

BITCOIN RETURN FORECASTING USING INTRINSIC MODE FUNCTION AND DEEP NEURAL NETWORK WITH CONFIDENCE-BASED TRADING SIGNAL

Khitawut PHONGPHAEW^{1*}, Somporn PUNPOCHA¹ and Bumroong PUANGKIRD²

1 Faculty of Science and Technology, University of the Thai Chamber of Commerce, Thailand;

Khitawutp@gmail.com (K. P.) (Corresponding Author); sompon_punpocha@yahoo.com (S. P.)

2 Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Thailand;

bumroong.pu@kmitl.ac.th

ARTICLE HISTORY

Received: 9 June 2025

Revised: 23 June 2025

Published: 7 July 2025

ABSTRACT

Bitcoin is a highly volatile asset that poses considerable investment risk. This study proposes a trading strategy that integrates signal decomposition with deep learning to enhance forecasting accuracy, reduce the likelihood of losses, and minimize trades triggered by inaccurate predictions. Daily closing prices of Bitcoin are decomposed using Empirical Mode Decomposition (EMD) to extract Intrinsic Mode Functions (IMFs). IMFs with significant temporal correlation to returns are selected through cross-correlation analysis and used as input features for a stacked deep neural network comprising Bi-LSTM, LSTM, and Dense layers to forecast daily returns. The forecast outputs are transformed into Z-scores and p-values to evaluate confidence levels, which are then used to generate trading signals based on thresholds ranging from 0% to 90%. The model achieves an R^2 of 0.55 and directional accuracy of 80.32%. Without applying confidence thresholds, the strategy yields an average daily return of 1.50%, clearly outperforming the buy-and-hold approach (0.163%). Even when using a high confidence threshold of 90%, which reduces the number of trades and average returns, the strategy still delivers better returns than the buy-and-hold strategy at all confidence levels.

Keywords: Empirical Mode Decomposition, Strategy, Confidence Level, Trading Signal

CITATION INFORMATION: Phongphaew, K., Punpocha, S., & Puangkird, B. (2025). Bitcoin Return Forecasting Using Intrinsic Mode Function and Deep Neural Network with Confidence-Based Trading Signal. *Procedia of Multidisciplinary Research*, 3(7), 7

การพยากรณ์ผลตอบแทนบิตคอยน์โดยใช้การแยกฟังก์ชันโหมตภายในร่วมกับโครงข่ายประสาทเทียมเชิงลึก และเกณฑ์ความเชื่อมั่นเพื่อสร้างสัญญาณซื้อขาย

คีตวรุฬ ฝ่องแผ้ว^{1*}, สมพร บันโกษา¹ และ บำรุง พ่วงเกิด²

1 คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยหอการค้าไทย; Khitawutp@gmail.com (คีตวรุฬ)

(Corresponding Author); sompon_punpocha@yahoo.com (สมพร)

2 คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง;

bumroong.pu@kmitl.ac.th

บทคัดย่อ

บิตคอยน์เป็นสินทรัพย์ที่มีความผันผวนสูง ก่อให้เกิดความเสี่ยงต่อการลงทุน งานวิจัยนี้เสนอแนวทางการพัฒนากลยุทธ์ซื้อขายที่ผสมผสานเทคนิคการแยกสัญญาณกับการเรียนรู้เชิงลึก เพื่อเพิ่มความแม่นยำในการพยากรณ์ ลดโอกาสขาดทุน และลดการซื้อขายที่เกิดจากสัญญาณพยากรณ์ที่ผิดพลาด ราคาปิดรายวันของบิตคอยน์ถูกแยกด้วยเทคนิคการแยกโหมตเชิงประจักษ์ เพื่อให้ได้ฟังก์ชันโหมตภายใน (IMFs) จากนั้นเลือก IMF ที่มีความสัมพันธ์กับผลตอบแทนผ่านการวิเคราะห์สหสัมพันธ์ไขว้ และใช้เป็นตัวแปรนำเข้าสำหรับโครงข่ายประสาทเทียมแบบลึกซ้อน ซึ่งประกอบด้วย Bi-LSTM, LSTM และ Dense Layer เพื่อพยากรณ์ผลตอบแทนรายวัน ผลลัพธ์จากแบบจำลองถูกแปลงเป็นค่า Z-score และ p-value เพื่อประเมินระดับความเชื่อมั่น และใช้เกณฑ์ความเชื่อมั่น 0%-90% ในการสร้างสัญญาณซื้อขายแบบจำลองมีค่า R^2 เท่ากับ 0.55 และความแม่นยำเชิงทิศทาง 80.32% กลยุทธ์ที่ไม่ใช้เกณฑ์กรองให้ผลตอบแทนเฉลี่ย 1.50% ต่อวัน สูงกว่ากลยุทธ์ซื้อและถือ (0.163%) อย่างชัดเจน แม้การใช้เกณฑ์ความเชื่อมั่นสูงถึง 90% จะลดจำนวนการซื้อขายและผลตอบแทนเฉลี่ย แต่ผลตอบแทนยังสูงกว่ากลยุทธ์ซื้อและถือในทุกระดับความเชื่อมั่น

คำสำคัญ: การแยกโหมตเชิงประจักษ์, กลยุทธ์, ความเชื่อมั่น, สัญญาณซื้อขาย

ข้อมูลอ้างอิง: คีตวรุฬ ฝ่องแผ้ว, สมพร บันโกษา และ บำรุง พ่วงเกิด. (2568). การพยากรณ์ผลตอบแทนบิตคอยน์โดยใช้การแยกฟังก์ชันโหมตภายในร่วมกับโครงข่ายประสาทเทียมเชิงลึก และเกณฑ์ความเชื่อมั่นเพื่อสร้างสัญญาณซื้อขาย. *Procedia of Multidisciplinary Research*, 3(7), 7

