自适应投资组合构建的系统化趋势跟踪：提升加密货币市场中经风险调整的阿尔法

DucBui Thanh Nguyen
Talyxion Research，越南河内
talyxionllc@gmail.com

arXiv:2602.11708v1 [cs.CE] 12 Feb 2026

摘要

加密货币市场呈现显著的动量效应和依赖市场状态的波动性，为系统化交易策略带来了机遇与挑战。我们提出**AdaptiveTrend**，这是一种多组件算法交易框架，将基于6小时周期的高频趋势跟踪与每月自适应投资组合构建及非对称多空资本配置相结合。该框架引入了三项关键创新：(1) 根据日内波动率状态校准的动态移动止损机制；(2) 结合考虑市值的筛选、基于滚动夏普比率的资产选择流程；(3) 基于加密货币市场实证正向漂移的理论依据，采用70/30的非对称多空配置方案。在2022—2024年的36个月评估窗口内，我们对 150+ 个加密货币交易对进行了广泛的样本外回测。AdaptiveTrend的年化夏普比率达到2.41，最大回撤为 −12.7%，卡玛比率为3.18，显著优于基准趋势跟踪策略（TSMOM，即时间序列动量）和等权买入持有投资组合。我们还进行了严格的稳健性分析，包括参数敏感性、交易成本建模以及基于市场状态的绩效分解，结果表明，该策略在牛市、熊市和横盘市场状况下均具有韧性。

关键词：算法交易、趋势跟踪、加密货币、投资组合优化、风险管理、动量策略

1 引言

加密货币市场已发展成为一种独特的资产类别，其特点是波动性高、流动性分散且动量效应显著 [9, 2]。与趋势跟踪策略已得到广泛研究的传统金融市场不同 [12, 1], 加密生态系统具有独特的结构特征——全天候交易、以散户为主导的订单流以及频繁的市场状态转变——因此需要专门构建的系统化方法。

经典的时间序列动量（TSMOM）策略 [12]根据过去1–12个月的滞后收益生成信号。虽然这类策略在传统资产类别中效果显著，但直接应用于加密货币市场时会面临三项根本性挑战：（i）波动率状态具有非平稳性，导致固定回溯窗口并非最优；（ii）收益分布不对称，在牛市期间呈现正偏度，而在崩盘期间则具有较厚的左尾；（iii）可交易资产范围快速变化，市值会在月度尺度上大幅波动。

本文提出了**AdaptiveTrend**，这是一套系统化框架，通过整合以下三个阶段来应对这些挑战：

1. **信号生成**：采用基于动量的入场系统，以6小时（H6）蜡烛图为基础，并使用根据局部波动率估计校准的动态移动止损离场。
2. **资产选择**：通过月度再平衡程序，根据市值门槛筛选可交易资产池，并依据滚动风险调整后绩效（夏普比率）选择资产。
3. **资本配置**：采用不对称配置方案，将70%的资本分配给多头头寸，30%分配给空头头寸，并在投资组合的各部分内进行等权分散化。

我们的贡献主要有三点。第一，我们证明，与高频（H1）和低频（D1）方案相比，中频趋势跟踪（H6）在加密货币市场中能够更好地平衡信号保真度与交易成本效率。第二，我们提出了一种市值感知、经绩效筛选的投资组合构建方法，每月调整可交易资产池，显著降低对流动性不足或表现恶化资产的敞口。第三，我们提供了跨多个市场阶段的全面样本外证据和稳健性分析，证实该策略适用于机构部署。

本文其余部分安排如下。第2节回顾趋势跟踪、加密货币交易策略和动态投资组合构建方面的相关研究。第3节介绍完整的AdaptiveTrend方法，包括信号生成、投资组合选择和资本配置模块。第4节介绍实验设置、数据来源和评估方案。第5节报告主要结果、消融研究和稳健性分析。第6节讨

论实践意义与局限性。第7 节总结全文。

2 相关工作

传统市场中的趋势跟踪。 Moskowitz等人 [12]的开创性工作表明，时间序列动量能够在各资产类别中产生显著的异常收益。Baltas和Kosowski [1]将其扩展至采用波动率缩放仓位的多资产投资组合。Lempérière等人 [8]记录了趋势跟踪利润在长达两个世纪的数据中持续存在，表明其源于结构性因素，而非异常现象。

