



สมาคมนวัตกรรมและเทคโนโลยีสร้างสรรค์ ร่วมกับ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ

การประชุมวิชาการระดับชาติเชิงสร้างสรรค์ ครั้งที่ 9

21-23
AUG.
2024

2024
CreTech

Creative
Technology &
Artificial Intelligence
at Cape Racha Hotel, Sriracha, Chon Buri

หุ่นยนต์ซื้อขายอัตโนมัติด้วยโมเดลมาร์คอฟซ่อนเร้น

สำหรับการพยากรณ์สกุลเงินดิจิทัล

Automated Trading Bot Using Hidden Markov Models

for Cryptocurrency Prediction

ดลธรรม เจริญธรรมกิจ¹, ภัทรชนน อุไรวิชัยกุล¹, ภูมิไทย พรหมโกฏิ¹,

จิตรัตน์ อัมมายุสสุนทร¹, ชุเกียรติ วรสุชีพ¹, และ วรินทร์ วัฒนพรพรหม^{1*}

Dollatham Charoenthammakit¹, Pattarachanon Uraiwichaiikul¹, Poomthai Promkote¹,

Thitirat Atchayasoonporn¹, Chukiat Worasuchee¹, and Warin Wattanapornprom^{1*}

¹สาขาวิทยาการคอมพิวเตอร์ประยุกต์ ภาควิชาคณิตศาสตร์ คณะวิทยาศาสตร์

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ประเทศไทย

¹Applied Computer Science Program, Department of Mathematics, Faculty of Science,

King Mongkut's University of Technology Thonburi, Thailand

*Tel: 66-954956245, E-mail: warin.wat@kmutt.ac.th

บทคัดย่อภาษาไทย

การพัฒนาเทคโนโลยีทางการเงินดิจิทัลและความนิยมในการซื้อขายสกุลเงินดิจิทัลเพิ่มขึ้นอย่างมากในปัจจุบัน ทำให้เกิดความต้องการหุ่นยนต์ซื้อขายอัตโนมัติที่มีประสิทธิภาพในการพยากรณ์และการตัดสินใจซื้อขายได้อย่างรวดเร็วและแม่นยำ การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาหุ่นยนต์ซื้อขายอัตโนมัติที่ใช้แบบจำลองมาร์คอฟซ่อนเร้น (HMM) ในการพยากรณ์ราคาสกุลเงินดิจิทัล เพื่อให้สามารถทำกำไรจากความผันผวนของตลาดได้อย่างมีประสิทธิภาพ ผลการทดลองแสดงให้เห็นว่า HMM มีความแม่นยำในการพยากรณ์ราคาสูงถึง 80.08% และมีความสามารถในการลดความเสี่ยงจากการใช้ข้อมูลล่าช้า โดยเมื่อเปรียบเทียบกับแบบจำลองต้นไม้ตัดสินใจ (Decision Tree) ที่มีความแม่นยำ 70.78% HMM ยังมีประสิทธิภาพในการทำกำไรสูงกว่าถึง 80% จากการซื้อขายแบบไดนามิกในตลาดบิตคอยน์

คำสำคัญ : การซื้อขายอัตโนมัติ แบบจำลองมาร์คอฟซ่อนเร้น การพยากรณ์ราคาสกุลเงินดิจิทัล

ABSTRACT

The development of financial technology and the increasing popularity of cryptocurrency trading have significantly driven the demand for efficient automated trading bots capable of accurate and rapid price prediction and trading decision-making. This study aims to develop an automated trading bot using Hidden Markov Models (HMM) for cryptocurrency price prediction to capitalize on market volatility effectively. The experimental results demonstrate that HMM achieves a high prediction accuracy of 80.08% and effectively



mitigates risks associated with outdated data usage. Compared to the Decision Tree model, which has an accuracy of 70.78%, HMM also shows superior profitability by 80% in dynamic trading scenarios within the Bitcoin market.

Keyword: Automated Trading; Hidden Markov Model; Cryptocurrency Price Prediction

1. บทนำ

การพัฒนาเทคโนโลยีและการเพิ่มขึ้นของการซื้อขายสินทรัพย์ทางการเงินออนไลน์ได้ส่งผลให้ความต้องการในการใช้ระบบอัตโนมัติและแบบจำลองการเรียนรู้ของเครื่องมีมากขึ้น การพัฒนาหุ่นยนต์ซื้อขายอัตโนมัติที่สามารถปรับตัวและทำกำไรได้อย่างมีประสิทธิภาพนั้นกลายเป็นเป้าหมายสำคัญของนักวิจัยหลายคน การใช้แบบจำลองการเรียนรู้ของเครื่องแบบออนไลน์ (Online Machine Learning) [1] และแบบจำลองที่สามารถอธิบายได้ (Interpretable Machine Learning) [2] นับว่าเป็นแนวทางที่สำคัญในการพัฒนาระบบเหล่านี้

แบบจำลองการเรียนรู้ของเครื่องแบบออนไลน์ช่วยให้ระบบสามารถอัปเดตและปรับตัวตามข้อมูลใหม่ได้อย่างต่อเนื่อง ซึ่งเป็นสิ่งสำคัญในสภาพแวดล้อมที่มีการเปลี่ยนแปลงอย่างรวดเร็ว เช่น ตลาดสกุลเงินดิจิทัล การใช้แบบจำลองการเรียนรู้แบบออนไลน์ช่วยลดความเสี่ยงจากการใช้ข้อมูลล้าสมัยและเพิ่มความแม่นยำในการพยากรณ์ราคาสินทรัพย์ นอกจากนี้ แบบจำลองที่สามารถอธิบายได้ยังมีความสำคัญในการทำให้ผู้ใช้งานสามารถเข้าใจและตรวจสอบการทำงานของแบบจำลองได้ง่ายขึ้น ลดความซับซ้อนในการตีความผลลัพธ์ และเพิ่มความโปร่งใสในการตัดสินใจ

