้ (Skewness) ของข้อมูลสำหรับการสอน (Training set) อยู่ระหว่าง 1.5675 ถึง 5.4086 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงแบบเบ้ขวาค่อนข้างมาก ซึ่งแตกต่างจากความเบ้ (Skewness) ชุดข้อมูลสำหรับทดสอบ (Test set) ที่อยู่ระหว่าง -0.1933 ถึง 0.5779 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงแบบเบ้ขวาเล็กน้อยและมี 2 สกุลเงินดิจิทัลที่ข้อมูลมีการแจกแจงแบบเบ้ขวาลittle และเมื่อพิจารณาความโด่ง (Kurtosis) พบว่า ความโด่ง (Kurtosis) ของข้อมูลสำหรับการสอน (Training set) อยู่ระหว่าง 1.1553 ถึง 31.1522 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงที่มีความโด่งสูงกว่าความโด่งของการแจกแจงปกติ ซึ่งแตกต่างจากความโด่ง (Kurtosis) ชุดข้อมูลสำหรับทดสอบ (Test set) ที่อยู่ระหว่าง -0.07475 ถึง -1.4487 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงที่มีความโด่งต่ำกว่าความโด่งของการแจกแจงปกติ โดยภาพรวมจะเห็นว่าข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับ

ทดสอบ (Test set) มีลักษณะข้อมูลที่ค่อนข้างแตกต่างกัน ซึ่งอาจส่งผลต่อการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล

ตารางที่ 6 แสดงร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลชุดข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set)

สกุลเงินดิจิทัล	Training set		Test set	
	ราคาสูงขึ้นในช่วงเวลาถัดไป	ราคาต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไป	ราคาสูงขึ้นในช่วงเวลาถัดไป	ราคาต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไป
Bitcoin (BTC)	55	45	50	50
Ethereum (ETH)	51	49	50	50
Binance Coin (BNB)	52	48	51	49
Ripple (XRP)	47	53	49	51
Cardano (ADA)	51	49	48	52
Dogecoin (DOGE)	49	51	48	52
TRON (TRX)	50	50	56	44
Polygon (MATIC)	51	49	48	52
Litecoin (LTC)	50	50	50	50
Wrapped Bitcoin (WBTC)	54	46	52	48
UNUS SED LEO (LEO)	52	48	55	45

จากตารางร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลชุดข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า สำหรับชุดข้อมูลสำหรับการสอน (Training set) ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 47 ถึงร้อยละ 55 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 45 ถึงร้อยละ 53 และสำหรับชุดข้อมูลสำหรับทดสอบ (Test set) ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 48 ถึงร้อยละ 56 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 44 ถึงร้อยละ 52 ซึ่งโดยภาพรวมอาจจะสรุปได้ว่าข้อมูลที่ศึกษามีความสมดุลของข้อมูล

ตารางที่ 7 แสดงร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลความถี่ 1 วัน และความถี่ 1 สัปดาห์

สกุลเงินดิจิทัล	ความถี่ 1 วัน		ความถี่ 1 สัปดาห์	
	ราคาสูงขึ้นในช่วงเวลาถัดไป	ราคาต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไป	ราคาสูงขึ้นในช่วงเวลาถัดไป	ราคาต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไป
Bitcoin (BTC)	54	46	54	46
Ethereum (ETH)	51	49	54	46
Binance Coin (BNB)	52	48	58	42
Ripple (XRP)	47	53	48	52
Cardano (ADA)	50	50	50	50
Dogecoin (DOGE)	49	51	45	55
TRON (TRX)	51	49	51	49
Polygon (MATIC)	50	50	49	51
Litecoin (LTC)	50	50	53	47
Wrapped Bitcoin (WBTC)	53	47	53	47
UNUS SED LEO (LEO)	53	47	50	50

จากตารางแสดงร้อยละการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัลความถี่ 1 วัน และความถี่ 1 สัปดาห์ พบว่า สำหรับข้อมูลความถี่ 1 วัน ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 47 ถึงร้อยละ 54 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 46 ถึงร้อยละ 53 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 45 ถึงร้อยละ 58 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 42 ถึงร้อยละ 55 ซึ่งโดยภาพรวมอาจจะสรุปได้ว่าข้อมูลที่ศึกษามีความสมดุลของข้อมูล

4.2 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC)

ตารางที่ 8 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) ความถี่ 1 วัน

Bitcoin (BTC) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5607	0.5041
ค่าความแม่นยำ (Precision)	0.5579	0.5041
ค่าความไว (Recall)	0.9907	1.0000
ค่าสถิติ F1 score	0.7131	0.6703
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5206	0.5274
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5589	0.5096
ค่าความแม่นยำ (Precision)	0.5567	0.5070
ค่าความไว (Recall)	0.9962	0.9891
ค่าสถิติ F1 score	0.7143	0.6703
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5405	0.5426
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5598	0.5068
ค่าความแม่นยำ (Precision)	0.5571	0.5055
ค่าความไว (Recall)	0.9970	1.0000
ค่าสถิติ F1 score	0.7148	0.6715
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5225	0.5312

ตารางที่ 9 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) ความถี่ 1 สัปดาห์

Bitcoin (BTC) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5854	0.4423
ค่าความแม่นยำ (Precision)	0.5667	0.4423
ค่าความไว (Recall)	0.9467	1.0000
ค่าสถิติ F1 score	0.7070	0.6133
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5683	0.4693
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5936	0.5000
ค่าความแม่นยำ (Precision)	0.5777	0.4667
ค่าความไว (Recall)	0.9644	0.9130
ค่าสถิติ F1 score	0.7225	0.6176
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5602	0.4678
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6286	0.4615
ค่าความแม่นยำ (Precision)	0.6321	0.4510
ค่าความไว (Recall)	0.8863	1.0000
ค่าสถิติ F1 score	0.7380	0.6216
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5463	0.4828

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5607 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5096 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6286 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5000

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Bitcoin (BTC) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5405 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการ

ถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5426 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5683 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.4828

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 วันให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 สัปดาห์

4.3 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ethereum (ETH)