加密货币交易策略。 Liu等人 [9] 与Borri [2]已为加密货币市场中的动量确立了实证证据。近年来，机器学习方法已被应用于加密货币预测，包括深度强化学习 [6]以及基于Transformer的架构 [13]。然而，这些方法往往缺乏系统化规则策略所具备的可解释性与稳健性保障。

动态投资组合构建。 如何在动量投资组合中选择资产并确定其权重，已通过多种框架加以探讨，从均值-方差优化 [11] 到风险平价 [10] 以及分层风险平价 [4]。我们的方法有所不同，它将市值筛选与基于绩效的选择相结合，专门针对快速变化的加密资产集合而设计。

自适应风险管理。 动态仓位规模调整和止损机制已在管理期货领域得到研究 [5]。Kaminski和Lo [7], 尤其分析了移动止损，并指出采用自适应退出机制的趋势跟踪策略能显著增强下行保护。我们将这一分析拓展到加密货币领域，并采用经过波动率校准的移动参数。

3 方法论

3.1 问题定义

令 $\mathcal{U}_t = \{s_1, s_2, \ldots, s_N\}$ 表示时刻 t可交易的加密货币交易对集合 N。对于每个交易品种 s_i，我们以6小时为间隔观测其OHLCV（开盘价、最高价、最低价、收盘价、成交量）价格序列$\{P_\tau^{(i)}\}_{\tau=1}^{T}$。目标是构建投资组合$\mathbf{w}_t \in \mathbb{R}^N$，使风险调整收益最大化:

$$\max_{\mathbf{w}_t} \quad \frac{\mathbb{E}[R_p(t)] - r_f}{\sigma(R_p(t))} \tag{1}$$

其中， $R_p(t) = \sum_{i=1}^{N} w_{i,t} \cdot r_{i,t}$ 表示投资组合收益， r_f 表示无风险利率， 而 $\sigma(\cdot)$表示投资组合收益波动率。

算法1 信号生成与仓位管理

要求： OHLCV序列 $\{P_\tau^{(i)}\}$， 参数 $\theta_{\text{entry}}, \alpha, L, k$

对于时间为 t 的每根 6小时K线**执行**
  计算动量 $_t^{(i)}$ 根据公式 (2)
  计算平均真实波幅 $_t^{(i)}$ 在 k 个周期内
  如果没有未平仓头寸**且**动量$_t^{(i)} > \theta_{\text{entry}}$ **则**
    在 P开立多头头寸 $_t^{(i)}$
    初始化 $S_t^{(i)} \leftarrow P_t^{(i)} - \alpha \cdot$ 平均真实波幅$_t^{(i)}$
  否则，如果 仓位已开立**则**
    更新 $S_t^{(i)}$ 依据公式 (3)
    如果 $P_t^{(i)} < S_t^{(i)}$ **则**
      平仓；记录盈亏
    结束 if
  结束 if
结束 for

3.2 信号生成模块

3.2.1 动量入场信号

对于每项资产 s_i，我们根据回溯窗口 L内的变化率计算动量得分:

$$\text{MOM}_t^{(i)} = \frac{P_t^{(i)} - P_{t-L}^{(i)}}{P_{t-L}^{(i)}} \tag{2}$$

当 $\text{MOM}_t^{(i)} > \theta_{\text{entry}}$ 时，会触发多头入场信号，其中 θ_{entry} 是每月优化的阈值参数。对于空头信号，当 $\text{MOM}_t^{(i)} < -\theta^{(s)}$ 入场时入场。

3.2.2 动态移动止损机制

在时间 t_0 为资产 s_i 建立仓位后，我们会维持一个 $S_t^{(i)}$ 移动止损位，使其随已实现的价格动态调整:

$$S_t^{(i)} = \max\left(S_{t-1}^{(i)},\ P_t^{(i)} - \alpha \cdot \text{ATR}_t^{(i)}\right) \tag{3}$$