หนึ่งในแบบจำลองที่ได้รับความนิยมในการใช้เป็นแบบจำลองการเรียนรู้ของเครื่องและสามารถอธิบายได้คือแบบจำลองมาร์คอฟซ่อนเร้น (Hidden Markov Model - HMM) [3] [4] มีความสามารถในการวิเคราะห์ข้อมูลตามลำดับเวลาและจัดการกับความไม่แน่นอนได้ดี โดยสามารถแสดงผลของสถานะที่ซ่อนอยู่ซึ่งไม่สามารถสังเกตได้

โดยตรง ทำให้สามารถพยากรณ์และตัดสินใจในสถานการณ์ที่มีความไม่แน่นอนได้อย่างมีประสิทธิภาพ

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาหุ่นยนต์ซื้อขายอัตโนมัติที่ใช้ HMM ในการพยากรณ์ราคาสกุลเงินดิจิทัล โดยมุ่งเน้นที่การสร้างกำไรจากความผันผวนของตลาด การใช้ HMM ช่วยให้สามารถจับแนวโน้มของราคาและตอบสนองต่อการเปลี่ยนแปลงของตลาดได้อย่างรวดเร็วและแม่นยำ การพัฒนานี้ยังครอบคลุมถึงการเปรียบเทียบประสิทธิภาพของ HMM กับแบบจำลองต้นไม้ตัดสินใจ (Decision Tree) เพื่อแสดงให้เห็นถึงข้อดีและข้อเสียของแต่ละแบบจำลอง

ผลการวิจัยพบว่า HMM มีความแม่นยำในการพยากรณ์ราคาบิตคอยน์สูงถึง 80.08% ซึ่งสูงกว่าแบบจำลองต้นไม้ตัดสินใจที่มีความแม่นยำเพียง 70.78% นอกจากนี้ การใช้ HMM ยังช่วยลดความผันผวนของการตัดสินใจและเพิ่มประสิทธิภาพในการทำกำไรของหุ่นยนต์ซื้อขายอัตโนมัติได้อย่างมีนัยสำคัญ

2. งานวิจัยที่เกี่ยวข้อง

การวิจัยเกี่ยวกับการพยากรณ์ราคาสกุลเงินดิจิทัลด้วยการเรียนรู้ของเครื่องได้รับความสนใจอย่างมากในช่วงหลายปีที่ผ่านมา เนื่องจากความผันผวนและการเติบโตอย่างรวดเร็วของตลาดสกุลเงินดิจิทัล งานวิจัยหลายชิ้นได้พัฒนาและประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องเพื่อพยากรณ์แนวโน้มและราคาของสกุลเงินดิจิทัล โดยหนึ่งในงานวิจัยที่ได้รับความนิยมคือการใช้เครือข่ายประสาทเทียม (Neural Networks) โดยเฉพาะอย่างยิ่ง Long Short-Term Memory (LSTM) ซึ่งเป็นประเภทของ Recurrent Neural Networks (RNN) ที่มีความสามารถในการ



จัดการกับลำดับข้อมูลที่ยาวและการพยากรณ์ระยะยาว งานวิจัยของ McNally, Roche และ Caton ในปี 2018 ได้ใช้ LSTM [5] เพื่อพยากรณ์ราคาบิตคอยน์และพบว่าโมเดลนี้สามารถให้ผลลัพธ์ที่แม่นยำและสามารถตอบสนองต่อการเปลี่ยนแปลงของตลาดได้ดี

งานวิจัยของ Alessandretti, ElBahrawy, Aiello และ Baronchelli ในปี 2018 [6] ได้ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ในการพยากรณ์ราคาสกุลเงินดิจิทัล โดยใช้ Convolutional Neural Networks (CNN) ร่วมกับ LSTM ในการวิเคราะห์ข้อมูลแบบกราฟและลำดับเวลา ผลการทดลองแสดงให้เห็นว่าโมเดลนี้มีความแม่นยำสูงในการพยากรณ์และสามารถจับแนวโน้มของราคาสกุลเงินดิจิทัลได้อย่างมีประสิทธิภาพ

ในอีกมุมหนึ่ง งานวิจัยของ Jiang และ Liang ในปี 2017 [7] ได้ใช้เทคนิคการเรียนรู้แบบเสริมกำลัง (Reinforcement Learning) ในการพยากรณ์และสร้างกลยุทธ์การซื้อขายอัตโนมัติสำหรับสกุลเงินดิจิทัล โดยใช้ Deep Q-Networks (DQN) ในการฝึกโมเดลให้สามารถตัดสินใจในการซื้อขายได้อย่างมีประสิทธิภาพ

ในด้านการใช้แบบจำลองทางสถิติงานวิจัยของ Jang และ Lee ในปี 2017 พบว่า Bayesian Neural Networks (BayesNN) [8] สามารถพยากรณ์แนวโน้มของราคาบิตคอยน์ได้อย่างแม่นยำ

ก่อนหน้านี้ HMM ได้รับการนำมาใช้ในการพยากรณ์การซื้อขายหุ้นจากความสามารถในการวิเคราะห์ลำดับข้อมูลและการจัดการกับความไม่แน่นอน งานวิจัยของ Hassan และ Nath ในปี 2005 [9] ได้ใช้ HMM ในการพยากรณ์แนวโน้มของราคาหุ้น โดยผลการวิจัยพบว่า HMM สามารถพยากรณ์ราคาหุ้นได้อย่างแม่นยำและมีความสามารถในการปรับตัวตามการเปลี่ยนแปลงของตลาดได้ดี นอกจากนี้ Yao, Tan และ Poh ในปี 1999 [10] ได้ใช้ HMM ในการพยากรณ์แนวโน้มของตลาดหุ้นสิงคโปร์ พบว่าโมเดลนี้สามารถจับแนวโน้มระยะสั้นและระยะยาวได้อย่างมีประสิทธิภาพและมีความแม่นยำสูง

ในแง่ของความเร็วและความซับซ้อน โมเดล LSTM และ CNN มักต้องการทรัพยากรคอมพิวเตอร์สูงและเวลาในการฝึกอบรมที่นาน เนื่องจากมีโครงสร้างที่ซับซ้อนและต้องการข้อมูลปริมาณมาก ในขณะที่โมเดล DQN และ HMM มีความซับซ้อนน้อยกว่าและสามารถฝึกอบรมได้เร็วกว่า อย่างไรก็ตามประสิทธิภาพของโมเดลเหล่านี้อาจแตกต่างกันไปตามคุณภาพของข้อมูลและการปรับแต่งพารามิเตอร์

