

การพัฒนาอัลกอริทึมการจัดการพอร์ตแบบ Event-Driven สำหรับกลยุทธ์ Funding Rate Arbitrage เพื่อเพิ่มประสิทธิภาพ Sharpe Ratio ในตลาดสกุลเงินดิจิทัล

Development of an Event-Driven Portfolio Management Algorithm for Funding Rate Arbitrage Strategies to Enhance Sharpe Ratio in Cryptocurrency Markets

จักรพันธ์ ฤทธิผล¹ และชัยพร เขมะภาคะพันธ์^{1*}

Chakrabandh Rittiplang¹ and Chaiyaporn Khemapatapan^{1*}

Received 26 March 2026, Revised 19 May 2026, Accepted 25 May 2026

ABSTRACT

Using the Funding Rate Arbitrage strategies of cryptocurrency Perpetual Futures markets brings many of its limitations to light. When faced with market volatility, a static equal-weight solution is unable to adjust immediately. On the other hand, Machine Learning approaches rely on forecasting Funding Rate values, which are characterized by mean-reversion, and this makes it difficult to predict profitably. This research thus develops an Event-Driven Portfolio Management Algorithm using Mean-Variance Optimization and compares it with three baseline strategies: Static Equal-Weight, Ridge Regression, and XGBoost with Walk-Forward Validation. Backtesting was done on actual data from Binance Futures for eight digital assets over a four-year period. Test results show that our method achieves an annualized return of 10.97% with a Sharpe Ratio of 30.47, outpacing Static by 22.4%, while both Machine Learning baselines fail to beat Static (Cohen's d less than 0.2). Our method never lost in any single month (43 out of 43 months) with Max Drawdown of only 0.18%. Statistical significance is confirmed through 8 methods, with Monte Carlo Bootstrap P (>0) equal to 99.63%. Sensitivity analysis confirms robustness and the Breakeven Fee ranges from 5.4 to 7.3 bps at least twice the actual transaction fee.

Keywords: Event-Driven Portfolio, Funding Rate, Sharpe Ratio, XGBoost, Monte Carlo Bootstrap

บทคัดย่อ

การจัดการพอร์ตสำหรับกลยุทธ์ Funding Rate Arbitrage ในตลาด Perpetual Futures ของสกุลเงินดิจิทัลในปัจจุบัน ยังคงมีข้อจำกัดสำคัญ คือ กลยุทธ์แบบน้ำหนักคงที่ไม่สามารถตอบสนองต่อความผันผวนของตลาดได้ทันทั่วทั้งที่ ขณะที่แนวทาง Machine Learning ที่พึ่งพาการทำนายค่า Funding Rate ซึ่งมีลักษณะ Mean-Reverting ทำให้ยากต่อการคาดการณ์อย่างมีกำไร งานวิจัยนี้จึงพัฒนาอัลกอริทึม Event-Driven Portfolio แบบขับเคลื่อนด้วยเหตุการณ์ โดยใช้ Mean-Variance Optimization เปรียบเทียบกับ 3 กลยุทธ์พื้นฐาน ได้แก่ Static Equal-Weight, Ridge Regression และ XGBoost ด้วย Walk-Forward Validation ทดสอบบนข้อมูลจริงจาก Binance Futures สำหรับสินทรัพย์ 8 ตัว ในช่วง 4 ปี ผลลัพธ์แสดงว่าวิธีที่เสนอให้ผลตอบแทน 10.97% ต่อปี โดย Sharpe Ratio 30.47

^{1*} สาขาวิศวกรรมคอมพิวเตอร์ วิทยาลัยวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยธุรกิจบัณฑิตย์ แขวงทุ่งสองห้อง เขตหลักสี่ กรุงเทพฯ 10210

Computer Engineering, College of Engineering and Technology, Dhurakij Pundit University, Thung Song Hong, Lak Si, Bangkok 10210, Thailand.

* Corresponding author: Tel. 0-2954-7300 E-mail address: chaiyaporn@dpu.ac.th

ซึ่งสูงกว่าแบบ Static 22.4% ขณะที่ Machine Learning ทั้งสองไม่สามารถเอาชนะ Static ได้ (Cohen's d น้อยกว่า 0.2) วิธีที่นำเสนอไม่เคยขาดทุนรายเดือน (ผลบวก 43 จาก 43 เดือน) และมี Max Drawdown เพียง 0.18% ซึ่งนัยสำคัญ ถูกยืนยันด้วย 8 วิธีทางสถิติ โดย Monte Carlo Bootstrap P (>0) เท่ากับ 99.63% Sensitivity Analysis ซึ่งสามารถยืนยัน Robustness และ Breakeven Fee อยู่ที่ 5.4 ถึง 7.3 bps สูงกว่าค่าธรรมเนียมจริงอย่างน้อย 2 เท่า

คำสำคัญ: พอร์ตการลงทุนแบบขับเคลื่อนด้วยเหตุการณ์ อัตราปันดิ่ง อัตราส่วนชาร์ป เอ็กซ์จีบูสต์ การจำลองมอนติคาร์โลแบบบูตสตราป