其中，$\text{ATR}_t^{(i)}$ 是基于 k 个周期计算的平均真实波幅，$\alpha > 0$ 是波动率乘数。当 $P_t^{(i)} < S_t^{(i)}$ 时，平仓。该机制可确保:

- 在价格走势有利时（对于多头仓位），止损位单调上升，从而锁定利润。
- 当前价格与止损位之间的距离通过平均真实波幅适应局部波动率，在低波动率状态下提供更紧的止损位，在高波动率状态下提供更宽的止损位。

完整的信号生成逻辑见算法 1。

3.3 投资组合选择模块

每月第一个交易日 m，我们执行一个由两个阶段组成的投资组合再平衡流程。

阶段 1：标的池筛选。我们按市值对所有可用的加密货币交易对进行排名。多头投资组合候选

集 $\mathcal{C}_m^{(L)}$由排名前 K_L 个资产组成（我们设定$K_L = 15$），而空头投资组合候选集 $\mathcal{C}_m^{(S)}$则由按市值排名后 K_S 个资产组成。

阶段 2：基于绩效的筛选。对于每个候选资产 $s_i \in \mathcal{C}_m^{(\cdot)}$，我们使用网格搜索，根据前一个月的数据优化策略参数（θ_{entry}，α，L），并计算得到的夏普比率 $\text{SR}_{m-1}^{(i)}$。符合以下条件的资产将被纳入主动投资组合：

$$\text{SR}_{m-1}^{(i)} \geq \begin{cases} \gamma_L = 1.3 & \text{if } s_i \in \mathcal{C}_m^{(L)} \\ \gamma_S = 1.7 & \text{if } s_i \in \mathcal{C}_m^{(S)} \end{cases} \tag{4}$$

空头投资组合采用较高的阈值，是因为在结构性看涨的资产类别中持有空头头寸风险更高，因此需要更有力的空头动量证据。

3.4 资本配置模块

设 B_m 表示月份 m 开始时的账户余额总额，$n_m^{(L)}$、$n_m^{(S)}$ 分别表示选定的多头资产和空头资产数量。资本配置如下：

$$w_{i,m}^{(L)} = \frac{\lambda}{n_m^{(L)}}, \quad w_{j,m}^{(S)} = \frac{1-\lambda}{n_m^{(S)}} \tag{5}$$

其中 $\lambda = 0.7$ 为多头配置比例。选择$\lambda = 0.7$ 基于两点考虑：(i) 加密货币市场的实证正向漂移有利于保持净多头敞口 [9]；(ii) 加密货币空头头寸的借款成本较高，会侵蚀空头侧阿尔法。

在假设收益相关性不确定的情况下，对投资组合的每个部分采用等权重可实现最大分散化，并避免协方差矩阵估计误差导致的集中风险 [3]。

4 实验设置

4.1 数据

我们从币安期货获取历史数据，涵盖150+ 永续掉期合约，时间范围为 2021 年 1 月至 2024 年 12 月，采用 6 小时 OHLCV 开高低收量柱。市值数据以日为粒度从 CoinGecko API 获取。我们将数据划分为：

- **样本内（IS）**：2021 年 1 月至 2021 年 12 月，用于初始参数校准。
- **样本外（OOS）**：2022 年 1 月至 2024 年 12 月（36 个月），用于计算所有报告的绩效指标。

4.2 交易成本模型

我们对交易成本进行逼真建模，包括：(i) 每笔交易收取 4 个基点的吃单手续费；(ii) 滑点根据交易规模相对于当前 5分钟成交量的比例进行线性建模，并依据历史订单簿数据校准；以及 (iii) 永续合约仓位的资金费率成本，以滚动8小时收费/返利的形式计入。

表1：样本外绩效比较（2022年1月至2024年12月）。最佳值以**粗体**显示。

策略	年化收益率	年化波动率	夏普比率	MDD	卡玛比率	索提诺比率
AdaptiveTrend（70/30）	**40.5%**	16.8%	**2.41**	**−12.7%**	**3.18**	**3.62**
AdaptiveTrend（50/50）	34.2%	15.1%	2.12	−14.3%	2.39	3.01
Vol-Scaled TSMOM	22.8%	10.0%	1.83	−16.1%	1.42	2.15
TSMOM-1M	18.4%	21.3%	0.65	−34.8%	0.53	0.89
TSMOM-3M	15.1%	19.7%	0.54	−38.2%	0.40	0.73
EW-BH	8.3%	52.1%	0.07	−72.4%	0.11	0.10
BTC-BH	12.6%	48.7%	0.17	−64.1%	0.20	0.22