ตารางที่ 10 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) ความถี่ 1 วัน

Ethereum (ETH) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5184	0.5068
ค่าความแม่นยำ (Precision)	0.5157	0.5042
ค่าความไว (Recall)	1.0000	0.9891
ค่าสถิติ F1 score	0.6803	0.6679
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5192	0.5481
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5252	0.5233
ค่าความแม่นยำ (Precision)	0.5186	0.5127
ค่าความไว (Recall)	0.9889	0.9945
ค่าสถิติ F1 score	0.6804	0.6766
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5541	0.4831
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5322	0.5233
ค่าความแม่นยำ (Precision)	0.5232	0.5127
ค่าความไว (Recall)	0.9872	0.9891
ค่าสถิติ F1 score	0.6839	0.6754
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5595	0.4816

ตารางที่ 11 แสดงผลการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) ความถี่ 1 สัปดาห์

Ethereum (ETH) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.6174	0.4808
ค่าความแม่นยำ (Precision)	0.6028	0.4808
ค่าความไว (Recall)	0.9637	1.0000
ค่าสถิติ F1 score	0.7393	0.6494
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5512	0.5393
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5850	0.6346
ค่าความแม่นยำ (Precision)	0.5758	0.5882
ค่าความไว (Recall)	0.9905	0.8000
ค่าสถิติ F1 score	0.7282	0.6780
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5001	0.6296
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6299	0.5000
ค่าความแม่นยำ (Precision)	0.6130	0.4902
ค่าความไว (Recall)	0.9687	1.0000
ค่าสถิติ F1 score	0.7508	0.6579
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6042	0.4000

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5322 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5233 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6299 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6346

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Ethereum (ETH) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC)

มากที่สุดซึ่งเท่ากับ 0.5595 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5481 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6042 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6296

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.4 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB)

ตารางที่ 12 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) ความถี่ 1 วัน

Binance Coin (BNB) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5217	0.5233
ค่าความแม่นยำ (Precision)	0.5209	0.5182
ค่าความไว (Recall)	1.0000	0.9893
ค่าสถิติ F1 score	0.6846	0.6801
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.4729	0.5557
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5341	0.5233
ค่าความแม่นยำ (Precision)	0.5286	0.5181
ค่าความไว (Recall)	0.9958	0.9947
ค่าสถิติ F1 score	0.6906	0.6813
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5628	0.4801
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5498	0.5178
ค่าความแม่นยำ (Precision)	0.5371	0.5152
ค่าความไว (Recall)	0.9872	1.0000
ค่าสถิติ F1 score	0.6957	0.6800
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5670	0.4521

ตารางที่ 13 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) ความถี่ 1 สัปดาห์

Binance Coin (BNB) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.6519	0.5577
ค่าความแม่นยำ (Precision)	0.6437	0.5208
ค่าความไว (Recall)	0.9611	1.0000
ค่าสถิติ F1 score	0.7703	0.6849
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5540	0.5793
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.7061	0.5577
ค่าความแม่นยำ (Precision)	0.6862	0.5208
ค่าความไว (Recall)	0.9882	1.0000
ค่าสถิติ F1 score	0.8100	0.6849
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5552	0.5763
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6788	0.4808
ค่าความแม่นยำ (Precision)	0.6654	0.4808
ค่าความไว (Recall)	0.9905	1.000
ค่าสถิติ F1 score	0.7960	0.6494
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6036	0.6296

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5498 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5233 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.7061 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5577

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Binance Coin (BNB) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training

set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5670 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5557 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6036 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6296

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.5 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ripple (XRP)

ตารางที่ 14 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Ripple (XRP) ความถี่ 1 วัน

Ripple (XRP) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.4847	0.4877
ค่าความแม่นยำ (Precision)	0.4777	0.4877
ค่าความไว (Recall)	0.9947	1.0000
ค่าสถิติ F1 score	0.6453	0.6556
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5404	0.5714
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.4763	0.5068
ค่าความแม่นยำ (Precision)	0.4739	0.4971
ค่าความไว (Recall)	0.9990	0.9719
ค่าสถิติ F1 score	0.6429	0.6578
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5359	0.5053
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.4886	0.4904
ค่าความแม่นยำ (Precision)	0.4796	0.4890
ค่าความไว (Recall)	0.9778	1.0000
ค่าสถิติ F1 score	0.6436	0.6568
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5324	0.5396

ตารางที่ 15 แสดงผลการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Ripple (XRP) ความถี่ 1 สัปดาห์

Ripple (XRP) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5856	0.4808
ค่าความแม่นยำ (Precision)	0.5599	0.4706
ค่าความไว (Recall)	0.9810	1.0000
ค่าสถิติ F1 score	0.7089	0.6400
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5208	0.5476
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.6021	0.5577
ค่าความแม่นยำ (Precision)	0.5734	0.5106
ค่าความไว (Recall)	0.9264	1.0000
ค่าสถิติ F1 score	0.7083	0.6761
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5542	0.6190
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5754	0.6346
ค่าความแม่นยำ (Precision)	0.5610	0.5610
ค่าความไว (Recall)	0.9526	0.9583
ค่าสถิติ F1 score	0.7062	0.7077
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5005	0.6875

จากการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Ripple (XRP) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.4886 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5068 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6021 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6346

จากการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Ripple (XRP) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5404

และในส่วนของคุณข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5714 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของคุณข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5542 แต่ในส่วนของคุณข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6875

โดยภาพรวมในส่วนของคุณข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของคุณข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.6 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Cardano (ADA)

ตารางที่ 16 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Cardano (ADA) ความถี่ 1 วัน

Cardano (ADA) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5132	0.4795
ค่าความแม่นยำ (Precision)	0.5095	0.4795
ค่าความไว (Recall)	0.9950	1.0000
ค่าสถิติ F1 score	0.6737	0.6481
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5475	0.5217
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5245	0.4959
ค่าความแม่นยำ (Precision)	0.5153	0.4873
ค่าความไว (Recall)	0.9806	0.9886
ค่าสถิติ F1 score	0.6756	0.6528
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5573	0.5078
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5314	0.4822
ค่าความแม่นยำ (Precision)	0.5201	0.4808
ค่าความไว (Recall)	0.9700	1.0000
ค่าสถิติ F1 score	0.6771	0.6494
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5639	0.5197

ตารางที่ 17 แสดงผลการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Cardano (ADA) ความถี่ 1 สัปดาห์