บทนำ

ในช่วงหลายปีที่ผ่านมา ตลาดสกุลเงินดิจิทัลเติบโตอย่างรวดเร็ว นับตั้งแต่ Nakamoto (2008) นำเสนอ Bitcoin จนถึงปัจจุบันมีสกุลเงินดิจิทัลมากกว่า 10,000 รายการ และมูลค่าตลาดรวมของสินทรัพย์กลุ่มนี้มีขนาดมากกว่า 2.5 ล้านล้านดอลลาร์สหรัฐ (CoinGecko, 2024) โดยเฉพาะสัญญา Perpetual Futures ซึ่งเป็นสัญญาซื้อขายล่วงหน้าที่ไม่วันหมดอายุ (Hull, 2022; Akerer *et al.*, 2026) ซึ่งได้กลายมาเป็นรูปแบบที่ได้รับความนิยมสูงสุด คิดเป็นสัดส่วนมากกว่าร้อยละ 75 (Alexander *et al.*, 2020) ของธุรกรรมทั้งหมดในตลาดอนุพันธ์คริปโต

กลไกสำคัญของ Perpetual Futures คือ Funding Rate ซึ่งเป็นค่าธรรมเนียมที่เกิดขึ้นระหว่างผู้ถือสถานะ Long และ Short โดยจะมีการชำระตามช่วงเวลาที่กำหนด ซึ่งโดยทั่วไปคือทุก 8 ชั่วโมง (Binance, 2026; He *et al.*, 2022) เพื่อทำหน้าที่รักษาราคาสัญญาให้ใกล้เคียงกับราคาอ้างอิง ความแตกต่างของ Funding Rate ในแต่ละสินทรัพย์และแต่ละช่วงเวลาก่อให้เกิดโอกาสในการทำกำไรจากค่าธรรมเนียมนี้ได้ (Makarov & Schoar, 2020; Werapun *et al.*, 2025)

การจัดการพอร์ตแบบน้ำหนักคงที่ (Static Equal-Weight) มีข้อจำกัดคือไม่สามารถตอบสนองต่อการเปลี่ยนแปลงของตลาดได้ทันทั่วทั้ง ในขณะ Machine Learning (ML) ซึ่งเป็นแนวทางที่ได้รับความนิยมในตลาดการเงิน (De Prado, 2018) เช่น Ridge Regression (James *et al.*, 2023) และ XGBoost (Chen & Guestrin, 2016) แม้จะนิยมในงานวิจัยแต่ก็พึ่งพาการ "ทำนาย" (Prediction) ค่าในอนาคต ซึ่ง Funding Rate มีลักษณะเป็น Mean-Reverting ที่ยากต่อการทำนายเพื่อทำกำไร สอดคล้องกับแนวคิด

Efficient Market Hypothesis (Fama, 1970) ที่ระบุว่าในตลาดที่มีประสิทธิภาพ ข้อมูลในอดีตไม่สามารถสร้างกำไรเกินปกติได้ และ Financial Data มี Noise สูง (Bouri *et al.*, 2020)

แนวทางการจัดการพอร์ตที่ไม่เน้นการพยากรณ์ข้อมูลในอนาคต แต่ใช้การปรับน้ำหนักพอร์ตผ่าน Mean-Variance Optimization (Markowitz, 1952; Jeleskovic *et al.*, 2024) ได้รับความสนใจในตลาดสกุลเงินดิจิทัลมากขึ้น โดย Sahu *et al.* (2024) พบว่าผลการดำเนินงานของพอร์ตขึ้นอยู่กับความถี่ในการปรับสมดุลอย่างมีนัยสำคัญ จึงเกิดคำถามว่าการนำแนวทางดังกล่าวมาใช้ร่วมกับการตอบสนองต่อเหตุการณ์ในรูปแบบ Event-Driven จะสามารถช่วยเพิ่มประสิทธิภาพของกลยุทธ์การลงทุนได้หรือไม่ ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาอัลกอริทึม (algorithm) Event-Driven Portfolio Management และเปรียบเทียบกับ 3 Baseline (Static, Ridge, XGBoost) โดยได้ทดสอบกับข้อมูลจริงจาก Binance Futures จำนวน 8 สินทรัพย์ ในช่วงระยะเวลา 4 ปี และประเมินผลด้วยวิธีการทดสอบทางสถิติ 8 รูปแบบ พร้อมทั้งใช้ Bonferroni Correction เพื่อลดความเสี่ยงจากข้อผิดพลาดที่เกิดจากการทดสอบหลายครั้ง

อุปกรณ์และวิธีการ

ข้อมูลและสินทรัพย์

ข้อมูล Funding Rate ที่ได้มาจาก Binance Futures REST API (Binance, 2026) สำหรับสินทรัพย์ดิจิทัล 8 สินทรัพย์ ได้แก่ BTC, ETH, MATIC, UNI, LTC, AAVE, SUSHI และ ETC ซึ่งครอบคลุมหลากหลายกลุ่ม (Large Cap, Mid Cap, DeFi, Payment, PoW) ข้อมูลมีความถี่ทุก 8 ชั่วโมง (3 รอบ/