บทนำ

ในช่วงทศวรรษที่ผ่านมา บิตคอยน์ (Bitcoin) ได้กลายเป็นหนึ่งในสินทรัพย์ดิจิทัลที่ได้รับความนิยมมากที่สุดในตลาดการเงินโลก ด้วยคุณลักษณะเฉพาะที่ไม่ขึ้นอยู่กับสถาบันการเงินกลาง มีระบบการกระจายศูนย์ (decentralization) และความโปร่งใสในการตรวจสอบธุรกรรมผ่านเทคโนโลยีบล็อกเชน ทำให้นักลงทุนทั่วโลกให้ความสนใจในฐานะสินทรัพย์ทางเลือกที่มีศักยภาพในการสร้างผลตอบแทนสูงในระยะยาว อย่างไรก็ตาม แม้บิตคอยน์จะสามารถสร้างผลกำไรได้ในช่วงตลาดขาขึ้น แต่ก็มีความผันผวนของราคาสูงมาก ซึ่งเป็นความท้าทายสำคัญของนักลงทุนที่ต้องเผชิญกับความเสี่ยงจากการขาดทุนในระยะสั้น โดยเฉพาะอย่างยิ่งเมื่อการตัดสินใจลงทุนอาศัยเพียงแค่อัตราดอกเบี้ยจากการวิเคราะห์ทางเทคนิคหรือการคาดการณ์ที่ขาดความแม่นยำ

เพื่อจัดการกับความผันผวนนี้ นักวิจัยได้พยายามพัฒนาแบบจำลองทางสถิติ เช่น ARIMA หรือ GARCH เพื่อพยากรณ์ราคาหรือผลตอบแทนในตลาดการเงิน แต่แบบจำลองเหล่านี้ยังมีข้อจำกัดในการจับข้อมูลที่ซับซ้อนและเปลี่ยนแปลงอย่างรวดเร็ว ด้วยเหตุนี้ การนำเทคนิคปัญญาประดิษฐ์ โดยเฉพาะการเรียนรู้เชิงลึก (Deep Learning) จึงกลายเป็นแนวทางที่ได้รับความนิยมมากขึ้น เนื่องจากสามารถเรียนรู้รูปแบบที่ซับซ้อนจากข้อมูลปริมาณมากได้อย่างมีประสิทธิภาพ

หนึ่งในโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงในการวิเคราะห์ข้อมูลอนุกรมเวลา คือโครงข่ายแบบ Long Short-Term Memory (LSTM) และ Bidirectional LSTM (Bi-LSTM) ซึ่งสามารถเรียนรู้ข้อมูลในลำดับเวลาได้ทั้งจากอดีตและอนาคตพร้อมกัน เหมาะสมอย่างยิ่งกับลักษณะข้อมูลที่เปลี่ยนแปลงตลอดเวลา เช่น ราคาบิตคอยน์ และเมื่อผสมผสานกับเทคนิคการแยกสัญญาณอย่าง Empirical Mode Decomposition (EMD) ซึ่งสามารถแยกข้อมูลออกเป็นฟังก์ชันโหมดภายใน (Intrinsic Mode Functions: IMFs) ที่สะท้อนความถี่ในช่วงต่างๆ ของข้อมูล ก็จะช่วยให้นักวิเคราะห์สามารถดึงสัญญาณที่มีความสำคัญออกมาใช้เป็นตัวแปรนำเข้าได้อย่างมีประสิทธิภาพมากขึ้น

อย่างไรก็ตาม แม้แบบจำลองจะสามารถพยากรณ์ผลตอบแทนได้ในระดับที่น่าพึงพอใจ แต่การนำผลพยากรณ์ไปใช้ประกอบการตัดสินใจซื้อขายโดยตรงอาจนำไปสู่ความเสี่ยงที่สำคัญ นั่นคือ การ "ตอบสนองต่อผลพยากรณ์ที่ผิดพลาด" โดยเฉพาะในสภาวะตลาดที่มีความไม่แน่นอนสูง หากไม่มีการประเมินระดับความเชื่อมั่นของค่าพยากรณ์เหล่านั้น นักลงทุนอาจดำเนินการซื้อขายตามสัญญาณที่คลาดเคลื่อน ซึ่งส่งผลให้เกิดการขาดทุนอย่างไม่จำเป็น

ด้วยเหตุนี้ งานวิจัยนี้จึงเสนอแนวทางใหม่ที่ไม่ได้หยุดเพียงแคการพัฒนาแบบจำลองพยากรณ์ผลตอบแทนบิตคอยน์ แต่ยังต่อยอดด้วยการแปลงค่าผลพยากรณ์ให้เป็นระดับความเชื่อมั่น (confidence level) โดยอาศัยค่า Z-score และ p-value เพื่อกรองเฉพาะผลพยากรณ์ที่มีความมั่นใจสูง ก่อนนำไปสร้างสัญญาณซื้อขายในรูปแบบ Long, Short หรือ No Position ซึ่งคาดว่าจะช่วยลดการตอบสนองต่อค่าพยากรณ์ที่ผิดพลาด และลดโอกาสในการขาดทุนจากกลยุทธ์ที่ไม่แม่นยำได้อย่างมีระบบ

การทบทวนวรรณกรรม

บิตคอยน์ (Bitcoin) เป็นหนึ่งในสินทรัพย์ดิจิทัลที่ได้รับความนิยมจากนักลงทุนทั่วโลก เนื่องจากมีศักยภาพในการสร้างผลตอบแทนสูงในระยะยาว อย่างไรก็ตาม ราคาของบิตคอยน์มีลักษณะผันผวนสูงและเปลี่ยนแปลงอย่างรวดเร็ว ซึ่งก่อให้เกิดความเสี่ยงต่อการลงทุนอย่างมีนัยสำคัญ (Katsiampa, 2017) ด้วยเหตุนี้ นักวิจัยและนักวิเคราะห์ทางการเงินจึงได้พัฒนาแบบจำลองเพื่อพยากรณ์พฤติกรรมราคาหรือผลตอบแทนของบิตคอยน์ โดยเฉพาะการนำเทคนิคขั้นสูงมาใช้เพื่อจัดการกับข้อมูลที่ไม่เป็นเชิงเส้นและไม่อยู่กับที่