HMM ไม่เพียงแต่มีความแม่นยำในการพยากรณ์เท่านั้น แต่ยังมีความเร็วในการประมวลผลที่สูง เนื่องจากการฝึกอบรม HMM มักใช้ทรัพยากรคอมพิวเตอร์น้อยกว่าแบบจำลองการเรียนรู้ของเครื่องอื่น ๆ เช่น Neural Networks หรือ Deep Learning ทำให้ HMM เหมาะสมสำหรับการใช้งานในสถานการณ์ที่ต้องการการตอบสนองที่รวดเร็ว งานวิจัยของ Bollen, Mao และ Zeng ในปี 2011 [11] ได้แสดงให้เห็นว่า HMM สามารถนำไปใช้ในการพยากรณ์ความเคลื่อนไหวของตลาดหุ้นโดยใช้ข้อมูลจากสื่อสังคมออนไลน์ และสามารถประมวลผลได้อย่างรวดเร็วและมีประสิทธิภาพสูงกว่าแบบจำลองอื่น ๆ

3. วิธีการดำเนินการวิจัย

ในส่วนนี้จะกล่าวถึงวิธีการและกระบวนการที่ใช้จัดทำระบบหุ่นยนต์ซื้อขายอัตโนมัติเพื่อช่วยให้นักลงทุนสามารถใช้หุ่นยนต์ซื้อขายอัตโนมัติได้อย่างมีประสิทธิภาพโดยลดความเสี่ยงและเพิ่มโอกาสในการทำกำไรจากการซื้อขายสกุลเงินดิจิทัล โดยมีรายละเอียดขั้นตอนดังต่อไปนี้

3.1 การพัฒนาการเรียนรู้ของเครื่อง

3.1.1 การเตรียมข้อมูล

ข้อมูลที่ใช้ในการทดลองนี้ได้มาจากตลาดบิตคอยน์ โดยใช้ข้อมูลจากตลาดจริงซึ่งประกอบด้วย เวลา, ราคาเปิด, ราคาสูงสุด, ราคาต่ำสุด, ราคาปิด, และปริมาณ เป็นจำนวน 3,539 วัน โดยใช้ข้อมูลตั้งแต่วันที่ 17 กันยายน พ.ศ. 2557 ถึง วันอาทิตย์ที่ 26 พฤษภาคม พ.ศ. 2567 ดังรูปที่ 1



	Open	High	Low	Close	Volume
Date					
2014-09-17 00:00:00+00:00	465.864014	468.174011	452.421997	457.334015	21056800
2014-09-18 00:00:00+00:00	456.859985	456.859985	413.104004	424.440002	34483200
2014-09-19 00:00:00+00:00	424.102997	427.834991	384.532013	394.795990	37919700
2014-09-20 00:00:00+00:00	394.673004	423.295990	389.882996	408.903992	36863600
2014-09-21 00:00:00+00:00	408.084991	412.425995	393.181000	398.821014	26580100

รูปที่ 1 ตัวอย่างตารางแสดงราคาประวัติและปริมาณการซื้อขายของบิตคอยน์

3.1.2 การสกัดคุณลักษณะ

การสกัดคุณลักษณะทางเทคนิคจากข้อมูลราคาสกุลเงินดิจิทัล [12] เป็นขั้นตอนสำคัญในการเตรียมข้อมูลสำหรับการฝึกอบรมแบบจำลองการเรียนรู้ของเครื่อง ได้แก่ การหาค่าเฉลี่ยเคลื่อนที่แบบทวีคูณ (Exponential Moving Average - EMA), ค่าเฉลี่ยเคลื่อนที่ (Moving Average - MA), ค่าเฉลี่ยขอบเขตที่แท้จริง (Average True Range - ATR), ดัชนีทิศทางเฉลี่ย (Average Directional Index - ADX), ดัชนีกำลังสัมพันธ์ (Relative Strength Index - RSI), เส้นค่าเฉลี่ยเคลื่อนที่แบบปกติ (Simple Moving Average - SMA), และ ดัชนีเฉลี่ยเคลื่อนที่เชิงแตกต่าง (Moving Average Convergence Divergence - MACD) เพื่อใช้ในการพยากรณ์

1. ค่าเฉลี่ยเคลื่อนที่แบบทวีคูณ (Exponential Moving Average - EMA) คือค่าเฉลี่ยเคลื่อนที่ที่ให้น้ำหนักมากกว่ากับราคาล่าสุด P_t มีวิธีการคำนวณดังนี้

$$EMA_t = \alpha \times P_t + (1 - \alpha) \times EMA_{t-1}$$

α คือ smooth factor ซึ่งคำนวณได้จาก

$$\alpha = \frac{2}{N + 1}$$

โดย N คือจำนวนวันที่ใช้ในการคำนวณ

2. ค่าเฉลี่ยเคลื่อนที่ (Moving Average - MA) คือค่าเฉลี่ยของราคาที่คำนวณจากราคาหลายช่วงเวลา ใช้สูตรดังนี้

$$MA_t = \frac{1}{N} \sum_{i=0}^{N-1} P_{t-i}$$

3. ค่าเฉลี่ยขอบเขตที่แท้จริง (Average True Range - ATR) ใช้ในการวัดความผันผวนของราคา คำนวณจากค่า True Range (TR)