วัน) ในช่วง 4 ปี (ตุลาคม 2564 - ตุลาคม 2568) รวม 35,064 ชุดข้อมูล เงินทุนจำลองเริ่มต้น 100,000 USDT ค่าธรรมเนียม 0.025% ต่อ Trade Amount การพัฒนาและทดสอบดำเนินการด้วย Python 3.11 โดยใช้ scikit-learn 1.3, xgboost 2.0, SciPy 1.11 (SLSQP), NumPy 1.25, Pandas 2.1 และ Matplotlib 3.8

กลยุทธ์ที่เปรียบเทียบ 4 แบบ

กลยุทธ์ A : Static Equal-Weight น้ำหนักคงที่ 12.5% ต่อสินทรัพย์ ไม่มีการ Rebalance ตลอดระยะเวลา ใช้เป็น Naive Benchmark

กลยุทธ์ B1 : Ridge Regression Linear ML ที่มี L2 Regularization ($\alpha = 1.0$) ใช้ Walk-Forward Validation (Bailey *et al.*, 2015) โดยแบ่ง Train Window 6 เดือน จากนั้น Test 1 เดือน จากนั้น เลื่อนหน้าต่าง สัดส่วน Train:Test เท่ากับ 6:1 จำนวน 43 รอบ) ดัง Figure 1 และใช้ Softmax Weighting สำหรับจัดสรรน้ำหนัก Rebalance ทุกเดือน (James *et al.*, 2023)




Figure 1 Walk-Forward Validation: Train 6 months, Test 1 month, 43 rounds

กลยุทธ์ B2 : XGBoost Non-linear Ensemble Tree (Chen & Guestrin, 2016) $n_estimators = 100$, $max_depth = 4$, $learning_rate = 0.1$ ใช้ Walk-Forward, Softmax และ Monthly Rebalance เหมือน Ridge เพื่อเปรียบเทียบ Linear และ Non-linear อย่างเป็นธรรม

กลยุทธ์ C : Event-Driven MVO ซึ่งเป็นกลยุทธ์ที่พัฒนาขึ้นในงานวิจัยนี้ โดยใช้ Mean-Variance Optimization (Markowitz, 1952) หาน้ำหนักพอร์ตที่เพิ่ม Sharpe Ratio (Sharpe, 1966) สูงสุด ร่วมกับ Event Detection และ Adaptive Rebalancing Interval ซึ่งแตกต่างจาก Multi-Objective Optimization (Muteba Mwamba *et al.*, 2025) ซึ่งหาค่าเหมาะสม

ของหลายเป้าหมายพร้อมกันบนกรอบเวลาปรับสมดุลคงที่

Mean-Variance Optimization

PortfolioOptimizer หาน้ำหนัก w ที่เพิ่ม Sharpe Ratio สูงสุด โดยใช้ SciPy SLSQP:

$$\text{maximize } S(w) = \frac{w^T \mu}{\sqrt{w^T \Sigma w}} \quad (1)$$

$$\text{subject to: } \Sigma w_i = 1, \quad 0 \leq w_i \leq 0.40 \quad (2)$$

โดยที่ μ คือ Expected Return Vector และ Σ คือ Covariance Matrix คำนวณจากข้อมูล Funding Rate ย้อนหลัง 90 รอบ (30 วัน)

Softmax Weighting สำหรับ ML

ML ทั้งสองตัวใช้ Features 4 กลุ่มจาก Funding Rate: Moving Averages (MA₇, MA₁₄, MA₂₁), Volatility (σ_7 , σ_{14} , σ_{21}), Trend (MA₇ - MA₂₁) และ Momentum (17 Features/สินทรัพย์) แปลง Predicted Scores เป็นน้ำหนักด้วย Softmax:

$$w_i = \frac{\exp\left(\frac{s_i}{T}\right)}{\sum_j \exp\left(\frac{s_j}{T}\right)}, \quad T = 1.0 \quad (3)$$

Event Detection และ Adaptive Interval

EventHandler ใช้ Multi-Layer Filter 4 ชั้นในการตัดสินใจ Rebalance: Layer 1 - Force Rebalance หากไม่ Rebalance เกิน 45 วัน, Layer 2 - Volatility

Filter หาก $\sigma_{\text{market}} < 0.0015$ จะ Skip, Layer 3 - Adaptive Interval ปรับระยะห่างตาม Volatility (สูง >0.02 กำหนดเป็น 96 ชม., กลาง กำหนดเป็น 144 ชม., ต่ำ กำหนดเป็น 216 ชม.), Layer 4 - Weight Deviation Filter หาก $\sum |W_i^* - W_i| < 0.07$ จะ Skip Funding Rate Spike ตรวจจับเมื่อ FR เปลี่ยนเกิน 60% จาก Moving Average 21 รอบ:

$$\text{Spike} = 1 \text{ if } \frac{|FR(t) - MA_{21}|}{|MA_{21}|} > 60 \quad (4)$$

การวิเคราะห์ความเสี่ยง (Risk Metrics) เพื่อประเมินความเสี่ยงของแต่ละกลยุทธ์งานวิจัยนี้ใช้ตัวชี้วัด 4 ด้าน ดังแสดงใน Table 1