Cardano (ADA) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.6225	0.5192
ค่าความแม่นยำ (Precision)	0.5963	0.4773
ค่าความไว (Recall)	0.9749	0.9130
ค่าสถิติ F1 score	0.7368	0.6269
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5335	0.5772
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.6399	0.4615
ค่าความแม่นยำ (Precision)	0.6099	0.4510
ค่าความไว (Recall)	0.9304	1.0000
ค่าสถิติ F1 score	0.7368	0.6216
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5755	0.5097
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6805	0.4423
ค่าความแม่นยำ (Precision)	0.6854	0.4423
ค่าความไว (Recall)	0.8758	1.0000
ค่าสถิติ F1 score	0.7690	0.6133
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6952	0.5262

จากการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Cardano (ADA) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5314 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.4959 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6805 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5192

จากการศึกษาค่าข้อมูลสกุลเงินดิจิทัล Cardano (ADA) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5639 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่า

สุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5217 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6952 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5772

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.7 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE)

ตารางที่ 18 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) ความถี่ 1 วัน

Dogecoin (DOGE) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.4922	0.4849
ค่าความแม่นยำ (Precision)	0.4904	0.4849
ค่าความไว (Recall)	1.0000	1.0000
ค่าสถิติ F1 score	0.6579	0.6531
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5442	0.5346
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.4935	0.4849
ค่าความแม่นยำ (Precision)	0.4912	0.4849
ค่าความไว (Recall)	0.9969	1.0000
ค่าสถิติ F1 score	0.6581	0.6531
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5416	0.5383
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.4989	0.5068
ค่าความแม่นยำ (Precision)	0.4936	0.4957
ค่าความไว (Recall)	0.9948	0.9661
ค่าสถิติ F1 score	0.6598	0.6552
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5415	0.5827

ตารางที่ 19 แสดงผลการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) ความถี่ 1 สัปดาห์

Dogecoin (DOGE) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5782	0.4615
ค่าความแม่นยำ (Precision)	0.5210	0.4510
ค่าความไว (Recall)	0.9314	1.0000
ค่าสถิติ F1 score	0.6642	0.6216
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6156	0.5682
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5253	0.5577
ค่าความแม่นยำ (Precision)	0.4917	0.5000
ค่าความไว (Recall)	0.9614	0.9565
ค่าสถิติ F1 score	0.6506	0.6567
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5187	0.5382
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5496	0.4808
ค่าความแม่นยำ (Precision)	0.5115	0.4600
ค่าความไว (Recall)	0.9439	1.0000
ค่าสถิติ F1 score	0.6635	0.6301
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5828	0.4783

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.4989 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5068 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5782 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5577

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Dogecoin (DOGE) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่ง

เท่ากับ 0.5442 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5827 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6156 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5682

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.8 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล TRON (TRX)

ตารางที่ 20 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล TRON (TRX) ความถี่ 1 วัน

TRON (TRX) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5217	0.5644
ค่าความแม่นยำ (Precision)	0.5143	0.5608
ค่าความไว (Recall)	0.9960	1.0000
ค่าสถิติ F1 score	0.6777	0.7186
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5361	0.5921
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5377	0.5671
ค่าความแม่นยำ (Precision)	0.5234	0.5627
ค่าความไว (Recall)	0.9831	0.9951
ค่าสถิติ F1 score	0.6331	0.7189
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5580	0.5394
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5210	0.5890
ค่าความแม่นยำ (Precision)	0.5138	0.5759
ค่าความไว (Recall)	0.9912	0.9901
ค่าสถิติ F1 score	0.6768	0.7283
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5715	0.5363

ตารางที่ 21 แสดงผลการศึกษาคือข้อมูลสกุลเงินดิจิทัล TRON (TRX) ความถี่ 1 สัปดาห์

TRON (TRX) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.6157	0.5577
ค่าความแม่นยำ (Precision)	0.5852	0.5577
ค่าความไว (Recall)	0.9450	1.0000
ค่าสถิติ F1 score	0.7154	0.7160
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5220	0.4843
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.6805	0.5962
ค่าความแม่นยำ (Precision)	0.6576	0.5833
ค่าความไว (Recall)	0.8751	0.9655
ค่าสถิติ F1 score	0.7509	0.7273
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5884	0.4753
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6740	0.5577
ค่าความแม่นยำ (Precision)	0.6257	0.5577
ค่าความไว (Recall)	0.9454	1.0000
ค่าสถิติ F1 score	0.7530	0.7160
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6301	0.5007

จากการศึกษาคือข้อมูลสกุลเงินดิจิทัล TRON (TRX) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอีลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5377 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5890 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอีลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6805 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอีลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5962

จากการศึกษาคือข้อมูลสกุลเงินดิจิทัล TRON (TRX) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5715 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่า

สุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5921 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6301 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5007

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.9 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Polygon (MATIC)

ตารางที่ 22 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) ความถี่ 1 วัน

Polygon (MATIC) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5203	0.5151
ค่าความแม่นยำ (Precision)	0.5167	0.4986
ค่าความไว (Recall)	0.9976	0.9830
ค่าสถิติ F1 score	0.6795	0.6616
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.4720	0.5620
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5288	0.5507
ค่าความแม่นยำ (Precision)	0.5205	0.5200
ค่าความไว (Recall)	0.9840	0.8864
ค่าสถิติ F1 score	0.6809	0.6554
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5347	0.5817
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5494	0.4849
ค่าความแม่นยำ (Precision)	0.5326	0.4835
ค่าความไว (Recall)	0.9679	1.0000
ค่าสถิติ F1 score	0.6871	0.6519
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5736	0.5583

ตารางที่ 23 แสดงผลการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) ความถี่ 1 สัปดาห์

Polygon (MATIC) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.8208	0.4423
ค่าความแม่นยำ (Precision)	0.7350	0.4423
ค่าความไว (Recall)	0.8667	1.0000
ค่าสถิติ F1 score	0.7954	0.6133
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.7002	0.4070
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5597	0.4808
ค่าความแม่นยำ (Precision)	0.5290	0.4600
ค่าความไว (Recall)	1.0000	1.0000
ค่าสถิติ F1 score	0.6920	0.6301
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.3452	0.6117
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.7035	0.4423
ค่าความแม่นยำ (Precision)	0.6583	0.4423
ค่าความไว (Recall)	0.8981	1.0000
ค่าสถิติ F1 score	0.7597	0.6133
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6517	0.3313

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5494 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5507 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.8208 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.4808

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล Polygon (MATIC) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5736 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการ

ถดถอยอิลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5817 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.7002 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอิลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6117

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 วันให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 สัปดาห์

4.10 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC)