หนึ่งในเทคนิคที่ได้รับความนิยมในการแยกองค์ประกอบย่อยของสัญญาณราคา คือ Empirical Mode Decomposition (EMD) ซึ่งถูกพัฒนาโดย Huang et al. (1998) เพื่อแยกข้อมูลออกเป็นชุดของฟังก์ชันโหมดภายใน (Intrinsic Mode Functions: IMFs) ที่สะท้อนความถี่ในย่านต่างๆ ของข้อมูล ทำให้สามารถวิเคราะห์และตีความโครงสร้างของข้อมูลได้ลึกซึ้งยิ่งขึ้น และสามารถใช้ในการตั้งพารามิเตอร์ที่มีนัยสำคัญสำหรับการพยากรณ์ผลตอบแทน

ในด้านการเรียนรู้ของเครื่องแบบลึก โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) และ Bidirectional LSTM (Bi-LSTM) ได้รับความนิยมอย่างแพร่หลายในงานพยากรณ์ข้อมูลอนุกรมเวลา เนื่องจากสามารถจัดการกับลำดับข้อมูลที่มีการเปลี่ยนแปลงแบบไม่แน่นอนได้ดี โดย LSTM มีโครงสร้างหน่วยความจำที่สามารถรักษาข้อมูลในระยะยาว ขณะที่ Bi-LSTM สามารถเรียนรู้ข้อมูลจากทั้งอดีตและอนาคตภายในลำดับเดียวกัน จึงมีศักยภาพในการจับรูปแบบเชิงลึกที่ซ่อนอยู่ในข้อมูล (Hochreiter & Schmidhuber, 1997; Schuster & Paliwal, 1997)

อย่างไรก็ตาม การนำผลพยากรณ์จากแบบจำลองไปใช้ในการตัดสินใจลงทุนโดยตรง อาจเสี่ยงต่อความผิดพลาด หากไม่สามารถประเมินระดับความเชื่อมั่นของผลพยากรณ์ได้อย่างเหมาะสม ดังนั้น จึงมีการประยุกต์ค่า Z-score และ p-value เพื่อประเมินระดับความเชื่อมั่นของค่าที่พยากรณ์ได้ ซึ่งช่วยให้สามารถกรองเฉพาะผลพยากรณ์ที่มีความน่าเชื่อถือ และนำไปสู่การตัดสินใจที่มีความเสี่ยงต่ำลง (Brownlee, 2017; Zhang et al., 2021)

ท้ายที่สุด เพื่อประเมินประสิทธิภาพของกลยุทธ์ที่พัฒนาขึ้น จึงมีการเปรียบเทียบกับกลยุทธ์พื้นฐาน เช่น การซื้อและถือครอง (Buy and Hold) โดยใช้ตัวชี้วัดด้านผลตอบแทน ความผันผวน ความแม่นยำ และ Maximum Drawdown ซึ่งเป็นเกณฑ์สำคัญในการวัดความสามารถของกลยุทธ์ในการจัดการความเสี่ยงและสร้างผลตอบแทนที่เหมาะสมในสภาวะตลาดที่ไม่แน่นอน

สมมติฐานการวิจัย

- 1) แบบจำลองโครงข่ายประสาทเทียมเชิงลึกที่พัฒนาโดยใช้ฟังก์ชันโหมดภายใน (IMFs) เป็นตัวแปรนำเข้า สามารถพยากรณ์ผลตอบแทนรายวันของบิตคอยน์ได้อย่างมีประสิทธิภาพ โดยให้ค่าความแม่นยำและค่าตัวชี้วัดประสิทธิภาพดีกว่าค่าเฉลี่ยแบบสุ่ม
- 2) การใช้สัญญาณซื้อขายที่ได้จากแบบจำลองสามารถลดโอกาสขาดทุน และเพิ่มอัตราผลตอบแทนเฉลี่ยได้ดีกว่า เมื่อเปรียบเทียบกับกลยุทธ์ซื้อและถือครอง (Buy-and-Hold)
- 3) การคัดกรองผลพยากรณ์ด้วยระดับความเชื่อมั่น (Confidence Level) สามารถลดจำนวนสัญญาณซื้อขายที่เกิดจากผลพยากรณ์ที่คลาดเคลื่อนได้อย่างมีประสิทธิภาพ และช่วยเพิ่มประสิทธิภาพเชิงความแม่นยำของกลยุทธ์โดยรวม

วิธีดำเนินการวิจัย

งานวิจัยนี้มีวัตถุประสงค์หลักในการประเมินประสิทธิภาพของกลยุทธ์การลงทุนที่พัฒนาจากแบบจำลองพยากรณ์ผลตอบแทนบิตคอยน์ โดยเปรียบเทียบกับกลยุทธ์พื้นฐานแบบซื้อและถือครอง (Buy and Hold) ทั้งนี้ การดำเนินการวิจัยสามารถแบ่งออกเป็น 2 ส่วนหลัก ได้แก่ 1) การพัฒนาแบบจำลองพยากรณ์ และ 2) วัดประสิทธิภาพของกลยุทธ์การลงทุนที่ได้จากแบบจำลอง

การพัฒนาแบบจำลองพยากรณ์ผลตอบแทน

- 1) รวบรวมและเตรียมข้อมูล ดึงมาข้อมูลราคาปิดรายวันจากฐานข้อมูล Yahoo Finance ครอบคลุมช่วงเวลาตั้งแต่วันที่ 1 มกราคม พ.ศ.2562 (2019) ถึงวันที่ 31 มีนาคม พ.ศ.2568 (2025) และคำนวณผลตอบแทนในรูปแบบ Logarithmic Return
- 2) สกัดและเลือกตัวแปรนำเข้า (Feature Selection) ใช้เทคนิค Empirical Mode Decomposition (EMD) เพื่อแยกราคาปิดออกเป็นฟังก์ชันโหมดภายใน (IMFs) จากนั้นนำ IMF ที่มีความสัมพันธ์เชิงเวลา (cross-correlation) กับผลตอบแทนมาใช้เป็นตัวแปรนำเข้า ร่วมกับผลตอบแทน
- 3) สร้างชุดข้อมูลนำเข้าแบบจำลอง เพื่อให้แบบจำลองสามารถเรียนรู้ลำดับเวลาได้อย่างมีประสิทธิภาพ ข้อมูลถูกปรับขนาดด้วย StandardScaler ให้อยู่ในรูปแบบการแจกแจงปกติมาตรฐาน จากนั้นจัดโครงสร้างให้อยู่ในรูปแบบลำดับเวลา โดยใช้ข้อมูลย้อนหลัง 14 วันเป็นอินพุต (X) เพื่อพยากรณ์ผลตอบแทนในวันถัดไป (y) พร้อมแบ่งข้อมูลเป็นชุดฝึกสอน 70% และชุดทดสอบ 30%
- 4) สร้างแบบจำลองเชิงลึก แบบจำลองถูกออกแบบให้ประกอบด้วย 4 กลุ่มหลัก ได้แก่