Table 1 Risk metrics used for strategy evaluation

Metric	Formula	Interpretation
Sharpe	$S = (R_p - R_f) / \sigma_p$	Return per total risk
Sortino	$S_o = (R_p - R_f) / \sigma_d$	Return per downside risk
MDD	$\max(V_p - V_t) / V_p$	Peak-to-trough loss
Calmar	$R_{\text{annual}} / \text{MDD}$	Return per drawdown

Note: R_p =mean return, R_f =risk-free rate(0), σ_p =std dev, σ_d =downside std dev

Sharpe Ratio และ Sortino Ratio ใช้วัดผลตอบแทนต่อหน่วยความเสี่ยง โดย Sharpe Ratio พิจารณาความผันผวนทั้งหมด ขณะที่ Sortino Ratio พิจารณาเฉพาะความผันผวนขาลง ซึ่งเหมาะสมกว่าสำหรับกลยุทธ์ Funding Rate Arbitrage ที่นักลงทุนกังวลเรื่องการขาดทุนมากกว่าความผันผวนจากกำไร ส่วน Maximum Drawdown วัดเหตุการณ์เลวร้ายที่สุดที่เกิดขึ้นจริง และ Calmar Ratio เชื่อมโยงผลตอบแทนกับ Drawdown เพื่อประเมินว่าผลตอบแทนคุ้มค่ากับความเสี่ยงสูงสุดหรือไม่ การใช้ตัวชี้วัดทั้ง 4 ด้านร่วมกัน ทำให้สามารถประเมินประสิทธิภาพของกลยุทธ์ได้อย่างรอบด้าน

การทดสอบทางสถิติ

ทดสอบระดับรายเดือน ($n = 43$ เดือน หลังหัก Walk-Forward Training) เปรียบเทียบ 6 คู่ ($m = 6$) ด้วย 8 วิธี: (1) Paired t-test (Montgomery & Runger,


2018) (2) Newey-West HAC (3) Monte Carlo Bootstrap 10,000 รอบ (Efron & Hastie, 2016) (4) Wilcoxon Signed-Rank Test (5) Block Bootstrap (6) Permutation Test 10,000 รอบ (7) Ledoit-Wolf Sharpe Test (8) Cohen's d Effect Size พร้อม Bonferroni Correction ($p_{\text{adj}} = p \times m$)

ผล

จาก Table 2 Event-Driven MVO ให้ผลตอบแทนสูงสุด 10.97% ต่อปี โดย Sharpe Ratio = 30.47 สูงกว่า Static (24.90) เพิ่มขึ้นคิดเป็น +22.4% และมี Max Drawdown เพียง 0.18% ต่ำกว่า Static (0.86%) ถึง 4.8 เท่า Calmar Ratio สูงถึง 61.51 เทียบกับ Static (11.19) สูงกว่า 5.5 เท่า สิ่งที่น่าสนใจคือ ML ทั้ง Ridge (9.64%) และ XGBoost (9.64%) ให้ผลตอบแทนแทบเท่ากับ Static (9.66%) และมีค่า Sharpe ต่ำกว่าเล็กน้อย

Table 2 Full period performance comparison (Oct 2021 - Oct 2025)

Strategy	Return (%)	Sharpe	Sortino	MDD (%)	Calmar	Rebalance
Static	9.66	24.90	25.10	0.86	11.19	0
Ridge	9.64	24.75	25.12	0.89	10.84	43
XGBoost	9.64	24.76	25.16	0.89	10.89	43
Event-MVO	10.97	30.47	26.95	0.18	61.51	166

**Figure 2** Annual returns: 4-strategy comparison by market condition**Table 3** Year-by-year performance summary

Period	Market	S. Ret%	E. Ret%	S-E Ret Diff	S. Sharpe	E. Sharpe	S-E Sharpe Diff
Year 1	Bear	4.86	8.33	+3.47	12.19	24.85	+12.66
Year 2	Recov.	6.40	7.17	+0.77	36.52	37.19	+0.67
Year 3	Bull	14.68	13.67	-1.01	32.58	29.98	-2.6
Year 4	Mixed	8.35	8.96	+0.61	44.07	62.75	+18.68
Average	-	8.57	9.53	+0.96	31.34	38.69	+7.35

จาก Figure 2 และ Table 3 Event-Driven ให้ผลชนะ 3 จาก 4 ปี (75%) โดย Year 1 (Bear Market) ให้ Improvement สูงสุด (+3.47%) เนื่องจาก Volatility สูงทำให้ MVO จัดสรรน้ำหนักได้มี

ประสิทธิภาพ Year 3 (Bull Market) เป็นปีเดียวที่แพ้ (-1.01%) โดยสังเกตว่า Ridge และ XGBoost ให้ผลแทบเหมือนกันทุกปี (ต่างกัน < 0.01%) แสดงว่า Non-linear Model ไม่ได้เหนือกว่า Linear Model ในบริบทนี้