$TR = \max(H_t - L_t, |H_t - C_{t-1}|, |L_t - C_{t-1}|)$
โดย H_t คือราคาสูงสุด, L_t คือราคาล่าสุด, และ C_{t-1} คือราคาปิดของวันก่อนหน้า ATR คือค่าเฉลี่ยเคลื่อนที่ของ TR:

$$ATR = \frac{1}{N} \sum_{i=0}^{N-1} TR_{t-i}$$

4. ดัชนีทิศทางเฉลี่ย (Average Directional Index - ADX) ใช้ในการวัดความแข็งแกร่งของแนวโน้ม คำนวณจากค่า Directional Movement Index (DMI) ซึ่งมีสองค่า ได้แก่ DI^+ และ DI^- :

$$DI^+ = \frac{EMA(DM^+)}{ATR} \times 100$$

$$DI^- = \frac{EMA(DM^-)}{ATR} \times 100$$

ค่า DM^+ และ DM^- คำนวณจากการเปรียบเทียบราคาส่งและต่ำสุดของวันก่อนหน้า ADX คำนวณจากค่าเฉลี่ยของค่า DI

$$ADX = EMA\left(\frac{|DI^+ - DI^-|}{DI^+ + DI^-} \times 100\right)$$



5. ดัชนีกำลังสัมพัทธ์ (Relative Strength Index - RSI) ใช้ในการวัดความเร็วและการเปลี่ยนแปลงของราคาคำนวณจากกำไรเฉลี่ย (Average Gain) และการสูญเสียเฉลี่ย (Average Loss):

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

โดยที่ RS คืออัตราส่วนของ Average Gain และ Average Loss คำนวณจากค่าเฉลี่ยเคลื่อนที่ของกำไรและการสูญเสียในช่วงเวลาที่กำหนด

6. เส้นค่าเฉลี่ยเคลื่อนที่แบบปกติ (Simple Moving Average - SMA) คือค่าเฉลี่ยเคลื่อนที่แบบธรรมดาของราคาใช้สูตรเดียวกับ MA ดังนี้

$$SMA_t = \frac{1}{N} \sum_{i=0}^{N-1} P_{t-i}$$

7. ดัชนีเฉลี่ยเคลื่อนที่เชิงแตกต่าง (Moving Average Convergence Divergence - MACD) คือความแตกต่างระหว่าง EMA สองช่วงเวลา (ปกติคือ 12 วัน และ 26 วัน)

$$MACD = EMA_{12} - EMA_{26}$$

การหาค่าเหล่านี้จากข้อมูลราคาสกุลเงินดิจิทัลสามารถทำได้โดยใช้โปรแกรมทางสถิติหรือโปรแกรมวิเคราะห์ข้อมูลที่มีฟังก์ชันสำหรับการคำนวณตัวบ่งชี้ทางเทคนิคเหล่านี้ เช่น Python ร่วมกับไลบรารี pandas และ ta (technical analysis library)

EMA12	EMA26	MA12	MA26	ATR	ADX	RSI	SMA	MACD
121731.401372	134943.973649	134880.013021	131146.334135	89139.734305	21.632016	48.816307	128524.765625	-13212.572277
107684.803565	127202.087870	120847.395833	125662.815505	85393.778395	22.086702	46.655525	123753.085938	-19517.284305
93385.218401	118871.377657	112583.854167	126196.529447	81684.926199	22.823610	46.159397	117266.835938	-25486.159256
92833.165570	116717.710793	112263.834635	129637.334736	79392.001783	23.222982	48.955652	119699.075521	-23884.545223
81533.291540	109507.805133	108424.869792	124738.070913	75705.830060	23.883176	46.515075	118805.052083	-27974.513593

รูปที่ 2 ตัวอย่างตารางแสดงคุณลักษณะที่ถูกสกัดหรือค่าของตัวบ่งชี้ทางเทคนิค

3.1.3 แบบจำลองที่ใช้

งานวิจัยนี้เลือกใช้แบบจำลองจากความสามารถในการอธิบายและให้เหตุผลของปัญญาประดิษฐ์ (Explainable AI) และประสิทธิภาพด้านความเร็วในการเรียนรู้แบบออนไลน์เท่านั้น (Online Learning) ความสามารถในการประมวลผลข้อมูลต้นไม้มัดสินใจมีโครงสร้างที่เรียบง่ายและไม่ซับซ้อน ทำให้สามารถสร้างและประมวลผลได้รวดเร็วเมื่อเทียบกับโมเดลการเรียนรู้ของเครื่องที่ซับซ้อน เช่น Neural Networks หรือ Deep Learning การตัดสินใจในแต่ละโหนดของ Decision Tree เป็นการเปรียบเทียบเชิงเงื่อนไขที่ใช้ทรัพยากรคอมพิวเตอร์น้อย ทำให้สามารถประมวลผลได้อย่างรวดเร็ว นอกจากนี้ Decision Tree ยังสามารถจัดการกับข้อมูลที่มีคุณลักษณะหลากหลายได้ดี และ

สามารถใช้ในการวิเคราะห์และอธิบายการตัดสินใจได้โดยไม่ต้องใช้เวลาเรียนรู้มาก ส่วน HMM เองก็มีความสามารถในการวิเคราะห์ลำดับข้อมูลและการเปลี่ยนแปลงของสถานะในแต่ละช่วงเวลา ทำให้สามารถวิเคราะห์และพยากรณ์ข้อมูลที่มีลักษณะเป็นลำดับเวลาได้อย่างมีประสิทธิภาพ [13] [14]

1. ต้นไม้ตัดสินใจ (Decision Tree) [15] เป็นโมเดลที่ใช้การตัดสินใจแบบไบนารีในการแยกข้อมูลออกเป็นกลุ่มย่อย ๆ โดยมีการตั้งค่ากฎเกณฑ์ (Rules) ที่ใช้ในการตัดสินใจในแต่ละโหนด (Node) จนกระทั่งไปถึงโหนดใบ (Leaf Node) ซึ่งจะแสดงผลการตัดสินใจสุดท้าย การสร้าง Decision Tree มีขั้นตอนหลัก ๆ ดังนี้:



CreTech²⁰²⁴

**Creative
Technology &
Artificial Intelligence**
at Cape Racha Hotel, Sriracha, Chon Buri

ขั้นตอนที่ 1. การเลือกคุณลักษณะ (Feature Selection): เลือกคุณลักษณะที่จะใช้ในการแยกข้อมูล โดยใช้เกณฑ์ต่าง ๆ เช่น Gini Index, Entropy หรือ Information Gain

ขั้นตอนที่ 2. การแยกข้อมูล (Data Splitting): แยกข้อมูลออกเป็นกลุ่มย่อย ๆ โดยใช้กฎเกณฑ์ที่กำหนด