- Bidirectional LSTM จำนวน 2 ชั้น เพื่อให้แบบจำลองเรียนรู้ลำดับข้อมูลทั้งจากอดีตและอนาคต
- LSTM ชั้นเดียว สำหรับกลั่นกรองลักษณะของข้อมูลลำดับเวลาเพิ่มเติม
- Dense Layers จำนวน 2 ชั้น พร้อมฟังก์ชันกระตุ้น LeakyReLU ซึ่งช่วยรองรับความไม่เป็นเชิงเส้นของข้อมูล และลดปัญหา vanishing gradient
- Dense สุดท้าย (Output Layer) พร้อมฟังก์ชันกระตุ้น Linear เพื่อให้ผลลัพธ์อยู่ในรูปของค่าต่อเนื่อง เหมาะกับปัญหาการพยากรณ์ (Regression)

Model: "my_BiLSTM_model"

Layer (type)	Output Shape	Param #
bidirectional (Bidirectional)	(None, 14, 128)	35,840
dropout (Dropout)	(None, 14, 128)	0
bidirectional_1 (Bidirectional)	(None, 14, 128)	98,816
dropout_1 (Dropout)	(None, 14, 128)	0
lstm_2 (LSTM)	(None, 64)	49,408
dropout_2 (Dropout)	(None, 64)	0
dense (Dense)	(None, 64)	4,160
leaky_re_lu (LeakyReLU)	(None, 64)	0
dropout_3 (Dropout)	(None, 64)	0
dense_1 (Dense)	(None, 64)	4,160
leaky_re_lu_1 (LeakyReLU)	(None, 64)	0
dropout_4 (Dropout)	(None, 64)	0
dense_2 (Dense)	(None, 1)	65

Total params: 192,449 (751.75 KB)
 Trainable params: 192,449 (751.75 KB)
 Non-trainable params: 0 (0.00 B)

ภาพที่ 1 โครงสร้างแบบจำลองโครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์ผลตอบแทนรายวัน

โดยกำหนดค่าไฮเปอร์พารามิเตอร์ ดังตารางที่ 1

ตารางที่ 1 ค่าไฮเปอร์พารามิเตอร์

องค์ประกอบการฝึก	ค่าไฮเปอร์พารามิเตอร์
Optimizer	Adam (learning_rate = 0.0001, weight_decay = 0.00001)
Loss Function	Huber loss (delta = 0.5)
Early Stopping	patience = 30
Learning Rate Scheduler	factor = 0.5, patience = 5, min_lr = 0.000001
Epochs	500
Batch Size	32

จากตารางที่ 1 การฝึกแบบจำลอง ใช้ Optimizer แบบ Adam โดยกำหนด learning rate ที่ 0.0001 และ weight decay ที่ 0.00001 เพื่อควบคุมการปรับน้ำหนักอย่างมีเสถียรภาพ ฟังก์ชันความสูญเสียเลือกใช้ Huber loss ซึ่งมีความทนทานต่อค่าผิดปกติได้ดีกว่า MSE แบบดั้งเดิม สำหรับการป้องกัน overfitting มีการใช้ Early Stopping เมื่อ validation loss ไม่ลดลงภายใน 30 รอบ และใช้ Learning Rate Scheduler เพื่อลดค่า learning rate แบบอัตโนมัติหาก performance ไม่ดีขึ้นภายใน 5 รอบ โดยจะลดลงครึ่งหนึ่งและหยุดลดเมื่อถึงค่า min_lr ที่ 0.000001 การฝึกใช้จำนวนรอบ 500 ครั้งต่อการฝึก และใช้ขนาดชุดข้อมูลย่อย (batch size) เท่ากับ 32

5) ประเมินประสิทธิภาพแบบจำลอง ผลลัพธ์จากการฝึกแบบจำลองจะถูกประเมินด้วยค่าความคลาดเคลื่อน MAE, MSE, และ R^2

การวัดประสิทธิภาพของกลยุทธ์การลงทุน

1) จำนวนระดับความเชื่อมั่นจากผลพยากรณ์

แปลงผลพยากรณ์ให้เป็นคะแนนมาตรฐาน (Z-score) แล้วคำนวณค่า p-value แบบสองด้าน ได้จากสมการที่ 1 และ 2 เพื่อสามารถกำหนดเกณฑ์ความเชื่อมั่น

$$Z = \frac{\hat{y}_i - \mu}{\sigma} \quad (1)$$

$$p = 2(1 - \Phi(|Z|)) \quad (2)$$

โดยที่

\hat{y}_i คือ ค่าที่พยากรณ์ได้

μ, σ คือ ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานของผลพยากรณ์

Φ คือ ฟังก์ชันการแจกแจงสะสมมาตรฐานของการแจกแจงแบบปกติ

2) สร้างสัญญาณซื้อขาย

โดยกำหนด Signal = 1 คือ Long position, Signal = -1 คือ Short position และ Signal = 0 คือ No position

คำนวณสัญญาณซื้อขายได้จากสมการดังนี้

$$Signal_t = \begin{cases} 1 & \text{if } \hat{y}_t > 0 \text{ and } p_t < \alpha \\ -1 & \text{if } \hat{y}_t < 0 \text{ and } p_t < \alpha \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

โดยที่

\hat{y}_t คือ ค่าผลพยากรณ์ผลตอบแทน ณ วันที่ t

p_t คือ ค่า p-value ณ วันที่ t ที่ได้จากการแปลง Z-score

α คือ ค่าระดับนัยสำคัญที่กำหนดเพื่อควบคุมเกณฑ์ความเชื่อมั่น

กำหนดเกณฑ์ความเชื่อมั่นไว้ตั้งแต่ 0%, 10% จนถึง 90% โดยที่ $\alpha = 1$ สำหรับเกณฑ์ 0% และ $\alpha = 0.1$ สำหรับเกณฑ์ 90%