Figure 3 Annual Sharpe Ratio comparison

Figure 3 แสดง Event-Driven Sharpe สูงกว่า Static ใน 3 จาก 4 ปี โดย Year 1 (Bear) มีความแตกต่างสูงสุด +12.66 จุด (+103.9%) เนื่องจากตลาดผันผวนสูงทำให้ MVO จัดสรรน้ำหนักหลีกเลี่ยงเหรียญที่ Funding Rate ต่ำได้ดี Year 4 (Mixed) ปรับปรุงมากเป็นอันดับสอง +18.68 จุด (+42.4%) ส่วน Year 3 (Bull) เป็นปีเดียวที่ต่ำกว่า (ลดลง 8.0%) เนื่องจาก Funding Rate เป็นบวกสม่ำเสมอ

ทำให้เฉลี่ยรวม Event Sharpe เท่ากับ 38.69 สูงกว่า Static Equal Weight ซึ่งให้ผลดีอยู่แล้วที่ 31.34 คิดเป็น +23.5% ซึ่งปรับปรุงมากกว่า Return (+11.2%) เนื่องจาก MVO ทำงานสองด้านพร้อมกัน คือเพิ่มผลตอบแทนและลดความผันผวนจาก 0.626% เหลือ 0.520% (ลดลง 16.9%) สอดคล้องกับหลักการ Diversification ของ Markowitz (1952)

Table 4 Monthly descriptive statistics

Metric	Static	Ridge	XGBoost	Event
Mean (%)	0.650	0.649	0.649	0.720
Std Dev (%)	0.626	0.631	0.630	0.520
Min (%)	- 0.502	- 0.523	- 0.519	0.115
Max (%)	3.346	3.361	3.361	3.338
Pos. Months	39/43	39/43	39/43	43/43
Best Count	7/43	4/43	5/43	27/43




Figure 4 Monthly best strategy distribution (n = 43)

Monthly Performance (n = 43)

Monthly Performance (จำนวน 43 เดือน) โดย Table 4 และ Figure 4 แสดงว่า Event-Driven ไม่เคยขาดทุนรายเดือน (43/43 เท่ากับ 100% Positive Months) ขณะที่ Static, Ridge และ XGBoost มี 4 เดือนที่ขาดทุน (90.7%) ค่าต่ำสุดของ Event ยังเป็นบวก (+0.115%) เทียบกับ Static ที่ต่ำสุดถึง -0.502% ซึ่งแสดงว่าแม้ในเดือนที่ผลตอบแทนต่ำที่สุด Event-Driven ก็ยังสามารถรักษากำไรเป็นบวกได้ สาเหตุมาจาก MVO ลดน้ำหนักเหรียญที่ Funding Rate ต่ำหรือติดลบ ร่วมกับ Max Weight 40% ที่ป้องกันการกระจุกตัวในเหรียญใดเหรียญหนึ่งมากเกินไป

ด้านความผันผวน Event-Driven มี Monthly Std Dev เพียง 0.520% ต่ำกว่า Static (0.626%) คิดเป็นลดลง 16.9% นั้นหมายความว่า Event-Driven ให้ผลตอบแทนเฉลี่ยสูงกว่า (0.720% เทียบกับ 0.650% ต่อเดือน) ด้วยความผันผวนที่ต่ำกว่า สำหรับ Monthly Win Rate ทำให้ Event-Driven เป็นกลยุทธ์ที่ทำให้ผลตอบแทนสูงสุดในรอบเดือนถึง 27 จาก 43 เดือน (62.8%) เทียบกับ Static (7 เดือน) XGBoost (5 เดือน) และ Ridge (4 เดือน) สังเกตว่า ML ทั้งสองรวมกันชนะเพียง 9 เดือน (20.9%) ซึ่งน้อยกว่า Event-Driven เพียงตัวเดียวถึง 3 เท่า ยืนยันว่าการทำนาย Funding Rate ด้วย ML ไม่สามารถสร้างความได้เปรียบเหนือวิธี Optimization ได้




Figure 5 Cumulative portfolio growth: Event-MVO vs Static




Figure 6 Bootstrap distribution of mean monthly improvement (10,000 iterations)

Table 5 Statistical tests: Event vs Static (n=43, Bonferroni m=6)

Test	Statistic	Raw p	Bonf. p	Result
t-test	t = 2.483	0.0171	0.1027	✓ Raw
Wilcoxon	W = 669	0.0086	0.0515	✓ Raw
Permutation	10K iter	0.0126	0.0756	✓ Raw
MC Bootstrap	P(>0)	99.63%	-	✓ >95%
Block Boot	P(>0)	92.13%	-	Borderline
Newey-West	t = 1.588	0.1198	0.7187	NS
Cohen's d	0.379	-	-	Small

Cumulative Portfolio Growth

Figure 5 แสดงให้เห็นว่า Event-Driven (เส้นเขียว) แยกออกจาก Static (เส้นน้ำเงิน) ตั้งแต่ช่วงแรก และช่องว่างขยายต่อเนื่องตลอด 43 เดือน พื้นที่สีเขียวระหว่างเส้น แสดงผลตอบแทนส่วนเพิ่มที่สะสม (Compound Effect) ซึ่งยืนยันว่า Event-Driven ให้ผลดีกว่าอย่างสม่ำเสมอ ไม่ใช่เพียงช่วงเวลาใดช่วงเวลาหนึ่งเท่านั้น