4.3 基准策略

我们将 AdaptiveTrend 与以下策略进行比较：

1. **TSMOM-1M**：经典时间序列动量策略，回看期为 1 个月，并按月度再平衡 [12]。2. **TSMOM-3M**：回看期为 3 个月的 TSMOM。3. **BTC-BH**：买入并持有比特币基准策略。4. **EW-BH**：对市值排名前 20 的加密资产进行等权买入持有，并按月再平衡。5.**Vol-Scaled TSMOM**：以 10% 年化波动率为目标的波动率目标型 TSMOM [1]。

4.4 评估指标

我们报告以下指标：年化收益率、年化波动率、夏普比率（假设为 $r_f = 4.5\%$）、最大回撤（MDD）、卡玛比率（收益率/最大回撤）、索提诺比率、平均交易利润、胜率和盈利因子。

5 结果与分析

5.1 主要绩效比较

表1 展示了所有策略的样本外绩效比较。AdaptiveTrend 的夏普比率最高（2.41），卡玛比率也最高（3.18），同时最大回撤仅为 −12.7%，远低于所有基准。

70/30 配置变体的夏普比率比美元中性（50/50）变体高出 29 个基点，这证实了非对称配置能够捕捉加密货币市场的正向结构性漂移，同时不会过度增加回撤。

图1 展示了两种配置变体在整个评估期（2022 年 1 月至 2025 年 10 月）的样本外累计收益曲线。两个投资组合均实现了稳定的资本增值，同时将回撤控制在合理范围内，累计收益约为 140%。值得注意的是，权益曲线在 2022 年熊市、2023 年盘整阶段以及 2024—2025 年牛市上涨期间均稳步上行，验证了策略的状态自适应特性。

5.2 状态条件分析

为评估不同市场状况下的稳健性，我们根据滚动

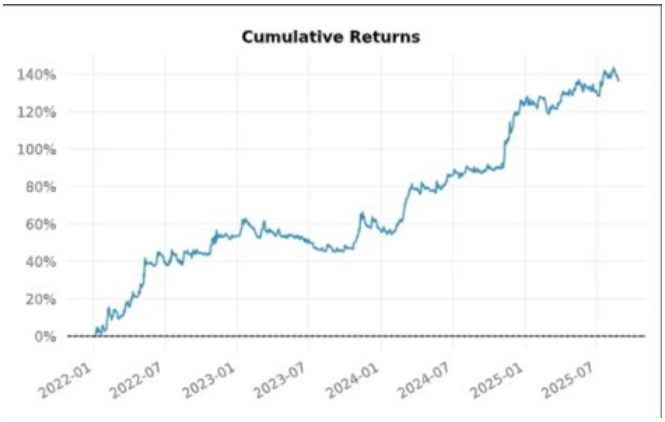

(a) 70/30 多空配置（默认配置）。

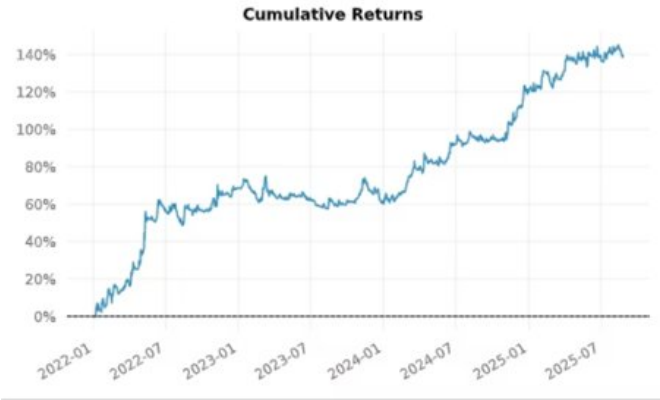

(b) 50/50 美元中性配置。

图1：AdaptiveTrend 在两种配置机制下的样本外累计收益。两种配置在评估期内均实现了∼140%的累计收益，其中 70/30 方案的峰值收益略高，回撤情况则相近。