ตารางที่ 24 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) ความถี่ 1 วัน

Litecoin (LTC) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5031	0.5068
ค่าความแม่นยำ (Precision)	0.5011	0.5042
ค่าความไว (Recall)	0.9990	0.9891
ค่าสถิติ F1 score	0.6671	0.6679
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5155	0.5409
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5035	0.5068
ค่าความแม่นยำ (Precision)	0.5011	0.5041
ค่าความไว (Recall)	0.9968	1.0000
ค่าสถิติ F1 score	0.6669	0.6703
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5510	0.5653
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5178	0.5068
ค่าความแม่นยำ (Precision)	0.5094	0.5042
ค่าความไว (Recall)	0.9764	0.9945
ค่าสถิติ F1 score	0.6695	0.6691
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5627	0.5640

ตารางที่ 25 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) ความถี่ 1 สัปดาห์

Litecoin (LTC) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5655	0.5769
ค่าความแม่นยำ (Precision)	0.5516	0.5417
ค่าความไว (Recall)	0.9929	1.0000
ค่าสถิติ F1 score	0.7059	0.7027
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5243	0.6642
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5724	0.5385
ค่าความแม่นยำ (Precision)	0.5599	0.5200
ค่าความไว (Recall)	0.9760	1.0000
ค่าสถิติ F1 score	0.7116	0.6842
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5128	0.5740
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5637	0.6538
ค่าความแม่นยำ (Precision)	0.5576	0.6000
ค่าความไว (Recall)	0.9849	0.9231
ค่าสถิติ F1 score	0.7121	0.7273
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5486	0.5888

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5178 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าทั้งสามตัวแบบให้ความถูกต้อง (Accuracy) เท่ากันซึ่งเท่ากับ 0.5068 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5724 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.6538

จากการศึกษาข้อมูลสกุลเงินดิจิทัล Litecoin (LTC) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5627 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการ

ถดถอยอิลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5653 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5486 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6642

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.11 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC)

ตารางที่ 26 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) ความถี่ 1 วัน

Wrapped Bitcoin (WBTC) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5376	0.5260
ค่าความแม่นยำ (Precision)	0.5336	0.5247
ค่าความไว (Recall)	0.9931	1.0000
ค่าสถิติ F1 score	0.6932	0.6883
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5530	0.5320
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5561	0.5315
ค่าความแม่นยำ (Precision)	0.5466	0.5276
ค่าความไว (Recall)	0.9811	1.0000
ค่าสถิติ F1 score	0.7020	0.6908
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5594	0.4709
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5564	0.5315
ค่าความแม่นยำ (Precision)	0.5469	0.5276
ค่าความไว (Recall)	0.9753	1.0000
ค่าสถิติ F1 score	0.7008	0.6908
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5311	0.5224

ตารางที่ 27 แสดงผลการศึกษาค้นคว้าข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) ความถี่ 1 สัปดาห์

Wrapped Bitcoin (WBTC) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.8175	0.4423
ค่าความแม่นยำ (Precision)	0.8010	0.4423
ค่าความไว (Recall)	0.9442	1.0000
ค่าสถิติ F1 score	0.8594	0.6133
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.7169	0.4798
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.8025	0.5577
ค่าความแม่นยำ (Precision)	0.8025	0.5000
ค่าความไว (Recall)	0.9429	0.9565
ค่าสถิติ F1 score	0.8670	0.6567
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.7197	0.5892
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6948	0.5769
ค่าความแม่นยำ (Precision)	0.6612	0.5122
ค่าความไว (Recall)	0.9714	0.9130
ค่าสถิติ F1 score	0.7868	0.6563
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.6414	0.5832

จากการศึกษาค้นคว้าข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5564 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5315 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.8175 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5769

จากการศึกษาค้นคว้าข้อมูลสกุลเงินดิจิทัล Wrapped Bitcoin (WBTC) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ

(AUC) มากที่สุดซึ่งเท่ากับ 0.5594 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5320 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.7197 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5892

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

4.12 ผลการศึกษาข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO)

ตารางที่ 28 แสดงผลการศึกษาข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 วัน

UNUS SED LEO (LEO) ความถี่ 1 วัน		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5376	0.5534
ค่าความแม่นยำ (Precision)	0.5288	0.5525
ค่าความไว (Recall)	0.9887	0.9950
ค่าสถิติ F1 score	0.6885	0.7105
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5647	0.5199
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.5303	0.5534
ค่าความแม่นยำ (Precision)	0.5257	0.5525
ค่าความไว (Recall)	0.9973	0.9950
ค่าสถิติ F1 score	0.6885	0.7105
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5351	0.4863
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.5457	0.5644
ค่าความแม่นยำ (Precision)	0.5363	0.5583
ค่าความไว (Recall)	0.9778	1.0000
ค่าสถิติ F1 score	0.6927	0.7166
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5758	0.4662

ตารางที่ 29 แสดงผลการศึกษารหัสข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์

UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์		
Random Forest (RF)	Training set	Test set
ความถูกต้อง (Accuracy)	0.5945	0.7115
ค่าความแม่นยำ (Precision)	0.5415	0.7037
ค่าความไว (Recall)	1.0000	0.7308
ค่าสถิติ F1 score	0.6808	0.7170
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.3754	0.6960
Elastic Net Regression	Training set	Test set
ความถูกต้อง (Accuracy)	0.7240	0.6154
ค่าความแม่นยำ (Precision)	0.7183	0.5750
ค่าความไว (Recall)	0.7810	0.8846
ค่าสถิติ F1 score	0.7483	0.6970
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5270	0.6982
Stacking Classification	Training set	Test set
ความถูกต้อง (Accuracy)	0.6682	0.5769
ค่าความแม่นยำ (Precision)	0.6679	0.5455
ค่าความไว (Recall)	0.9667	0.9231
ค่าสถิติ F1 score	0.7900	0.6857
ค่าพื้นที่ใต้เส้นกราฟ (AUC)	0.5168	0.5947

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) เมื่อพิจารณาจากความถูกต้อง (Accuracy) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5457 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.5644 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.7240 แต่ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ความถูกต้อง (Accuracy) มากที่สุดซึ่งเท่ากับ 0.7115

จากการศึกษารหัสข้อมูลสกุลเงินดิจิทัล UNUS SED LEO (LEO) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่า สำหรับข้อมูลความถี่ 1 วัน ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5758 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะ

ได้ว่าตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5199 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.5270 และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) จะได้ว่าตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดซึ่งเท่ากับ 0.6982