ผลการทดสอบทางสถิติ

ผลทดสอบทางสถิติ จาก Table 5 และ Figure 6 Raw p-value ผ่าน 0.05 จาก 4 วิธี (t-test 0.017, Wilcoxon 0.009, Permutation 0.013, MC Bootstrap 99.63%) Bootstrap 95% CI = [0.016%, 0.125%] ไม่รวมค่า 0 ยืนยันว่า Improvement เป็นบวกจริง Bonferroni Correction (×6) ทำให้ p-value อยู่ที่ 0.05-0.10 ซึ่ง Conservative สำหรับ Correlated Comparisons Cohen's d = 0.379 (Small Effect) สอดคล้องกับ Efficient Market ที่ Alpha มีขนาดเล็กแต่สม่ำเสมอ

Table 6 ML vs Static: Effect size analysis

Comparison	Mean Diff%	t-test p	d	Effect
Ridge vs Static	- 0.001	0.340	- 0.15	Negligible
XGBoost vs Static	- 0.001	0.403	- 0.13	Negligible
Event vs Static	+0.070	0.017	0.38	Small

Table 7 Sensitivity analysis summary

Parameter	Range	Return%	Sharpe	Wins All
spike_threshold	40-80%	10.90-10.99	30.0-31.0	Yes
lookback_window	60-120 periods	10.92-10.99	29.8-31.0	Yes
min_interval	96-240 hrs	10.97	30.47	Yes

Table 6 แสดงว่า Machine Learning (ML) ทั้ง Ridge ($d = -0.15$) และ XGBoost ($d = -0.30$) มี Effect Size ระดับ Negligible (< 0.2) เมื่อเทียบกับ Static ผลนี้ยืนยันว่า การทำนาย Funding Rate ด้วย ML ไม่สร้าง Alpha ไม่ว่าจะใช้ Linear หรือ Non-linear Model ก็ตาม แต่ในทางตรงกันข้าม Event-Driven MVO ($d = 0.38$, Small) ที่ไม่ได้ทำนาย กลับให้ผลที่ดีกว่าอย่างมีนัยสำคัญ

Sensitivity และ Breakeven Analysis

Table 7 แสดง Event-Driven ชนะ ทุก Baseline ในทุก Parameter Setting (Wins All เท่ากับ Yes) Return อยู่ในช่วงแคบ 10.90-10.99% และ Sharpe 29.8-31.0 เป็นการยืนยันว่าผลลัพธ์ไม่ได้เกิดจาก Parameter Overfitting แต่มาจากหลักการของ Event-Driven MVO โดยมีค่า Breakeven Fee อยู่ที่ 5.4 bps (เกณฑ์ Sharpe Ratio) หรือ 7.3 bps (เกณฑ์ Return) ซึ่งทั้งสองค่าสูงกว่าค่าธรรมเนียมจริงของ Binance (2.5 bps) อย่างน้อย 2 เท่า แสดงว่ามี Safety Margin เพียงพอ

วิจารณ์

งานวิจัยนี้มีเป้าหมายหลักคือการเพิ่มประสิทธิภาพ Sharpe Ratio ผ่านอัลกอริทึม Event-Driven ผลลัพธ์ยืนยันว่าวิธีที่เสนอบรรลุเป้าหมายอย่างชัดเจน โดย Sharpe Ratio เพิ่มขึ้นจาก 24.90 (Static) เป็น 30.47 คิดเป็น +22.4% ซึ่งเกิดจากการทำงานสองด้านพร้อมกัน ด้านแรกคือการเพิ่มผลตอบแทนเฉลี่ยรายเดือนจาก 0.650% เป็น 0.720% ผ่านการจัดสรรน้ำหนักไปยังสินทรัพย์ที่มี Funding Rate สูงด้วย Mean-Variance Optimization (Markowitz, 1952) ด้านที่สองคือการลด Monthly Volatility จาก 0.626% เหลือ 0.520% (ลดลง 16.9%) ผ่าน Covariance Matrix ที่กระจายความเสี่ยง หลีกเลี่ยงการถือสินทรัพย์ที่มี Correlation สูงพร้อมกัน

ค่า Sharpe Ratio ที่สูงถึง 30.47 อาจดูผิดปกติเมื่อเทียบกับกลยุทธ์การลงทุนทั่วไปอย่างไรก็ตามค่านี้สอดคล้องกับธรรมชาติของกลยุทธ์ Delta-

Neutral Funding Rate Arbitrage ที่มีความผันผวนต่ำมาก (Monthly Std Dev เพียง 0.520%) กล่าวคือผลตอบแทนมาจากค่า Funding Rate ที่เป็นบวกเกือบตลอด ไม่ใช่จากการเก็งกำไรทิศทางราคาทำให้อัตราส่วนผลตอบแทนต่อความเสี่ยงสูงตามลักษณะเฉพาะของกลยุทธ์ประเภทนี้ ซึ่ง He *et al.* (2022) รายงาน Sharpe Ratio ที่สูงในลักษณะเดียวกันจากกลยุทธ์ Arbitrage บน Perpetual Futures ของ Binance