3) จำนวนผลตอบแทนกลยุทธ์

เมื่อได้สัญญาณซื้อขายสำหรับทุกกลยุทธ์ตามเกณฑ์ที่กำหนด จึงดำเนินการคำนวณผลตอบแทนรายวันได้ตามสมการดังนี้

$$r_t^{strategy} = Signal_t \cdot r_t \quad (4)$$

โดยที่

$r_t^{strategy}$ คือ ผลตอบแทนของกลยุทธ์ ณ วันที่ t

r_t คือ ผลตอบแทนที่แท้จริง ณ วันที่ t

4) การประเมินประสิทธิภาพกลยุทธ์

เปรียบเทียบประสิทธิภาพของกลยุทธ์จากแบบจำลองกับการซื้อและถือครองด้วยตัวชี้วัดดังนี้

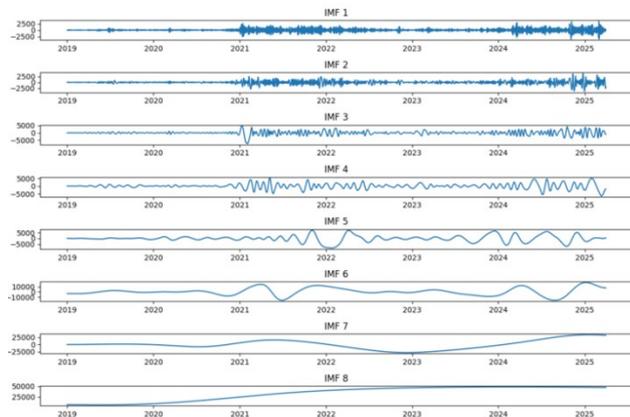
ผลตอบแทนเฉลี่ยต่อวัน, ค่าความผันผวน (Standard Deviation), Maximum Drawdown, Sharpe Ratio และ ความแม่นยำสำหรับกลยุทธ์จากแบบจำลองทุกเกณฑ์ความเชื่อมั่น

ผลการวิจัย

การนำเสนอผลการวิจัยแบ่งออกเป็น 2 ส่วน ได้แก่ 1) ผลการพัฒนาแบบจำลองพยากรณ์ และ 2) ประสิทธิภาพของกลยุทธ์การลงทุนที่ได้จากแบบจำลอง

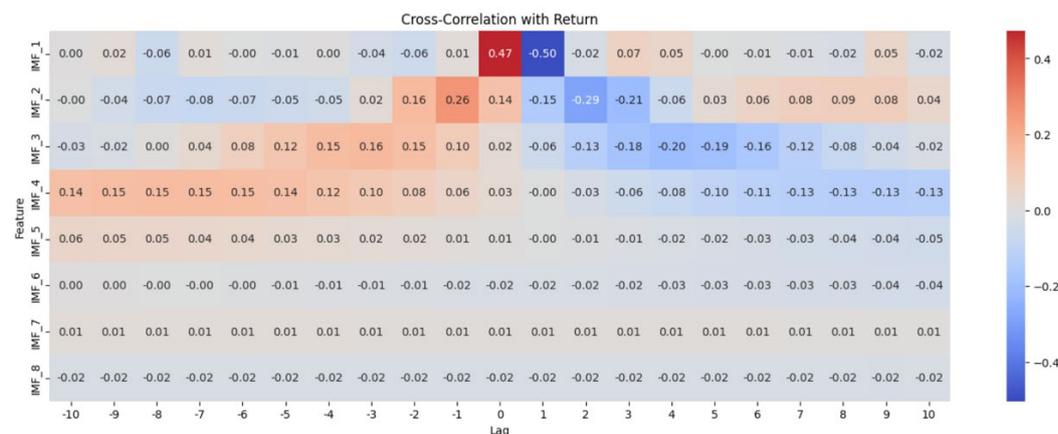
ผลการพัฒนาแบบจำลองพยากรณ์

ข้อมูลราคาปิดรายวันของบิตคอยน์ระหว่างปี 2019-2025 ถูกแปลงเป็นผลตอบแทนแบบ Log Return และแยกองค์ประกอบด้วยเทคนิค Empirical Mode Decomposition (EMD) ได้ IMF จำนวน 8 ชุด ดังภาพที่ 2



ภาพที่ 2 กราฟแสดงสัญญาณย่อย (IMFs)

เพื่อคัดเลือก IMF เป็นตัวแปรนำเข้าที่มีความสัมพันธ์เชิงเวลา กับผลตอบแทน ได้ทำการวิเคราะห์ค่า Cross-Correlation ระหว่างแต่ละ IMF กับผลตอบแทนในช่วง 10 วันย้อน จนถึง 10 วันข้างหน้า ดังภาพที่ 3



ภาพที่ 3 Heatmap แสดงค่า Cross-Correlation

จากภาพที่ 3 พบว่า IMF1, IMF2, IMF3 และ IMF4 มีค่าสหสัมพันธ์ที่เด่นชัด จึงได้รับการคัดเลือกเป็นตัวแปรนำเข้าสำหรับแบบจำลอง ร่วมกับผลตอบแทนของบิตคอยน์ จากนั้นปรับขนาดชุดข้อมูลนำเข้า (StandardScale) และจัดโครงสร้างให้อยู่ในรูปลำดับเวลา โดยใช้ข้อมูลย้อนหลัง 14 วันเป็นอินพุต (X) เพื่อพยากรณ์ผลตอบแทนในวันถัดไป (y) พร้อมแบ่งข้อมูลเป็นชุดฝึกสอน 70% และชุดทดสอบ 30%

ในขั้นต่อไป ฝึกแบบจำลองด้วยข้อมูลฝึกสอนและประเมินประสิทธิภาพด้วยข้อมูลทดสอบ ผลการประเมินแสดงในภาพที่ 2

Metric Value	
R ² Score	0.555278
Mean Absolute Error (MAE)	0.012405
Mean Squared Error (MSE)	0.000289