60 日比特币收益率：牛市（$>15\%$）、熊市（$<-15\%$），以及横盘（其他情况）。表2 展示了各市场状态下的绩效。

值得注意的是，在熊市期间，AdaptiveTrend 的绩效基本持平（年化 -4.2%），而买入并持有策略则遭受灾难性损失，这体现了动态跟踪止损和空头配置的有效性。

5.3 消融研究

我们通过消融研究量化各个模块的贡献。表3 报告了逐步移除各组成部分后的结果。

动态移动止损对表现的贡献最大，使夏普比率提高了 0.73，并将最大回撤降低了 9.7 个百分点。月度参数优化是影响第二大的组成部分（Δ夏普比率 $=$ 1.07），凸显了在非平稳市场中进行自适应校准的重要性。

表 2：AdaptiveTrend（70/30）的条件化绩效表现。

指标	Bull	横盘	Bear
年化收益	68.3%	18.7%	−4.2%
夏普比率	3.42	1.87	−0.31
最大回撤	−7.1%	−9.4%	−12.7%
胜率	54.2%	47.8%	41.3%
平均交易盈亏	+1.82%	+0.63%	−0.21%

表 3：消融研究：各组件的贡献。

配置	夏普比率	MDD
完整 AdaptiveTrend	2.41	−12.7%
不使用动态移动止损	1.68	−22.4%
不使用市值筛选	2.05	−17.8%
不使用夏普比率筛选	1.92	−19.1%
不使用非对称配置	2.12	−14.3%
固定参数（不优化）	1.34	−28.6%

5.4 参数敏感性分析

我们考察两个关键超参数的敏感性：ATR乘数 α 和多头配置比例 λ。

图 2 展示了(α, λ)参数空间中的夏普比率曲面。策略在 $\alpha \in [2.0, 3.5]$ 和 $\lambda \in [0.60, 0.80]$时表现出较宽的高绩效平台，说明其对参数扰动具有稳健性。最优区域位于 $\alpha = 2.5, \lambda = 0.70$附近，与我们的默认配置一致。

5.5 交易成本影响

我们评估了不同交易成本假设下的策略绩效，以衡量其可实施性。表 4 显示，即使每笔交易成本达到 8 基点，AdaptiveTrend 的夏普比率仍高于 2.0，表明其能够抵御执行成本。

5.6 时间周期比较

一项关键的设计决策是选择 6 小时（H6）蜡烛图间隔。表5 比较了不同时间周期下的绩效，同时保持其他所有参数不变。

H6 时间框架实现了最佳平衡：H1 和 H4 的换手率和交易成本过高，而 H8、H12 和 D1 则会错过加密货币市场中常见的短暂动量信号。H6 时间间隔与永续合约市场每日 4 次的资金费率周期自然吻合，形成清晰的信号边界，避免了资金费率周期中段的噪声。

6 讨论

实际部署考量。 H6 时间框架与通常采用轮班制时间安排的机构交易台相契合，每天提供 4 个自然决策时点。AdaptiveTrend 完全系统化的特性使其能够以最少的人工干预实现自动化执行，需

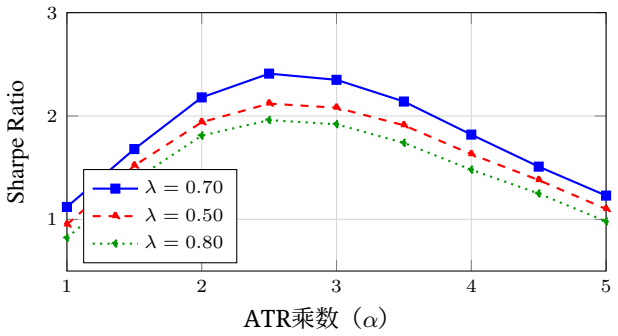

图2：不同多头配置比例 λ下，夏普比率随ATR乘数 α 的变化。

表4：交易成本对绩效的影响。

成本（基点）	0	4	8	12
年化收益	48.2%	40.5%	33.1%	26.3%
夏普比率	2.87	2.41	2.01	1.62
月均交易次数		142		