ด้าน Downside Risk Event-Driven ให้ Max Drawdown เพียง 0.18% ต่ำกว่า Static (0.86%) ถึง 4.8 เท่า Calmar Ratio สูงถึง 61.51 เทียบกับ Static (11.19) สูงกว่า 5.5 เท่า และไม่เคยขาดทุนรายเดือน (43/43 เท่ากับ 100%) ขณะที่ Static ขาดทุน 4 เดือน สาเหตุที่ปกป้อง Downside ได้ดีมาจากสถาปัตยกรรม Event-Driven ที่ตอบสนองต่อเหตุการณ์จริง (Spike Detection) ไม่ใช่ Fixed Schedule ร่วมกับ Adaptive Interval ที่ปรับความถี่ตาม Volatility และ Max Weight 40% ที่ป้องกัน Concentration Risk นอกจากนี้ตลาดคริปโตมีความเชื่อมโยงเชิงพลวัต (Hanif *et al.*, 2023)

ผลลัพธ์อีกอย่างหนึ่งที่น่าสนใจคือ ML ทั้ง Ridge และ XGBoost ไม่สามารถเอาชนะ Equal Weight ได้ แม้ว่า Yang (2024) จะแสดงว่า XGBoost ร่วมกับ CAPM ให้ผลดีในบริบท Price Prediction แต่ในบริบท Funding Rate กลับไม่สร้าง Alpha (Cohen's d น้อยกว่า 0.2) Feature Importance จาก XGBoost แสดงว่า `current_fr` มี Importance สูงสุด (ประมาณร้อยละ 30) แสดงว่า Funding Rate มีลักษณะ Mean-Reverting ยากต่อการทำนายอย่างมีกำไร สอดคล้องกับ Iqbal *et al.* (2024) และ Efficient Market Hypothesis (Fama, 1970) ที่ข้อมูลในอดีตไม่สามารถทำนายอนาคตได้อย่างมีนัยสำคัญ และ Noise-to-Signal Ratio สูงใน Financial Data (Bouri *et al.*, 2020) ผลนี้ชี้ว่าการ Optimize น้ำหนักพอร์ตตามแนวทาง Event-Driven MVO มีประสิทธิภาพเหนือกว่าการทำนายด้วย ML ในบริบท Funding Rate

สำหรับประเด็น Bonferroni Correction ทำให้ p-value ของ t-test อยู่ที่ 0.1027 และ Wilcoxon อยู่ที่ 0.0515 ซึ่งไม่ผ่านเกณฑ์ 0.05 อย่างชัดเจน เนื่องจาก 6 Comparisons มี Correlation กัน Bonferroni จึงอาจ Conservative เกินไป อย่างไรก็ตามในส่วนของ MC Bootstrap $P(>0)$ เท่ากับ 99.63% ซึ่งเป็น Non-Parametric ไม่ต้อง Adjust ยืนยัน Practical Significance Sensitivity Analysis แสดง Event-Driven ชะงัก Parameter Setting ซึ่งเป็นการยืนยัน Robustness ของระบบ และทำให้ค่า Breakeven Fee อยู่ที่ 5.4 ถึง 7.3 bps สูงกว่าค่าธรรมเนียมจริงของ Binance (2.5 bps) อย่างน้อย 2 เท่า แสดงว่ามี Safety Margin เพียงพอ

ข้อจำกัดของงานวิจัย ได้แก่ (1) ศึกษาเฉพาะ Binance ไม่รวม Bybit, OKX (2) จำกัด 8 สินทรัพย์ (3) ไม่รวม Slippage จริง (4) ML ใช้เฉพาะ Ridge/XGBoost ไม่รวม LSTM (García-Medina & Aguayo-Moreno, 2024), Reinforcement Learning (Zhang *et al.*, 2020) ข้อเสนอแนะสำหรับอนาคต ได้แก่ การเพิ่ม Deep Learning Baseline การขยายสินทรัพย์และตลาด การพัฒนาระบบ Real-Time และการใช้ Holm-Bonferroni แทน Standard Bonferroni