ขั้นตอนที่ 3. การเลือกโหนดตัดสินใจ (Decision Node Selection): สร้างโหนดใหม่สำหรับแต่ละกลุ่มย่อยและทำการแยกข้อมูลซ้ำ ๆ จนกระทั่งไม่มีโหนดเหลือให้แยกได้ ที่โหนดใบ (leaf node) จะมีการตัดสินใจที่เป็นผลลัพธ์สุดท้าย เช่น การซื้อ (Buy), การขาย (Sell) หรือการถือ (Hold) ทั้งนี้ขึ้นอยู่กับพารามิเตอร์ในการเรียนรู้ อาทิ การตัดกิ่ง (Pruning) เพื่อให้โมเดลมีความยืดหยุ่น

2. แบบจำลองมาร์คอฟซ่อนเร้น (Hidden Markov Model - HMM) [16] เป็นวิธีการประมาณค่าพารามิเตอร์ โดยใช้วิธีการแมกซิมัมไลเคิลฮูด (Maximum Likelihood) อัลกอริทึมนี้ถูกพัฒนาขึ้นโดย Leonard E. Baum และ J.A. Eagon ในปี 1967 และได้รับการปรับปรุงโดย Baum และนักวิจัยอื่น ๆ ในช่วงปีต่อมา โดยทั่วไปแล้วอัลกอริทึม Baum-Welch จะใช้ในการฝึกอบรม HMM เพื่อหาค่าพารามิเตอร์ที่เหมาะสมที่สุดในการทำนายลำดับของข้อมูล มีขั้นตอนหลัก ๆ ดังนี้

ขั้นตอนที่ 1. การตั้งค่าเริ่มต้น (Initialization): เริ่มต้นด้วยการตั้งค่าพารามิเตอร์เริ่มต้นของ HMM ซึ่งรวมถึงเวกเตอร์ความน่าจะเป็นเริ่มต้น

π เมทริกซ์การเปลี่ยนสถานะ A และเมทริกซ์การสังเกต B

ขั้นตอนที่ 2. การประมาณค่า (Expectation Step): ในขั้นตอนนี้จะมีการคำนวณค่าความน่าจะเป็นของการเปลี่ยนสถานะและการสังเกตในแต่ละสถานะ โดยใช้

Forward-Backward Algorithm คำนวณความน่าจะเป็นของการเป็นสถานะ i และ j ในเวลาต่าง ๆ โดย:

$$\xi_t(i, j) = \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{\sum_{i=1}^n \sum_{j=1}^n \alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}$$

ทั้งนี้ $\alpha_t(i)$ และ $\beta_t(i)$ เป็นความน่าจะเป็นของสถานะที่ i ในเวลาต่าง ๆ ซึ่งคำนวณได้จาก Forward-Backward Algorithm

ขั้นตอนที่ 3. ปรับค่าพารามิเตอร์สูงสุด (Maximization Step): โดยใช้ผลลัพธ์จากขั้นตอนก่อนหน้า

$$\pi_i = \gamma_1(i)$$

$$a_{ij} = \frac{\sum_{t=1}^{T-1} \xi_t(i, j)}{\sum_{t=1}^{T-1} \gamma_t(i)}$$

$$b_j(k) = \frac{\sum_{t=1}^T \gamma_t(j) 1(O_t = k)}{\sum_{t=1}^T \gamma_t(j)}$$

ในที่นี้ $\gamma_t(i)$ เป็นความน่าจะเป็นของการอยู่ในสถานะ i ในเวลาต่าง ๆ ซึ่งคำนวณได้จาก:

$$\gamma_t(i) = \sum_{j=1}^N \xi_t(i, j)$$


จากนั้นจึงวนซ้ำขั้นตอนที่ 2 และ 3 จนกว่าค่าพารามิเตอร์จะคงที่ หรือค่าความน่าจะเป็นของข้อมูลไม่เปลี่ยนแปลงไป

3.1.2 การเรียนรู้แบบจำลอง

ขั้นตอนนี้จะใช้ผลตอบแทนจากการเปลี่ยนแปลงราคาของบิตคอยน์และแบ่งข้อมูลออกเป็นชุดฝึกอบรม 70% ตั้งแต่วันที่ 17 กันยายน พ.ศ.2557 ถึง วันพฤหัสบดีที่ 1 กรกฎาคม พ.ศ.2564 และชุดทดสอบ 30% ตั้งแต่วันที่ 2 กรกฎาคม พ.ศ.2564 ถึง วันอาทิตย์ที่ 26 กรกฎาคม พ.ศ.2567 โดยใช้วิธีการแบ่งข้อมูลแบบสำหรับการจำแนกประเภทและการแบ่งข้อมูลตาม

เวลา โดยที่แบบจำลองต้นไม้ตัดสินใจ (Decision Tree) ได้เรียน เพื่อการจำแนกประเภทตัวบ่งชี้ทางเทคนิคเพื่อหาตัวบ่งชี้ที่เหมาะสมที่สุดและนำไปทำนายสถานะการเข้าซื้อของราคาตลาดจริงผ่านการจำแนกด้วย Gini impurity [17] เพื่อวัดความไม่สอดคล้องของการแบ่งแยกในต้นไม้ตัดสินใจ เพื่อการแบ่งกลุ่มในต้นไม้ตัดสินใจทำให้กลุ่มที่สร้างขึ้นมีความหมายที่มากที่สุดด้วยการลดความสอดคล้องในกลุ่ม ดังรูปที่ 3

และได้ฝึกอบรม HMM เพื่อทำนายสถานะราคาตลาดจริง โดยแบ่งเป็น 3 ช่วง คือ ช่วงที่ 0 ตลาดที่มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในระยะยาว ช่วงที่ 1 ช่วงเวลาที่ราคาของสินทรัพย์เคลื่อนไหวโดยไม่มีทิศทางแน่นอนที่ชัดเจนว่าจะขึ้นหรือลง และช่วงที่ 2 เป็นช่วงการเปลี่ยนผ่านวัฏจักรของตลาดที่ลดลงอย่างรวดเร็ว โดยใช้ช่วงที่ 2 ที่เป็นสถานะที่ลดลงอย่างรวดเร็วในระยะเวลาสั้นโดยให้ทำการขายดัง รูปที่ 4