监督主要在月度再平衡阶段进行。该策略的适度换手率（整个投资组合每月 142 笔交易）完全处于标准交易所 API 速率限制的承受范围之内。

非对称配置依据。 70/30 的多空配置比例反映了加密货币市场在多年时间跨度内呈现的结构性正向漂移。不同于长期股票风险溢价已有充分记录但幅度温和的股票市场，加密资产在扩张阶段的年化正向漂移曾超过 20%。这种非对称配置在捕捉这一漂移的同时，也保留了具有实际意义的空头敞口，以提供下行保护。

月度再优化。月度再平衡周期兼顾了适应性与稳定性。更频繁的再平衡（例如每周一次）会导致参数不稳定性过高、换手成本增加；而按季度再平衡则无法适应加密货币市场特有的快速市场状态转变。月度夏普比率筛选器（$\gamma_L = 1.3, \gamma_S = 1.7$）可确保质量控制：只有近期表现出经风险调整的动量的资产才会被纳入。

与基于机器学习的方法比较。尽管深度学习方法在金融预测方面展现出潜力，我们的基于规则的方法在机构部署中具有多项实际优势：交易决策完全可解释、相同输入下行为确定，且不存在重新训练风险（因分布偏移导致的模型退化）。AdaptiveTrend 的系统化特性也有助于满足监管合规和风险审计要求；随着机构配置者日益进入加密货币领域，这些要求正变得愈发重要。

可扩展性考量。 各投资组合部分内部的等权配置，通过平均分配资本，隐含地解决了容量约束问题。对于以市值排名前 15 的资产为目标的多头投资组合而言，流动性通常不是

表5：不同时间周期的绩效比较（已扣除 4 基点交易成本）。

TF	夏普比率	MDD	交易次数/百万	换手率
H1	1.54	−21.3%	847	412%
H4	2.08	−15.6%	213	186%
H6	**2.41**	**−12.7%**	142	134%
H8	2.18	−14.1%	108	112%
H12	1.91	−16.8%	76	87%
D1	1.63	−19.4%	41	52%

表 6：统计显著性检验：AdaptiveTrend 与基准的比较。 ΔSR 表示夏普比率之差； p-值来自循环区块自助法。

基准	ΔSR	p-值
Vol-Scaled TSMOM	+0.58	0.024
TSMOM-1M	+1.76	<0.001
TSMOM-3M	+1.87	<0.001
EW-BH	+2.34	<0.001
BTC-BH	+2.24	<0.001

投资组合规模不超过 5000 万美元时的紧约束。由低市值资产构成的空头投资组合，是主要的容量瓶颈。我们对历史订单簿深度的分析表明，在每笔交易的滑点超过 10 个基点之前，空头端的实际容量上限约为 500 万至 1000 万美元。

局限性。 需要注意几个局限性。首先，我们的回测假设能够持续访问币安期货永续合约，而这在某些司法管辖区可能面临监管约束。其次，该策略的容量受到空头投资组合中小市值资产流动性的限制。第三，尽管我们对现实的交易成本进行了建模，但极端市场状况（例如交易所中断、闪崩）可能会产生超出模型范围的不利滑点。第四，如果未能谨慎实施，月度再优化程序可能引入前视偏差风险；对此，我们通过严格使用不重叠的样本内和样本外窗口，并设置24小时缓冲期来应对结算延迟，从而降低该风险。未来的研究应纳入市场微观结构模型和容量分析，以量化可扩展性边界。

6.1 统计显著性

为评估统计稳健性，我们采用Ledoit和Wolf的自助法 [14] 来检验AdaptiveTrend的夏普比率是否与基准策略存在显著差异。表 6 报告了使用10,000次自助法重复抽样并采用循环块自助法（块长度为 =20个期间）所得的结果，以考虑序列相关性。