เอกสารอ้างอิง

- Ackerer, D., Hugonnier, J., & Jermann, U. (2026). Perpetual futures pricing. *Mathematical Finance*, 36(3), 481-499. <https://doi.org/10.1111/mafi.70018>
- Alexander, C., Choi, J., Park, H., & Sohn, S. (2020). BitMEX bitcoin derivatives: Price discovery, informational efficiency, and hedging effectiveness. *Journal of Futures Markets*, 40(1), 23-43. <https://doi.org/10.1002/fut.22050>
- Bailey, D. H., Borwein, J. M., López de Prado, M., & Zhu, Q. J. (2017). The probability of backtest overfitting. *Journal of Computational Finance*, 20(4), 39-69. <https://doi.org/10.21314/JCF.2016.322>
- Binance. (2026, 06 March). *Introduction to Binance Futures Funding Rate*. Binance Academy. <https://www.binance.com/en/support/faq/detail/360033525031>
- Bouri, E., Shahzad, S. J. H., Roubaud, D., Kristoufek, L., & Lucey, B. (2020). Bitcoin, gold, and commodities as safe havens for stocks: New insight through wavelet analysis. *The Quarterly Review of Economics and Finance*, 77, 156-164. <https://doi.org/10.1016/j.qref.2020.03.004>
- Chen, T., & Guestrin, C. (2016). *XGBoost: A scalable tree boosting system*. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785-794. <https://doi.org/10.1145/2939672.2939785>
- CoinGecko. (2024). *2024 Annual Cryptocurrency Report*. <https://www.coingecko.com/research/publications/2024-annual-crypto-report>
- De Prado, M. L. (2018). *Advances in Financial Machine Learning*. Wiley.
- Efron, B., & Hastie, T. (2016). *Computer Age Statistical Inference: Algorithms, Evidence, and Data Science*. Cambridge University Press.

- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383-417. <https://doi.org/10.2307/2325486>
- García-Medina, A., & Aguayo-Moreno, E. (2024). LSTM-GARCH hybrid model for the prediction of volatility in cryptocurrency portfolios. *Computational Economics*, 63, 1511-1542. <https://doi.org/10.1007/s10614-023-10373-8>
- Hanif, W., Ko, H. U., Pham, L., & Kang, S. H. (2023). Dynamic connectedness and network in the high moments of cryptocurrency, stock, and commodity markets. *Financial Innovation*, 9(1), 84. <https://doi.org/10.1186/s40854-023-00474-6>
- He, S., Manela, A., Ross, O., & von Wachter, V. (2022). Fundamentals of perpetual futures. SSRN. <https://doi.org/10.2139/ssrn.4301150>
- Hull, J. C. (2022). *Options, Futures, and Other Derivatives* (11th ed.). Pearson.
- Iqbal, R., Riaz, M., Sorwar, G., & Qadir, J. (2024). Cryptocurrency market volatility and forecasting: A comparative analysis of modern machine learning models for cryptocurrencies predicting accuracy. *Review of Pacific Basin Financial Markets and Policies*, 27(4), 2450028. <https://doi.org/10.1142/S0219091524500280>
- James, G., Witten, D., Hastie, T., Tibshirani, R., & Taylor, J. (2023). *An Introduction to Statistical Learning with Applications in Python*. Springer. <https://doi.org/10.1007/978-3-031-38747-0>
- Jeleskovic, V., Latini, C., Younas, Z. I., & Al-Faryan, M. A. S. (2024). Cryptocurrency portfolio optimization: Utilizing a GARCH-copula model within the Markowitz framework. *Journal of Corporate Accounting & Finance*, 35(4), 139-155. <https://doi.org/10.1002/jcaf.22721>
- Makarov, I., & Schoar, A. (2020). Trading and arbitrage in cryptocurrency markets. *Journal of Financial Economics*, 135(2), 293-319. <https://doi.org/10.1016/j.jfineco.2019.07.001>
- Markowitz, H. (1952). Portfolio selection. *The Journal of Finance*, 7(1), 77-91. <https://doi.org/10.1111/j.1540-6261.1952.tb01525.x>
- Montgomery, D. C., & Runger, G. C. (2018). *Applied Statistics and Probability for Engineers* (7th ed.). Wiley.
- Muteba Mwamba, J. W., Mbucici, L. M., & Mba, J. C. (2025). Multi-objective portfolio optimization: An application of the non-dominated sorting genetic algorithm III. *International Journal of Financial Studies*, 13(1), Article 15. <https://doi.org/10.3390/ijfs13010015>
- Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. <https://bitcoin.org/bitcoin.pdf>

- Sahu, S., Ochoa Vázquez, J. H., Fonseca Ramírez, A., & Kim, J.-M. (2024). Analyzing portfolio optimization in cryptocurrency markets: A comparative study of short-term investment strategies using hourly data approach. *Journal of Risk and Financial Management*, 17(3), Article 125. <https://doi.org/10.3390/jrfm17030125>
- Sharpe, W. F. (1966). Mutual fund performance. *The Journal of Business*, 39(1), 119-138. <https://doi.org/10.1086/294846>
- Werapun, W., Karode, T., Suaboot, J., Arpornthip, T., & Sangiamkul, E. (2025). Exploring risk and return profiles of funding rate arbitrage on CEX and DEX. *Blockchain: Research and Applications*, 7(4), 100354. <https://doi.org/10.1016/j.bcra.2025.100354>
- Yang, J. (2024). Portfolio construction based on XGBoost-CAPM model: Evidence from the cryptocurrency market. Proceedings of the 2024 9th International Conference on Social Sciences and Economic Development (ICSSSED 2024), 127-136. https://doi.org/10.2991/978-94-6463-459-4_16
- Zhang, Z., Zohren, S., & Roberts, S. (2020). Deep reinforcement learning for trading. *The Journal of Financial Data Science*, 2(2), 25-40. <https://doi.org/10.3905/jfds.2020.1.030>