โดยภาพรวมในส่วนของชุดข้อมูลสำหรับการสอน (Training set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน และในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันเช่นกัน

จากการศึกษาข้อมูลสกุลเงินดิจิทัลทั้งหมดสามารถสรุปตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) และค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดของแต่ละสกุลเงินดิจิทัลได้ดังตารางต่อไปนี้

ตารางที่ 30 แสดงตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) มากที่สุดสำหรับชุดข้อมูลสำหรับทดสอบ (Test set)

สกุลเงินดิจิทัล	ความถี่ 1 วัน	ความถี่ 1 สัปดาห์
Bitcoin (BTC)	Elastic Net Regression	Elastic Net Regression
Ethereum (ETH)	Elastic Net Regression / Stacking Classification	Elastic Net Regression
Binance Coin (BNB)	Random Forest / Elastic Net Regression	Random Forest / Elastic Net Regression
Ripple (XRP)	Elastic Net Regression	Stacking Classification
Cardano (ADA)	Elastic Net Regression	Random Forest
Dogecoin (DOGE)	Stacking Classification	Elastic Net Regression
TRON (TRX)	Stacking Classification	Elastic Net Regression
Polygon (MATIC)	Elastic Net Regression	Elastic Net Regression
Litecoin (LTC)	Random Forest / Elastic Net Regression / Stacking Classification	Stacking Classification
Wrapped Bitcoin (WBTC)	Elastic Net Regression / Stacking Classification	Stacking Classification
UNUS SED LEO (LEO)	Stacking Classification	Random Forest

ตารางที่ 31 แสดงตัวแบบที่ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากที่สุดสำหรับชุดข้อมูลสำหรับทดสอบ (Test set)

สกุลเงินดิจิทัล	ความถี่ 1 วัน	ความถี่ 1 สัปดาห์
Bitcoin (BTC)	Elastic Net Regression	Stacking Classification
Ethereum (ETH)	Random Forest	Elastic Net Regression
Binance Coin (BNB)	Random Forest	Stacking Classification
Ripple (XRP)	Random Forest	Stacking Classification
Cardano (ADA)	Random Forest	Random Forest
Dogecoin (DOGE)	Stacking Classification	Random Forest
TRON (TRX)	Random Forest	Stacking Classification
Polygon (MATIC)	Elastic Net Regression	Elastic Net Regression
Litecoin (LTC)	Elastic Net Regression	Random Forest
Wrapped Bitcoin (WBTC)	Random Forest	Elastic Net Regression
UNUS SED LEO (LEO)	Random Forest	Elastic Net Regression

4.13 ผลการศึกษาตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่ให้ความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงินดิจิทัล

ตารางที่ 32 แสดงตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable importance) 5 อันดับแรกในตัวอย่างที่ให้ความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงินดิจิทัล

สกุลเงินดิจิทัล	ตัวแบบ	Variable importance Top 5	Number of active predictors	ความถูกต้อง (Accuracy)
Bitcoin (BTC)	Elastic Net Regression	$X_{16}, X_{48}, X_6, X_{33}, X_{37}$	48	0.5096
Ethereum (ETH)	Elastic Net Regression	$X_{43}, X_{41}, X_{45}, X_{10}, X_{34}$	25	0.6346
Binance Coin (BNB)	Elastic Net Regression	$X_{25}, X_{45}, X_{48}, X_{10}, X_{24}$	22	0.5577
Ripple (XRP)	Stacking Classification	-	-	0.6346
Cardano (ADA)	Random Forest	$X_8, X_{21}, X_{50}, X_{27}, X_{24}$	50	0.5192
Dogecoin (DOGE)	Elastic Net Regression	$X_{10}, X_{24}, X_6, X_{47}, X_{18}$	23	0.5577
TRON (TRX)	Elastic Net Regression	$X_2, X_{29}, X_6, X_{15}, X_{43}$	22	0.5962
Polygon (MATIC)	Elastic Net Regression	$X_{50}, X_{24}, X_{18}, X_{29}, X_{10}$	17	0.5507
Litecoin (LTC)	Stacking Classification	-	-	0.6538
Wrapped Bitcoin (WBTC)	Stacking Classification	-	-	0.5769
UNUS SED LEO (LEO)	Random Forest	$X_{10}, X_{15}, X_8, X_6, X_{41}$	50	0.7115

จากตารางแสดงตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable importance) 5 อันดับแรกในตัวอย่างที่ให้ความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงินดิจิทัล พบว่า โดยภาพรวมตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable importance) และถูกเลือกมากที่สุด ได้แก่ X_{10} (Chande Momentum Oscillator) X_6 (Chaikin Accumulation) และ X_{24} (Rate of Change) นอกจากนี้สำหรับตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) สกุลเงินดิจิทัลส่วนใหญ่จะเลือกตัวบ่งชี้ 17 ถึง 25 ตัวบ่งชี้ ทำให้ได้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.5507 ถึง 0.6346 ยกเว้นสกุลเงินดิจิทัล Bitcoin (BTC) ซึ่งเลือกตัวบ่งชี้ 48 ตัวบ่งชี้ และให้ค่าความถูกต้อง (Accuracy) เพียง 0.5096

บทที่ 5

สรุปผลการวิจัย

5.1 สรุปผลการศึกษา

ในช่วงทศวรรษที่ผ่านมาการเติบโตของตลาดการซื้อขายสกุลเงินดิจิทัลมีการเติบโตแบบทวีคูณ การลงทุนในตลาดสกุลเงินดิจิทัลได้รับความสนใจจากนักลงทุนจำนวนมากเพราะเป็นสินทรัพย์ที่สามารถให้ผลตอบแทนสูง ซึ่งอาจสูงกว่าการลงทุนในตลาดอื่น ๆ ในทางกลับกันสามารถทำให้เกิดความสูญเสียสูงเช่นกัน เนื่องจากมีความผันผวนสูง การลงทุนในตลาดสกุลเงินดิจิทัลจึงต้องอาศัยเครื่องมือวิเคราะห์ที่มีประสิทธิภาพในการจัดการลงทุน การศึกษาค้นคว้าครั้งนี้จึงศึกษาเพื่อทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ตัวแบบการถดถอยอีลาสติกเน็ต (Elastic Net Regression) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification และการวิเคราะห์ทางเทคนิค (Technical Analysis) สำหรับสกุลเงินดิจิทัลที่มีเงื่อนไขมูลค่าตามราคาตลาด (Market capitalization) สูงสุด 20 อันดับแรก ข้อมูลระหว่าง มกราคม พ.ศ.2559 ถึง มิถุนายน พ.ศ.2565 โดยใช้ข้อมูลความถี่ที่แตกต่างกัน 2 แบบ ได้แก่ ข้อมูลความถี่ 1 วัน และ 1 สัปดาห์ จากการศึกษาสามารถสรุปผลการศึกษาได้ดังนี้