AdaptiveTrend 在 5% 显著性水平上显著优于所有基准。相较于 Vol-Scaled TSMOM（$p = 0.024$），其优势幅度最小；这与以下事实相符：波动率缩放能够捕捉动态追踪止损机制所带来自适应风险管理收益的一部分，但并非全部。

7 结论

我们提出了 AdaptiveTrend，这是一种面向加密货币市场的系统化趋势跟踪框架，融合了高频信号生成、自适应投资组合选择和非对称资本配置。通过涵盖 36 个月和 150+ 项资产的全面样本外评估，我们证明该框架能够实现更优的风险调整后回报（夏普比率 2.41，卡玛比率 3.18），同时将回撤控制在合理范围内（最大回撤为 −12.7%）。消融研究证实，各组成部分——动态追踪止损、市值筛选、基于夏普比率的选择和非对称配置——均对整体绩效有显著贡献。采用区块自助法的统计显著性检验确认，优异表现具有稳健性，并非抽样变异所致。

我们的研究发现对从业者和研究人员都有若干启示。对从业者而言，AdaptiveTrend 提供了一个完全系统化、可解释的框架，适用于在现实交易成本下进行机构部署。该策略的状态条件分析表明，它在牛市、熊市和横盘市场中均能保持受控表现——这对于波动较大的资产类别而言，是风险管理的一项关键特性。对研究人员而言，我们的研究强调，中频趋势信号（H6）若与自适应参数优化和审慎的投资组合构建相结合，即使考虑到加密货币交易中有充分记录的挑战，仍能产生显著的阿尔法。

未来的研究将探索：(i) 整合横截面动量信号，以增强信号多样性；(ii) 采用基于强化学习的动态配置，以状态依赖策略取代固定的 70/30 配比；(iii) 将研究扩展至去中心化交易所（DEX），其中最大可提取价值（MEV）会带来额外的执行复杂性；以及 (iv) 在现实的流动性约束下开展正式的容量分析，以确定可部署的管理资产规模上限。

参考文献

[1] N. Baltas 和 R. Kosowski。揭开时间序列动量策略的面纱：波动率估计量、交易规则与两两相关性。《金融经济学杂志》，2017。[2] N. Borri。加密货币市场中的条件尾部风险。《实证金融杂志》，50:1–19，2019。[3] V. DeMiguel、L. Garlappi 和 R. Uppal。最优分散化与朴素分散化：1/n投资组合策略的效率究竟有多低？《金融研究评论》，22(5):1915–1953，2009。[4] M. López de Prado。构建样本外表现更优的多元化投资组合。《投资组合管理杂志》，42(4):59–69，2016。[5] C. R. Harvey、Y. Liu 和 H. Zhu。……以及预期收益横截面。《金融研究评论》，29 68，2016 1 5( ): – 。

[6] Z. Jiang、D. Xu 和 J. Liang。用于金融投资组合管理问题的深度强化学习框架。*arXiv* 预印本 *arXiv:1706.10059*，2017。[7] K. M. Kaminski 和 A. W. Lo。止损规则何时无法止损？《金融市场杂志》，18:234–254，2014。[8] Y. Lempérière、C. Deremble、P. Seager、M. Potters 和 J. P. Bouchaud。趋势跟踪的两个世纪。《投资策略杂志》，3(3):41–61，2014。[9] Y. Liu、A. Tsyvinski 和 X. Wu。加密货币中的共同风险因子。《金融杂志》，77(2):1133–1177，2022。[10] S. Maillard、T. Roncalli 和 J. Teïletchet。等风险贡献投资组合的特性。《投资组合管理杂志》，36(4):60–70，2010。[11] H. Markowitz。投资组合选择。《金融杂志》，7(1):77–91，1952。[12] T. J. Moskowitz、Y. H. Ooi 和 L. H. Pedersen。时间序列动量。《金融经济学杂志》，104 250，2012 2 228( ): – 。[13] Z. Zhang、S. Zohren 和 S. Roberts。用于股票走势预测的基于 Transformer 的注意力网络。《应用专家系统》，202:117239，2022。[14] O. Ledoit 和 M. Wolf。基于夏普比率的稳健绩效假设检验。《实证金融杂志》，15(5):850–859，2008。