รูปที่ 3 การใช้แบบจำลองต้นไม้ตัดสินใจให้เข้าใจโครงสร้างและกระบวนการตัดสินใจในการแยกข้อมูลและจากตัวบ่งชี้ทางเทคนิค



รูปที่ 4 สถานะของตลาดโดยใช้แบบจำลองมาร์คอฟซ่อนเร้น

ผู้พัฒนาทำการออกแบบส่วนต่อประสานกับผู้ใช้และประสบการณ์ของผู้ใช้โดยเว็บไซต์ Figma [18] โดยที่คำนี้ว่าเว็บไซต์ที่พัฒนาขึ้นจะสามารถเข้าใจได้ง่ายต่อผู้ใช้งาน ฟังก์ชันของเว็บไซต์จะมีดังนี้ หน้าเว็บไซต์สำหรับลงทะเบียนและเข้าสู่ระบบเพื่อสามารถเข้าสู่บัญชีที่ถูกเชื่อมกับบัญชีของเว็บไซต์ไบแนนซ์ (Binance) [19] หน้าเว็บไซต์ที่ใช้สำหรับนำเสนอแผนภูมิของบิตคอยน์เพื่อให้ผู้ใช้สามารถติดตามราคาของสินทรัพย์ดิจิทัลได้อย่างสะดวก หน้าที่ทำให้ผู้ใช้งานสามารถปรับค่าของตัวบ่งชี้ทางเทคนิคได้ตามต้องการและสามารถดูประวัติการทำงานของหุ่นยนต์ซื้อขายอัตโนมัติได้ หน้าสุดท้ายจะเป็นหน้าที่ให้ผู้ใช้สามารถตั้งค่าส่วนต่อประสานโปรแกรมประยุกต์มาของผู้ใช้งานได้

การพัฒนาเว็บไซต์ได้ใช้ React [20] ซึ่งเป็นคลังโปรแกรม Javascript ที่มีจุดเด่นในด้านคอมโพเนนต์ (Virtual Document Object Model) ซึ่งช่วยให้การปรับปรุงส่วนต่อประสานให้เป็นปัจจุบัน เป็นไปอย่างมีประสิทธิภาพ มาช่วยในการพัฒนาทั้งส่วน

หน้าเว็บไซต์ และ ส่วนหลังของเว็บไซต์ตามที่ออกแบบเอาไว้ซึ่งภายในเว็บไซต์ได้เก็บข้อมูลของผู้ใช้งานในรูปแบบฐานข้อมูลไม่ใช่เชิงสัมพันธ์ภายใน MongoDB [21] โดยที่ข้อมูลที่จัดเก็บไว้ได้แก่ ชื่อผู้ใช้, รหัสผ่าน, จดหมายอิเล็กทรอนิกส์, รหัสการเชื่อมต่อโปรแกรมประยุกต์ และ ค่าของตัวบ่งชี้เริ่มต้น และเมื่อทำการพัฒนาเสร็จจึงทำการทดสอบการทำงานของเว็บไซต์ เพื่อให้แน่ใจว่าฟังก์ชันทุกอย่างทำงานได้อย่างถูกต้อง เริ่มแรกเมื่อเข้าสู่เว็บไซต์ของผู้ใช้งานจะพบกับหน้าลงทะเบียนที่ต้องกรอกชื่อผู้ใช้งาน, จดหมายอิเล็กทรอนิกส์, รหัสผ่าน และ ยืนยันรหัสผ่านเพื่อสร้างบัญชี หรือถ้าหากว่าผู้ใช้มีบัญชีอยู่แล้วก็สามารถไปยังหน้าเข้าสู่ระบบเพื่อเข้าสู่ระบบด้วยชื่อผู้ใช้งานและรหัสผ่านที่ลงทะเบียนเอาไว้

หลังจากที่ผู้ใช้งานสร้างบัญชีหรือเข้าสู่ระบบเรียบร้อยแล้วจะเข้ามาสู่หน้าที่แสดงแผนภูมิบิตคอยน์และสามารถไปยังหน้าอื่นๆ และออกจากระบบได้ที่แถบด้านซ้ายตามรูปที่ 5



รูปที่ 5 แผนภูมิของราคาบิตคอยน์

เมื่อผู้ใช้งานทำการเปลี่ยนหน้าจากแถบนำทางทางด้านซ้ายเป็นหน้าการซื้อขายผู้ใช้งานจะพบกับหน้าที่สามารถปรับค่า

ของ ตัวบ่งชี้ตามที่ผู้ใช้งานต้องการและสามารถดูประวัติการซื้อขายที่หุ่นยนต์ซื้อขายอัตโนมัติได้ทำการซื้อขายเอาไว้ตามรูปที่ 6



สมาคมนวัตกรรมและเทคโนโลยีสร้างสรรค์ ร่วมกับ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ

การประชุมวิชาการระดับชาติเชิงสร้างสรรค์ ครั้งที่ 9


2024
CreTech

Creative
Technology &
Artificial Intelligence

at Cape Racha Hotel, Sriracha, Chon Buri

21-23
AUG.
2024

และสุดท้ายคือหน้าสำหรับการตั้งค่า ผู้ใช้งานสามารถกรอกรหัส
การเชื่อมต่อโปรแกรมประยุกต์เพื่อเชื่อมต่อกับบัญชีในเว็บไซต์
ไบแนนซ์และสามารถเปลี่ยนรหัสได้เช่นเดียวกัน



รูปที่ 6 หน้าต่างปรับค่าของตัวบ่งชี้ทางเทคนิค


4. ผลการวิจัยและอภิปรายผล

การประเมินผลได้ทำการประเมินความแม่นยำของทั้งสองวิธี คือแบบจำลองต้นไม้ตัดสินใจและ HMM โดยใช้การวัดความแม่นยำในการพยากรณ์ราคา และทำการทดสอบประสิทธิภาพของหุ่นยนต์ซื้อขายอัตโนมัติเน้นทำกำไรแบบไดนามิก ผ่านการนำหุ่นยนต์มาทดสอบซื้อขายเปรียบเทียบกับกรถือสินทรัพย์ไว้โดยไม่ทำการซื้อเพิ่มและขายออกของตลาดปิดคอยน์เป็นจำนวน 5 ครั้ง และนำมาหาค่าเฉลี่ย