ภาพที่ 4 ตารางแสดงตัวชี้วัดประสิทธิภาพแบบจำลอง

ค่า R² แสดงว่าแบบจำลองสามารถอธิบายความแปรปรวนของผลตอบแทนได้ 55.52% และให้ค่าความคลาดเคลื่อนเฉลี่ยอยู่ในระดับต่ำ แสดงถึงความสามารถในการพยากรณ์ผลตอบแทนรายวันได้อย่างแม่นยำ

ประสิทธิภาพของกลยุทธ์การลงทุนจากผลพยากรณ์

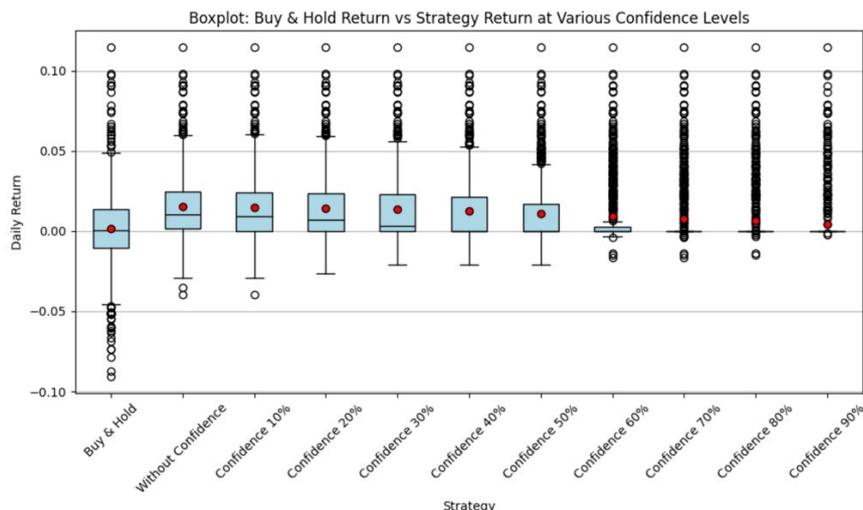
ผลพยากรณ์จากแบบจำลองถูกแปลงเป็นค่า Z-score และคำนวณค่า p-value เพื่อใช้ประเมินระดับความเชื่อมั่นของสัญญาณซื้อขาย โดยกำหนดเกณฑ์ความเชื่อมั่นตั้งแต่ 0% ถึง 90% เพื่อกรองสัญญาณที่มีความน่าเชื่อถือ และสร้างสัญญาณซื้อขาย จากนั้นกลยุทธ์จากแบบจำลองแต่ละระดับเกณฑ์ความเชื่อมั่นถูกนำมาเปรียบเทียบกับกลยุทธ์พื้นฐานแบบซื้อและถือครอง (Buy & Hold)

Strategy	P value	Accuracy	Mean_Return	Std_Dev	Sharpe_Ratio	Max_Drawdown
Buy & Hold	-	-	0.163%	2.552%	0.064	-26.182%
Confidence 0%	1.0	80.32%	1.504%	2.068%	0.727	-4.221%
Confidence 10%	0.9	84.18%	1.484%	2.043%	0.726	-4.190%
Confidence 20%	0.8	87.32%	1.437%	2.022%	0.710	-4.190%
Confidence 30%	0.7	89.81%	1.369%	2.021%	0.677	-3.283%
Confidence 40%	0.6	92.64%	1.240%	2.023%	0.613	-2.896%
Confidence 50%	0.5	93.44%	1.093%	1.994%	0.548	-2.753%
Confidence 60%	0.4	94.18%	0.918%	1.929%	0.476	-1.651%
Confidence 70%	0.3	94.48%	0.745%	1.829%	0.407	-1.651%
Confidence 80%	0.2	95.61%	0.624%	1.738%	0.359	-1.454%
Confidence 90%	0.1	97.22%	0.442%	1.533%	0.288	-0.244%

ภาพที่ 5 ตารางเปรียบเทียบความแม่นยำ ผลตอบแทน และความเสี่ยงของแต่ละกลยุทธ์

จากภาพที่ 5 ผลการทดลองพบว่า กลยุทธ์ที่ไม่ใช้การกรองความเชื่อมั่นให้ความแม่นยำ 80.32% และให้ผลตอบแทนเฉลี่ยต่อวันสูงสุดที่ 1.504% พร้อม Sharpe Ratio สูงสุดที่ 0.727 ขณะที่การเพิ่มระดับความเชื่อมั่นเป็น 90% ช่วยเพิ่มความแม่นยำเป็น 97.22% แต่ผลตอบแทนเฉลี่ยลดลงเหลือ 0.442% ต่อวัน แสดงถึงการแลกเปลี่ยนระหว่างความแม่นยำและโอกาสสร้างผลตอบแทน

นอกจากนี้ ความเสี่ยงของกลยุทธ์วัดจาก Maximum Drawdown พบว่า กลยุทธ์แบบจำลองที่ใช้ความเชื่อมั่น 90% มี Max Drawdown ต่ำสุดเพียง -0.244% เทียบกับ -26.182% ของกลยุทธ์ซื้อและถือ สะท้อนความสามารถในการลดความเสี่ยงอย่างมีประสิทธิภาพ



ภาพที่ 6 Boxplot แสดงการกระจายตัวของผลตอบแทนรายวันในแต่ละกลยุทธ์

จากภาพที่ 6 แสดงให้เห็นว่ากลยุทธ์ซื้อและถือครองมีการกระจายตัวของผลตอบแทนที่กว้างทั้งในด้านบวกและด้านลบ สะท้อนความผันผวนของผลลัพธ์ในระดับสูง ในขณะที่กลยุทธ์ที่ได้จากแบบจำลองแสดงให้เห็นถึงการกระจายตัวด้านลบที่ค่อย ๆ ลดลงเมื่อระดับความเชื่อมั่นเพิ่มขึ้น ซึ่งบ่งชี้ถึงการลดความเสี่ยงจากสัญญาณพยากรณ์ที่คลาดเคลื่อน นอกจากนี้ ค่ากลางและค่าเฉลี่ยของผลตอบแทนจะอยู่ในระดับสูงที่สุดเมื่อใช้เกณฑ์ความเชื่อมั่นต่ำ และมีแนวโน้มลดลงตามลำดับความเข้มงวดของเกณฑ์ความเชื่อมั่นที่เพิ่มขึ้น แสดงถึงการแลกเปลี่ยนระหว่างผลตอบแทนและความมั่นใจของสัญญาณ อย่างไรก็ตาม กลยุทธ์แต่ละระดับความเชื่อมั่นอาจเหมาะกับนักลงทุนที่มีระดับการยอมรับความเสี่ยงที่แตกต่างกัน