จากผลการวิเคราะห์ข้อมูลเชิงการตรวจสอบ (Exploratory Data Analysis (EDA)) พบว่าความเบ้ (Skewness) ของข้อมูลสำหรับการสอน (Training set) อยู่ระหว่าง 1.5675 ถึง 5.4086 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงแบบเบ้ขวาค่อนข้างมาก ซึ่งแตกต่างจากความเบ้ (Skewness) ชุดข้อมูลสำหรับทดสอบ (Test set) ที่อยู่ระหว่าง -0.1933 ถึง 0.5779 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงแบบเบ้ขวาลึกน้อยและมี 2 สกุลเงินดิจิทัลที่ข้อมูลมีการแจกแจงแบบเบ้ขวาลึกน้อยและเมื่อพิจารณาความโด่ง (Kurtosis) พบว่า ความโด่ง (Kurtosis) ของข้อมูลสำหรับการสอน (Training set) อยู่ระหว่าง 1.1553 ถึง 31.1522 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงที่มีความโด่งสูงกว่าความโด่งของการแจกแจงปกติ ซึ่งแตกต่างจากความโด่ง (Kurtosis) ชุดข้อมูลสำหรับทดสอบ (Test set) ที่อยู่ระหว่าง -0.07475 ถึง -1.4487 ทำให้เห็นว่าข้อมูลส่วนใหญ่มีการแจกแจงที่มีความโด่งต่ำกว่าความโด่งของการแจกแจงปกติ โดยภาพรวมจะเห็นว่าข้อมูลสำหรับการสอน (Training set) และชุดข้อมูลสำหรับทดสอบ (Test set) มีลักษณะข้อมูลที่ค่อนข้างแตกต่างกัน ซึ่งอาจส่งผลกระทบต่อการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล

เมื่อพิจารณาความสมดุลของข้อมูล จากข้อมูลสกุลเงินดิจิทัลทั้งหมดที่ใช้ในการทำนายสัญญาณพบว่า สำหรับข้อมูลความถี่ 1 วัน ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 47 ถึงร้อยละ 54 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 46 ถึงร้อยละ 53 และสำหรับข้อมูลความถี่ 1 สัปดาห์ ราคาสกุลเงินดิจิทัลสูงขึ้นในช่วงเวลาถัดไปอยู่

ระหว่างร้อยละ 45 ถึงร้อยละ 58 และราคาสกุลเงินดิจิทัลต่ำลงหรือเท่าเดิมในช่วงเวลาถัดไปอยู่ระหว่างร้อยละ 42 ถึงร้อยละ 55 ซึ่งโดยภาพรวมอาจจะสรุปได้ว่าข้อมูลที่ศึกษามีความสมดุลของข้อมูล

การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4847 ถึง 0.8208 ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) และให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4423 ถึง 0.7115 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์ให้ค่าความถูกต้อง (Accuracy) เท่ากับ 0.7115 มากที่สุดสำหรับตัวแบบป่าสุ่ม (Random Forest (RF)) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่าให้ค่าระหว่าง 0.4070 ถึง 0.6960 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) เท่ากับ 0.6960 มากที่สุดสำหรับตัวแบบป่าสุ่ม (Random Forest (RF))

การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) ให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4763 ถึง 0.8025 ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) และให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4615 ถึง 0.6346 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล Ethereum (ETH) ความถี่ 1 สัปดาห์ให้ค่าความถูกต้อง (Accuracy) เท่ากับ 0.6346 มากที่สุดสำหรับตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่าให้ค่าระหว่าง 0.4678 ถึง 0.6982 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล UNUS SED LEO (LEO) ความถี่ 1 สัปดาห์ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) เท่ากับ 0.6982 มากที่สุดสำหรับตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression)

การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4886 ถึง 0.7035 ในส่วนของชุดข้อมูลสำหรับการสอน (Training set) และให้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.4423 ถึง 0.6538 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล Litecoin (LTC) ความถี่ 1 สัปดาห์ให้ค่าความถูกต้อง (Accuracy) เท่ากับ 0.6538 มากที่สุดสำหรับตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification เมื่อพิจารณาจากค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่าให้ค่าระหว่าง 0.3313 ถึง 0.6875 ในส่วนของชุดข้อมูลสำหรับทดสอบ (Test set) ซึ่งการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล Ripple (XRP) ความถี่ 1 สัปดาห์ให้ค่าพื้นที่ใต้

เส้นกราฟ (AUC) เท่ากับ 0.6875 มากที่สุดสำหรับตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification

เมื่อพิจารณาจากตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) มากที่สุดจากชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลสำหรับข้อมูลความถี่ 1 วัน ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ผลลัพธ์ที่ดีที่สุด 2 สกุลเงินดิจิทัล คือ Binance Coin (BNB) และ Litecoin (LTC) ตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ผลลัพธ์ที่ดีที่สุด 8 สกุลเงินดิจิทัล คือ Bitcoin (BTC) Ethereum (ETH) Binance Coin (BNB) Ripple (XRP) Cardano (ADA) Polygon (MATIC) Litecoin (LTC) และ Wrapped Bitcoin (WBTC) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ผลลัพธ์ที่ดีที่สุด 6 สกุลเงินดิจิทัล คือ Ethereum (ETH) Dogecoin (DOGE) TRON (TRX) Litecoin (LTC) Wrapped Bitcoin (WBTC) และ UNUS SED LEO (LEO) และการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลสำหรับข้อมูลความถี่ 1 สัปดาห์ ตัวแบบป่าสุ่ม (Random Forest (RF)) ให้ผลลัพธ์ที่ดีที่สุด 3 สกุลเงินดิจิทัล คือ Binance Coin (BNB) Cardano (ADA) และ UNUS SED LEO (LEO) ตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) ให้ผลลัพธ์ที่ดีที่สุด 6 สกุลเงินดิจิทัล คือ Bitcoin (BTC) Ethereum (ETH) Binance Coin (BNB) Dogecoin (DOGE) TRON (TRX) และ Polygon (MATIC) และตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification ให้ผลลัพธ์ที่ดีที่สุด 3 สกุลเงินดิจิทัล คือ Ripple (XRP) Litecoin (LTC) Wrapped Bitcoin (WBTC) จากผลการศึกษาดังกล่าวจะเห็นว่าแต่ละตัวแบบจะเหมาะสมกับข้อมูลสกุลเงินดิจิทัลที่แตกต่างกัน ซึ่งตัวแบบการถดถอยอิลาสติกเน็ต (Elastic Net Regression) เป็นตัวแบบที่เหมาะสมสำหรับสกุลเงินดิจิทัลส่วนใหญ่ อีกทั้งเมื่อพิจารณาจากตัวแบบการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification พบว่า สามารถช่วยเพิ่มประสิทธิภาพสำหรับการทำนายให้มีค่าความถูกต้อง (Accuracy) ที่มากขึ้น