จากการทดลอง แบบจำลองต้นไม้ตัดสินใจ ได้รับการฝึกอบรมและมีความแม่นยำในการพยากรณ์ โดยมีค่าความแม่นยำ เท่ากับ 70.78% ส่วนHMMได้รับการฝึกอบรมโดยใช้ข้อมูลทางเทคนิคและผลตอบแทนจากการเปลี่ยนแปลงราคาแบบจำลองนี้สามารถพยากรณ์การเปลี่ยนแปลงราคาของบิตคอยน์ได้ด้วยค่าความแม่นยำที่สูงถึง 80.08%

การใช้ต้นไม้ตัดสินใจในการพยากรณ์ข้อมูลอนุกรมเวลาอาจพบปัญหาบางอย่าง เช่น การปรับตัวเกินไป (Overfitting) ซึ่งเกิดจากการสร้างโมเดลมากเกินไปจนทำให้โมเดลมีความซับซ้อนและไม่สามารถทำนายข้อมูลใหม่ได้อย่างแม่นยำ นอกจากนี้อาจมีความไวต่อข้อมูลที่มีเสียงรบกวน (Noisy Data) และการกระจายตัวที่ไม่สมดุล ทำให้การพยากรณ์ไม่แม่นยำเท่าที่ควร การใช้ป่าสุ่ม (Random Forest) ซึ่งเป็นการรวมต้นไม้ตัดสินใจหลายต้นเข้าด้วยกันสามารถช่วยลดปัญหาการปรับตัวเกินไปและเพิ่มความแม่นยำในการพยากรณ์ได้ อย่างไรก็ตามการใช้ป่าสุ่มอาจไม่เหมาะสมกับการเรียนรู้ออนไลน์ (Online Learning) เนื่องจากต้องการการปรับปรุงหลายต้นไม้มาร่วมกัน ซึ่งใช้เวลานานและต้องการทรัพยากรการคำนวณ (Breiman, 2001; Domingos & Hulten, 2000) [22][23] ดังนั้นผู้วิจัยจึงเลือกใช้ HMM ในการตัดสินใจหลัก

การประเมินประสิทธิภาพในการให้ผลตอบแทนพบว่าการใช้หุ่นยนต์ซื้อขายอัตโนมัติเน้นทำกำไรแบบไดนามิก ซื้อขายอัตโนมัติสามารถให้ผลตอบแทนสูงกว่าวิธีการซื้อและถือแบบปกติถึง 80.00% จากการทดสอบความเสถียรที่ยืนยันด้วยเทคนิคบิตคอยน์ดังรูปที่ 7



รูปที่ 7 แผนภูมิเปรียบเทียบผลตอบแทนจากหุ่นยนต์และผลตอบแทนจากการถือครองหลักทรัพย์

ในอนาคตการปรับปรุงการใช้ HMM ยังสามารถพัฒนาต่อได้ดีโดยการพิจารณาการใช้ขนาดหน้าต่างที่หลากหลาย (Varying Window Sizes) และการใช้หน้าต่างที่ซ้อนทับกัน (Overlapping Windows) เพื่อเพิ่มความแม่นยำในการพยากรณ์ ขนาดหน้าต่างที่เหมาะสมสามารถช่วยให้โมเดลจับแนวโน้มและลักษณะการเปลี่ยนแปลงของข้อมูลได้ดียิ่งขึ้น การใช้ขนาดหน้าต่างที่หลากหลายช่วยให้โมเดลสามารถเรียนรู้จากข้อมูลที่มีลักษณะเปลี่ยนแปลงได้ในหลายช่วงเวลา เช่น การใช้ขนาดหน้าต่างเล็กเพื่อจับความผันผวนระยะสั้น และการใช้ขนาดหน้าต่างใหญ่เพื่อจับแนวโน้มระยะยาว

การใช้หน้าต่างที่ซ้อนทับกันสามารถช่วยเพิ่มจำนวนข้อมูลที่ใช้ในการฝึกอบรมโมเดล ทำให้แบบจำลองสามารถเรียนรู้จากข้อมูลที่มีความหลากหลายมากขึ้น การใช้หน้าต่างที่ซ้อนทับกันช่วยลดปัญหาการขาดข้อมูลในบางช่วงเวลา ซึ่ง

เป็นสิ่งสำคัญในการพยากรณ์ข้อมูลอนุกรมเวลา นอกจากนี้การทดลองใช้ขนาดหน้าต่างและการซ้อนทับที่หลากหลายยังช่วยให้ได้ผลลัพธ์ที่มีความแม่นยำสูงขึ้น โดยสามารถปรับแต่งขนาดหน้าต่างและการซ้อนทับตามลักษณะเฉพาะของข้อมูลและปัญหาที่ต้องการแก้ไข

การเลือกขนาดหน้าต่างที่เหมาะสมและการใช้หน้าต่างที่ซ้อนทับกันเป็นสิ่งสำคัญในการเพิ่มประสิทธิภาพของโมเดลการพยากรณ์ข้อมูลอนุกรมเวลา งานวิจัยที่ศึกษาวิธีการเหล่านี้พบว่า การใช้ขนาดหน้าต่างและการซ้อนทับที่เหมาะสมสามารถเพิ่มความแม่นยำของการพยากรณ์ได้อย่างมีนัยสำคัญ [24] [25]

สรุปผลการทดลองควรประกอบด้วยทฤษฎีที่นำมาอ้างอิงเพื่ออธิบายผลการทดลองรวมถึงข้อจำกัดของงานวิจัยและอาจมีข้อเสนอแนะของงานที่จะทำต่อไป

5. สรุปผลการวิจัย

จากการดำเนินงานสร้างหุ่นยนต์จากเทคนิคการเรียนรู้ของเครื่องด้วยการนำข้อมูลจากตลาดโดยใช้ข้อมูลจากตลาดจริงและใช้ตัวบ่งชี้ทางเทคนิคหลายตัวเพื่อนำมาเป็นคุณลักษณะในการพยากรณ์ ได้แบ่งข้อมูลออกมาเป็นชุดฝึกอบรมและชุดทดสอบโดยใช้วิธีการแบ่งข้อมูลแบบสุ่มสำหรับการจำแนกประเภทและการแบ่งข้อมูลตามเวลาและจะฝึกอบรมและทดสอบทั้งสองแบบจำลอง