สรุปและอภิปรายผลการวิจัย

จากการทดสอบแบบจำลองโครงข่ายประสาทเทียมเชิงลึกที่พัฒนาโดยใช้ฟังก์ชันโหนดภายใน (IMFs) เป็นตัวแปรนำเข้า พบว่าแบบจำลองสามารถพยากรณ์ผลตอบแทนรายวันของบิตคอยน์ได้อย่างมีประสิทธิภาพ โดยให้ค่าความแม่นยำ 80.32% และสามารถอธิบายความแปรปรวนของผลตอบแทนได้ถึง 55.52% ($R^2 = 0.5552$) พร้อมค่า MAE และ MSE ที่อยู่ในระดับต่ำ สอดคล้องกับสมมติฐานที่ 1 ที่ระบุว่าแบบจำลองสามารถให้ค่าตัวชี้วัดประสิทธิภาพดีกว่าค่าเฉลี่ยแบบสุ่ม และสามารถเรียนรู้รูปแบบจากข้อมูลได้อย่างมีนัยสำคัญ

เมื่อเปรียบเทียบกลยุทธ์การลงทุนที่ได้จากแบบจำลองกับกลยุทธ์ซื้อและถือครอง พบว่า กลยุทธ์แบบจำลองให้ผลตอบแทนเฉลี่ยรายวันสูงกว่าในทุกระดับ โดยเฉพาะกรณีไม่กรองความเชื่อมั่น ซึ่งให้ผลตอบแทนเฉลี่ย 1.53% ต่อวัน เทียบกับ การซื้อและถือครอง ที่ให้เพียง 0.163% ต่อวัน และยังลด Maximum Drawdown ได้อย่างมีประสิทธิภาพ (จาก -26.18% เหลือเพียง -4.22%) สนับสนุนสมมติฐานที่ 2 ว่าการใช้สัญญาณจากแบบจำลองสามารถลดโอกาสขาดทุน และเพิ่มอัตราผลตอบแทนได้ดีกว่า

สำหรับสมมติฐานที่ 3 ผลการทดลองพบว่า เมื่อเพิ่มระดับความเชื่อมั่นจาก 0% ถึง 90% ความแม่นยำของกลยุทธ์เพิ่มขึ้นจาก 80.32% เป็น 97.22% ขณะที่ความผันผวนและ Maximum Drawdown ลดลงอย่างต่อเนื่อง แสดงให้เห็นว่าการคัดกรองค่าพยากรณ์ด้วยระดับความเชื่อมั่นช่วยลดสัญญาณที่มาจากค่าพยากรณ์ที่ไม่แม่นยำ และเพิ่มความน่าเชื่อถือของกลยุทธ์ในภาพรวมได้จริง อย่างไรก็ตาม ผลตอบแทนเฉลี่ยต่อวันมีแนวโน้มลดลงตามระดับความเชื่อมั่นที่เพิ่มขึ้น ซึ่งสะท้อนถึงการแลกเปลี่ยนระหว่าง “ความแม่นยำ” และ “โอกาสสร้างผลตอบแทน”

โดยสรุป กลยุทธ์การลงทุนที่พัฒนาจากแบบจำลองในงานวิจัยนี้มีประสิทธิภาพเหนือกว่ากลยุทธ์พื้นฐานทั้งในด้านผลตอบแทน ความเสี่ยง และความแม่นยำ โดยระดับความเชื่อมั่นในการคัดกรองสามารถนำมาใช้เป็นเครื่องมือในการออกแบบกลยุทธ์ที่เหมาะสมกับผู้ลงทุนแต่ละกลุ่มตามระดับการยอมรับความเสี่ยงได้อย่างยืดหยุ่น

ข้อเสนอแนะที่ได้รับจากการวิจัย

จากผลการวิจัยที่แสดงให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมเชิงลึกที่พัฒนาขึ้นโดยใช้ฟังก์ชันโหมดภายใน (IMFs) จากกระบวนการแยกสัญญาณด้วยเทคนิค Empirical Mode Decomposition (EMD) สามารถพยากรณ์ผลตอบแทนรายวันของบิตคอยน์ได้อย่างมีประสิทธิภาพ และเมื่อใช้ผลพยากรณ์เหล่านี้สร้างกลยุทธ์การซื้อขายร่วมกับการควบคุมระดับความเชื่อมั่น ผลลัพธ์ที่ได้แสดงให้เห็นถึงประสิทธิภาพที่เหนือกว่ากลยุทธ์พื้นฐานในหลากหลายมิติ ทั้งด้านผลตอบแทน ความเสี่ยง และความแม่นยำ ดังนั้นจึงสามารถเสนอแนะแนวทางการนำผลการศึกษานี้ไปใช้ประโยชน์ได้ทั้งในเชิงวิชาการและเชิงปฏิบัติดังต่อไปนี้

ในด้านเชิงวิชาการ งานวิจัยนี้สนับสนุนแนวคิดที่ว่า การแยกสัญญาณเพื่อวิเคราะห์องค์ประกอบภายในของข้อมูลสามารถช่วยให้แบบจำลองเรียนรู้รูปแบบของผลตอบแทนได้ดีขึ้น โดยเฉพาะเมื่อผสมผสานกับกระบวนการคัดเลือกฟังก์ชันโหมดที่มีความสัมพันธ์เชิงเวลา (cross-correlation) กับผลตอบแทน ซึ่งช่วยลดปัญหา overfitting และเพิ่มความแม่นยำของแบบจำลองได้อย่างมีนัยสำคัญ นักวิจัยในอนาคตสามารถนำแนวทางนี้ไปประยุกต์ใช้กับการพยากรณ์สินทรัพย์ทางการเงินประเภทอื่น เช่น หุ้น ทองคำ หรือดัชนีตลาด เพื่อศึกษาว่ากลยุทธ์ที่ใช้ IMF ร่วมกับโมเดลเชิงลึกสามารถใช้ได้อย่างมีประสิทธิภาพในบริบทอื่นหรือไม่