เมื่อพิจารณาจากความถี่ของข้อมูล โดยการวัดประสิทธิภาพของตัวแบบจากชุดข้อมูลสำหรับทดสอบ (Test set) พบว่า การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัล Bitcoin (BTC) และ Polygon (MATIC) ข้อมูลความถี่ 1 วันให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 สัปดาห์ แต่การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลอื่น ๆ พบว่า ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน ซึ่งภาพรวมจากการวัดประสิทธิภาพของตัวแบบอาจจะสรุปได้ว่า การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วันสำหรับข้อมูลสกุลเงินดิจิทัลส่วนใหญ่

โดยภาพรวมเมื่อพิจารณาค่าความถูกต้อง (Accuracy) พบว่าตัวแบบที่ศึกษาให้ค่าความถูกต้อง (Accuracy) เฉลี่ยเท่ากับ 0.5250 ซึ่งในการนำไปใช้อาจจะต้องเลือกตัวแบบที่เหมาะสม

สำหรับสกุลเงินดิจิทัลอื่นๆ ที่ให้ค่าความถูกต้อง (Accuracy) มากกว่า 0.6 หรือ 0.7 ขึ้นอยู่กับระดับความเสี่ยงที่ยอมรับได้ และเมื่อพิจารณาค่าพื้นที่ใต้เส้นกราฟ (AUC) พบว่าตัวแบบที่ศึกษาให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) เฉลี่ยเท่ากับ 0.5464 ซึ่งในการนำไปใช้อาจจะต้องเลือกตัวแบบที่เหมาะสมสำหรับสกุลเงินดิจิทัลอื่นๆ ที่ให้ค่าพื้นที่ใต้เส้นกราฟ (AUC) มากกว่า 0.6 หรือ 0.7 ขึ้นอยู่กับระดับความเสี่ยงที่ยอมรับได้เช่นกัน

เมื่อพิจารณาตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable importance) 5 อันดับแรกในตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) มากที่สุดสำหรับแต่ละสกุลเงินดิจิทัล พบว่า โดยภาพรวมตัวบ่งชี้ทางเทคนิค (Technical indicator) ที่มีความสำคัญ (Variable importance) และถูกเลือกมากที่สุด ได้แก่ X_{10} (Chande Momentum Oscillator) X_6 (Chaikin Accumulation) และ X_{24} (Rate of Change) นอกจากนี้สำหรับตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) สกุลเงินดิจิทัลส่วนใหญ่จะเลือกตัวบ่งชี้ 17 ถึง 25 ตัวบ่งชี้ ทำให้ได้ค่าความถูกต้อง (Accuracy) ระหว่าง 0.5507 ถึง 0.6346 ยกเว้นสกุลเงินดิจิทัล Bitcoin (BTC) ซึ่งเลือกตัวบ่งชี้ 48 ตัวบ่งชี้ และได้ค่าความถูกต้อง (Accuracy) เพียง 0.5096

5.2 อภิปรายผลการศึกษา

จากการศึกษาการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลครั้งนี้พบว่า ตัวแบบแต่ละตัวแบบเหมาะสมสำหรับการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลที่แตกต่างกัน ซึ่งตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) เหมาะสมสำหรับการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลส่วนใหญ่ อย่างไรก็ตามถึงแม้ตัวแบบป่าสุ่ม (Random Forest (RF)) จะเหมาะสมสำหรับการทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลเพียงบางสกุลเงินดิจิทัล แต่สามารถให้ค่าความถูกต้อง (Accuracy) สูงถึง 0.7115 ซึ่งมากที่สุดสำหรับการศึกษาการทำนายครั้งนี้ นอกจากนี้พบว่าการสร้างตัวแบบด้วยการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สามารถช่วยเพิ่มประสิทธิภาพสำหรับการทำนายของตัวแบบซึ่งสอดคล้องกับผลการศึกษาในอดีต อ้างอิงจาก Ye et al., (2022) ที่ได้ศึกษาการทำนายราคาสกุลเงินดิจิทัลบิตคอยน์ (Bitcoin) โดยพบว่า การสร้างตัวแบบโดยใช้วิธีการ Stacking Classification สามารถช่วยเพิ่มประสิทธิภาพสำหรับการทำนายของตัวแบบได้

นอกจากนี้ยังพบผลการศึกษาที่แตกต่างจากผลการศึกษาในอดีต คือ การทำนายสัญญาณการซื้อขายสกุลเงินดิจิทัลโดยใช้ข้อมูลความถี่ 1 สัปดาห์ให้ผลลัพธ์ดีกว่าข้อมูลความถี่ 1 วัน ซึ่งแตกต่างจากผลการศึกษาในอดีตที่กล่าวไว้ว่า ข้อมูลความถี่สูงให้ผลลัพธ์ดีกว่าข้อมูลความถี่ต่ำ อ้างอิงจาก Ozer and Sakar (2022) ได้ศึกษาการซื้อขายสกุลเงินดิจิทัล โดยกำหนดตัวแปรตามเป็นการเปลี่ยนแปลงของราคาซื้อขายสกุลเงินดิจิทัล และตัวแปรอิสระเป็นค่าของราคาซื้อขายสกุลเงิน