แบบจำลองต้นไม้ตัดสินใจได้เรียนรู้สำหรับการจำแนกประเภทเพื่อค้นหาตัวบ่งชี้ที่เหมาะสมที่สุดในการพยากรณ์และพบว่ามีโดยมีค่าความแม่นยำ เท่ากับ 70.78% ส่วน HMM สามารถพยากรณ์การเปลี่ยนแปลงราคาของบิตคอยน์ได้ด้วยค่าความแม่นยำ ที่สูงถึง 80.08%

ขั้นตอนสุดท้ายการประเมินผลได้ทำการประเมินความแม่นยำของทั้งสองวิธีและผลลัพธ์จากแบบจำลองต้นไม้ตัดสินใจและ HMM โดยใช้การวัดความแม่นยำ โดยให้แบบจำลองต้นไม้ทำนายสถานะราคาตลาดจริงเพื่อทำการซื้อและใช้แบบจำลองมาร์คอฟซ่อนเร้นเพื่อทำการขาย ซึ่ง



การประเมินผลตอบแทนพบว่าการใช้หุ่นยนต์ซื้อขาย
อัตโนมัติเน้นทำกำไรแบบไดนามิก ซื้อขายอัตโนมัติสามารถ
ให้ผลตอบแทนสูงกว่าวิธีการซื้อและถือแบบปกติถึง 80.08%

6. อ้างอิง (ใช้ระบบแวนคูเวอร์)

- [1] Steven C.H. Hoi, Doyen Sahoo, Jing Lu, and Peilin Zhao. Online learning: A comprehensive survey. Neurocomput. 459, C (Oct 2021), 249–289
- [2] Mohammadi Gheymasi H, Soroush M. Explainable AI: Foundations, Methodologies, and Applications. 1st ed. Cham: Springer International Publishing; 2023. 540 p. Available from: <https://link.springer.com/book/10.1007/978-3-030-52701-7>
- [3] Goodfellow I, Bengio Y, Courville A. Deep Learning. MIT Press; 2016
- [4] Murphy KP. Machine Learning: A Probabilistic Perspective. MIT Press; 2012.
- [5] McNally S, Roche J, Caton S. Predicting the price of Bitcoin using Machine Learning. In 2018 26th Euromicro International Conference on Parallel, Distributed and Network-based Processing (PDP) 2018 Mar 21 (pp. 339-343). IEEE.
- [6] Alessandretti L, ElBahrawy A, Aiello LM, Baronchelli A. Anticipating cryptocurrency prices using machine learning. Complexity. 2018 Apr 29;2018.
- [7] Jiang Z, Liang J. Cryptocurrency portfolio management with deep reinforcement learning. In 2017 Intelligent Systems Conference (IntelliSys) 2017 Sep 7 (pp. 905-913). IEEE.
- [8] Jang H, Lee J. An empirical study on modeling and prediction of bitcoin prices with Bayesian neural networks based on blockchain information. IEEE Access. 2017 Sep 26;6:5427-37.
- [9] Hassan MR, Nath B. Stock market forecasting using hidden Markov model: a new approach. In 5th International Conference on Intelligent Systems Design and Applications (ISDA'05) 2005 Sep 8 (pp. 192-196). IEEE.
- [10] Yao JL, Tan CL, Poh HC. Neural networks for technical analysis: A study on KLCI. International Journal of Theoretical and Applied Finance. 1999 Mar;2(02):221-41.
- [11] Bollen J, Mao H, Zeng X. Twitter mood predicts the stock market. Journal of Computational Science. 2011 Mar 1;2(1):1-8.
- [12] Chan HFC, Lee STH, Wong WK. Technical Analysis and Financial Asset Forecasting: From Simple Tools to Advanced Techniques. World Scientific; 2014.
- [13] Patel J, Shah S, Thakkar P, Kotecha K. Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. Expert Systems with Applications. 2015; 42(1): 259-268.
- [14] Rodriguez-Gonzalez A, Garza-Gomez X, Mendoza-Mexicano C, Sanchez-Ramirez C. Stock market trading rule based on a pattern recognition system. Expert Systems with Applications. 2011; 38(3): 2011-2015.



สมาคมนวัตกรรมและเทคโนโลยีสร้างสรรค์ ร่วมกับ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ

การประชุมวิชาการระดับชาติเชิงสร้างสรรค์ ครั้งที่ 9

CreTech 2024

**Creative
Technology &
Artificial Intelligence**
at Cape Racha Hotel, Sriracha, Chon Buri

**21-23
AUG.
2024**

- [15] Quinlan JR. Induction of decision trees. Machine Learning. 1986;1:81-106.
- [16] Baum LE, Petrie T, Soules G, Weiss N. A maximization technique occurring in the statistical analysis of probabilistic functions of Markov chains. Ann Math Statist. 1970;41(1):164-171.
- [17] Breiman L, Friedman JH, Olshen RA, Stone CJ. Classification and Regression Trees. Wadsworth; 1984.
- [18] Jackowski M, Cline D. Figma: Collaborative interface design tool. Journal of User Experience Design. 2018;12(4):34-40.
- [19] Binance Research. Binance Exchange Review. Binance Research. 2024. Available from: <https://research.binance.com>
- [20] Jackson N, Scott M. Mastering React: A comprehensive guide to modern web development. Journal of Web Development Technologies. 2020; 15(1): 22-45.
- [21] BDCC. A Comparative Study of MongoDB and Document-Based MySQL for Big Data Application Data Management. Big Data Cogn. Comput. 2022; 6(2): 49. doi:10.3390/bdcc6020049.
- [22] Breiman L. Random forests. Machine Learning. 2001;45(1):5-32.
- [23] Domingos P, Hulten G. Mining high-speed data streams. Proceedings of the Sixth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2000. p. 71-80.
- [24] Gama J. Knowledge Discovery from Data Streams. CRC Press; 2010.
- [25] Chen T, Guestrin C. XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining; 2016. p. 785-794.