ในด้านเชิงปฏิบัติ ผลการวิจัยแสดงให้เห็นว่าการนำระดับความเชื่อมั่น (confidence level) มาช่วยกรองค่าพยากรณ์ก่อนสร้างสัญญาณซื้อขายสามารถลดโอกาสการซื้อขายผิดพลาดจากค่าพยากรณ์ที่ไม่แม่นยำได้จริง โดยที่กลยุทธ์ในทุกระดับความเชื่อมั่นยังให้ผลตอบแทนเฉลี่ยสูงกว่ากลยุทธ์พื้นฐานแบบซื้อและถือครอง ทั้งนี้ ผู้ใช้งานหรือผู้ลงทุนสามารถเลือกใช้ระดับความเชื่อมั่นให้สอดคล้องกับระดับความเสี่ยงที่ยอมรับได้ เช่น หากเป็นนักลงทุนที่เน้นการเติบโต อาจเลือกใช้กลยุทธ์ที่ไม่กรอง (0%) เพื่อเพิ่มโอกาสทำกำไรสูงสุด แต่หากเป็นนักลงทุนที่เน้นความปลอดภัยและเสถียรภาพของพอร์ต อาจเลือกใช้กลยุทธ์ที่กรองความเชื่อมั่นในระดับสูง เช่น 80-90% เพื่อลดความเสี่ยงจากสัญญาณที่อาจคลาดเคลื่อน

ดังนั้น ข้อเสนอสำคัญจากงานวิจัยนี้คือ การออกแบบกลยุทธ์ที่มีประสิทธิภาพไม่จำเป็นต้องพึ่งพาเพียงความแม่นยำของแบบจำลองเพียงอย่างเดียว แต่สามารถเพิ่มประสิทธิภาพเชิงระบบได้ผ่านการกรองและควบคุมการตัดสินใจจากผลพยากรณ์ ซึ่งแนวคิดนี้สามารถนำไปต่อยอดเป็นระบบการลงทุนอัตโนมัติที่ยืดหยุ่นตามระดับความเสี่ยงของผู้ใช้งานแต่ละกลุ่มได้อย่างมีประสิทธิภาพ

ข้อเสนอแนะในการวิจัยครั้งต่อไป

- 1) งานวิจัยนี้ใช้ข้อมูลของบิตคอยน์เป็นกรณีศึกษา ซึ่งมีลักษณะเฉพาะ เช่น ความผันผวนสูงและการเคลื่อนไหวที่ไม่เป็นเชิงเส้น (nonlinear and non-stationary) จึงควรทดลองนำแบบจำลองไปประยุกต์ใช้กับสินทรัพย์อื่น เช่น หุ้นรายตัว ดัชนีตลาด หรือทองคำ เพื่อประเมินความสามารถในการพยากรณ์ในบริบทที่แตกต่างกัน
- 2) แม้ EMD จะเป็นเทคนิคที่มีประสิทธิภาพในการแยกข้อมูลที่ไม่เป็นเชิงเส้นและไม่อยู่กับที่ แต่ยังมีเทคนิคอื่นที่น่าสนใจ เช่น Wavelet Transform หรือ Variational Mode Decomposition (VMD) ที่อาจให้คุณภาพของฟีเจอร์นำเข้าไปที่แตกต่างกัน การศึกษาเปรียบเทียบประสิทธิภาพของเทคนิคเหล่านี้จะช่วยยืนยันความเหมาะสมของวิธีที่เลือกไว้
- 3) แบบจำลองในงานวิจัยนี้ใช้สถาปัตยกรรม Bi-LSTM ร่วมกับ LSTM และ Dense Layer ซึ่งให้ผลลัพธ์ที่ดี อย่างไรก็ตาม อาจทดลองใช้สถาปัตยกรรมใหม่ เช่น Transformer-based models, Temporal Convolutional Networks (TCNs) หรือ Attention mechanisms เพื่อเปรียบเทียบผลลัพธ์และเพิ่มประสิทธิภาพของการพยากรณ์

4) งานวิจัยนี้ใช้ข้อมูลย้อนหลังในการประเมินผล หากมีโอกาส ควรทดลองใช้กลยุทธ์ในสภาพแวดล้อมจำลองหรือทดสอบแบบ Real-time ด้วยข้อมูล Streaming เพื่อประเมินความเสถียรของกลยุทธ์ในภาวะตลาดที่เปลี่ยนแปลงอย่างต่อเนื่อง

เอกสารอ้างอิง

- Arslan, S. (2024). Bitcoin price prediction using sentiment analysis and empirical mode decomposition. *Computational Economics*, 1-22.
- Bouoiyour, J., Selmi, R., Tiwari, A. K., & Olayeni, O. R. (2016). What drives Bitcoin price?. *Economics Bulletin*, 36(2), 843-850.
- Korstanje, J. (2021). *Advanced Forecasting with Python: With State-of-the-Art-Models Including LSTMs, Facebook's Prophet, and Amazon's DeepAR*. Apress. Maisons Alfort, France.
- Latif, N., Selvam, J. D., Kapse, M., Sharma, V., & Mahajan, V. (2023). Comparative performance of LSTM and ARIMA for the short-term prediction of Bitcoin prices. *Australasian Accounting, Business and Finance Journal*, 17(1), 256-275.
- Mounir, N., Ouadi, H., & Jrhilifa, I. (2023). Short-term electric load forecasting using an EMD-BI-LSTM approach for smart grid energy management system. *Energy & Buildings*, 288, 113022.
- Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2019). *A comparison of ARIMA and LSTM in forecasting time series*. In 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA) (pp. 1394-1401). IEEE.
- Lane, D. M. (2003). *Introduction to statistics*. Rice University. Retrieved from <http://onlinestatbook.com/2/index.html>.
- Vassiliadis, S., Papadopoulos, P., Rangoussi, M., Konieczny, T., & Gralewski, J. (2017). Bitcoin value analysis based on cross-correlations. *Journal of Internet Banking and Commerce*, 22(S7), 1-12.
- Zakamulin, V. (2021). *Simple Return or Log Return?*. Retrieved from https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3773043.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.



Copyright: © 2025 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).