ดิจิทัล ซึ่งประเมินผลโดยใช้อัตราผลตอบแทนเฉลี่ย (Average ROI) จากการศึกษาการซื้อขายสกุลเงินดิจิทัลพบว่าการศึกษาการซื้อขายในเวลาที่ 4 ชั่วโมงให้อัตราผลตอบแทนมากกว่าในเวลาที่ 1 วัน และ Vo and Bremm (2020) ได้ศึกษาการซื้อขายสกุลเงินดิจิทัลด้วยความถี่สูง โดยกำหนดตัวแปรตามเป็นสัญญาณซื้อขายสกุลเงินดิจิทัล และแปรอิสระเป็นค่าของตัวบ่งชี้ทางเทคนิค (Technical indicator) ซึ่งประเมินผลโดยใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความไว (Recall) และค่าสถิติ F1 score จากการศึกษาการซื้อขายสกุลเงินดิจิทัลบิตคอยน์ (Bitcoin) พบว่าการซื้อขายด้วยความถี่สูงให้ผลลัพธ์ดีกว่าการซื้อขายด้วยความถี่ต่ำ

อย่างไรก็ตามการศึกษารุ่นนี้ศึกษาเพียงตัวแบบป่าสุ่ม (Random Forest (RF)) และตัวแบบการถดถอยอีลาสติคเน็ต (Elastic Net Regression) อาจจะมีตัวแบบอื่นที่เหมาะสมในการเพิ่มประสิทธิภาพด้วยการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สำหรับข้อมูลการซื้อขายสกุลเงินดิจิทัล นอกจากนี้ตลาดการซื้อขายสกุลเงินดิจิทัลเป็นตลาดที่ค่อนข้างใหม่สำหรับนักลงทุน มีการเปลี่ยนแปลงอย่างรวดเร็ว และมีการเติบโตแบบทวีคูณ ซึ่งข้อมูลสำหรับผู้วิจัยศึกษาเป็นข้อมูลระหว่าง มกราคม พ.ศ.2559 ถึง มิถุนายน พ.ศ.2565 ซึ่งอาจจะทำให้เห็นภาพรวมและการเปลี่ยนแปลงของตลาดสกุลเงินดิจิทัลยังไม่มากพอ จึงควรต้องศึกษาข้อมูลที่ระยะเวลายาวนานขึ้นและเป็นปัจจุบันมากขึ้น และควรศึกษาปัจจัยอื่น ๆ ที่ส่งผลต่อตลาดการซื้อขายสกุลเงินดิจิทัล

5.3 ข้อเสนอแนะ

- 1) พิจารณาเพิ่มข้อมูลความถี่ที่หลากหลายในการศึกษา เช่น ข้อมูลความถี่ 12 ชั่วโมง ความถี่ 3 วัน ความถี่ 2 สัปดาห์ และศึกษาข้อมูลที่เป็นปัจจุบันมากขึ้น
- 2) การศึกษาเพิ่มเติมสำหรับตัวแบบการถดถอยโลจิสติก (Logistic Regression (LR)) เนื่องจากเป็นตัวแบบที่เหมาะสมสำหรับสกุลเงินดิจิทัลส่วนใหญ่
- 3) การศึกษาเพิ่มเติมสำหรับตัวแบบป่าสุ่ม (Random Forest (RF)) เนื่องจากเป็นตัวแบบที่สามารถให้ค่าความถูกต้อง (Accuracy) มากที่สุดสำหรับการศึกษาการทำนายครั้งนี้
- 4) การศึกษาตัวแบบอื่น ๆ ที่อาจจะเหมาะสมในการเพิ่มประสิทธิภาพด้วยการเรียนรู้แบบกลุ่มด้วยเทคนิค Stacking Classification สำหรับข้อมูลการซื้อขายสกุลเงินดิจิทัล

บรรณานุกรม

- Akyildirim, E., Goncu, A., & Sensoy, A. (2021). Prediction of cryptocurrency returns using machine learning. *Annals of Operations Research*, 297, 3-36.
- Džeroski, S., & Ženko, B. (2004). Is combining classifiers with stacking better than selecting the best one? *Machine learning*, 54, 255-273.
- Ganaie, M. A., Hu, M., Malik, A., Tanveer, M., & Suganthan, P. (2022). Ensemble deep learning: A review. *Engineering Applications of Artificial Intelligence*, 115, 105151.
- Gkillas, K., & Katsiampa, P. (2018). An application of extreme value theory to cryptocurrencies. *Economics Letters*, 164, 109-111.
- Gradojevic, N., Kukolj, D., Adcock, R., & Djakovic, V. (2023). Forecasting Bitcoin with technical analysis: A not-so-random forest? *International Journal of Forecasting*, 39(1), 1-17.
- Grobys, K., Ahmed, S., & Sapkota, N. (2020). Technical trading rules in the cryptocurrency market. *Finance Research Letters*, 32, 101396.
- Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., & Quintana, D. (2020). Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators. *Expert Systems with Applications*, 149, 113250.
- Nti, I. K., Adekoya, A. F., & Weyori, B. A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007-3057.
- Obthong, M., Tantisantiwong, N., Jeamwatthanachai, W., & Wills, G. (2020). A survey on machine learning for stock price prediction: Algorithms and techniques.
- Ortu, M., Uras, N., Conversano, C., Bartolucci, S., & Destefanis, G. (2022). On technical trading and social media indicators for cryptocurrency price classification through deep learning. *Expert Systems with Applications*, 198, 116804.
- Ozer, F., & Sakar, C. O. (2022). An automated cryptocurrency trading system based on the detection of unusual price movements with a Time-Series Clustering-Based approach. *Expert Systems with Applications*, 200, 117017.
- Park, C. H., & Irwin, S. H. (2007). What do we know about the profitability of technical

analysis? *Journal of Economic surveys*, 21(4), 786-826.

Parray, I. R., Khurana, S. S., Kumar, M., & Altalbe, A. A. (2020). Time series data analysis of stock price movement using machine learning techniques. *Soft Computing*, 24, 16509-16517.

Vo, A., & Yost-Bremm, C. (2020). A high-frequency algorithmic trading strategy for cryptocurrency. *Journal of Computer Information Systems*, 60(6), 555-568.

Ye, Z., Wu, Y., Chen, H., Pan, Y., & Jiang, Q. (2022). A stacking ensemble deep learning model for bitcoin price prediction.





จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	ศรารุณี ทองเชื้อ
วัน เดือน ปี เกิด	20 สิงหาคม 2539
สถานที่เกิด	โรงพยาบาลโสธร ยโสธร
วุฒิการศึกษา	วิทยาศาสตรบัณฑิต จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	134 ถ.กรุงธนบุรี แขวงบางลำภูล่าง เขตคลองสาน กรุงเทพมหานคร 10600



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY