自适应预测型投资组合管理智能体

Anton Kolonin[1, 2[0000-0003-4180-2870]], Alexey Glushchenko[1[0000-0002-8183-9208]]、Arseniy Fokin[1[0000-0002-7868-6482]]、Marcello Mari[1], Mario Casiraghi[1], Mukul Vishwas[1[0000-0002-8824-1954]]

[1] SINGULARITYDAO LABS DMCC，阿联酋迪拜[2] 俄罗斯联邦
新西伯利亚新西伯利亚国立大学 akolonin@gmail.com

摘要。本文介绍了一种先进版本的自适应做市智能体，该智能体能够通过体验式学习，采用“试错”方法，借助在虚拟环境中运行的从属智能体群来确定最优策略。本文将该问题视为“狭义通用人工智能”问题，其目标和环境范围限定于金融市场，特别是加密货币市场。这种智能体称为“自适应多策略智能体”，因为它会在虚拟环境中执行多种策略，并仅选择少数策略进行实盘执行。本文介绍的智能体版本经过扩展，可解决多种资产的投资组合优化与再平衡问题，从而应对主动投资组合管理问题。此外，本文尝试采用经验学习方法，在基于历史市场数据的多智能体仿真和回测虚拟环境中进行学习，使智能体能够学习特定市场状况与相应最优策略之间的映射关系。此外，该智能体还具备基于社交媒体数据预测价格走势的能力，从而提升其财务表现。

关键词：自适应智能体、回测、加密货币市场、经验学习、限价订单簿、做市、多智能体仿真、狭义通用人工智能、主动投资组合管理、价格预测。

1 引言

近年来，关于在金融市场环境中运行的自适应智能体的方法与架构，已得到广泛探讨；这是一种专门用于金融领域的“狭义通用人工智能”（狭义通用人工智能）智能体 [Rahe- man, 2023]。该方案最初被提出作为一种基于智能体的主动投资组合管理解决方案，其整体架构也已得到概述 [Raheman, KNOTH 2021]。最新研究探讨了通用人工智能智能体学习金融市场预测能力的可能性 [Oswald, 2023]。

一些较早的研究，例如 [Tsantekidis、2018] 和 [Ganesh，2019], 针对传统金融市场中的特定问题——在中心化交易所基于限价订单簿进行做市——尝试采用机器学习。

其他较晚的研究，例如 [Sadighian、2019] 和 [Sadighian，2020], 则尝试进一步聚焦于将强化学习应用于加密货币市场。

所谓“自适应多策略智能体”（AMSA）的概念由 [Raheman, AGI 2021]提出。在这种方法中，做市智能体会开展有目的的活动 [Vityaev, 2015] 通过体验式学习，以“试错”的方式实现金融回报最大化 [Kolonin, 2021] 。该方法依靠在虚拟环境中运行的从属智能体群来确定最优策略，随后在真实环境中执行这些策略，如图 1 所示。这类智能体被称为“自适应多策略智能体”，因为它会在虚拟环境中执行多种策略，并仅选择其中少数几种用于实盘执行。策略演化的虚拟环境通过对真实市场进行多智能体仿真构建，方式包括：a）构建完全合成的智能体群体，让其扮演做市商和交易者的角色，并由历史价格曲线驱动；或 b）通过仿真交易所运营进行回测，将市场上实际交易的历史记录与限价订单簿（LOB）结构的历史快照进行匹配。近期，[Raheman, 2023], 介绍了该方法的最新进展，展示了其在波动剧烈的加密货币市场中的表现能力。

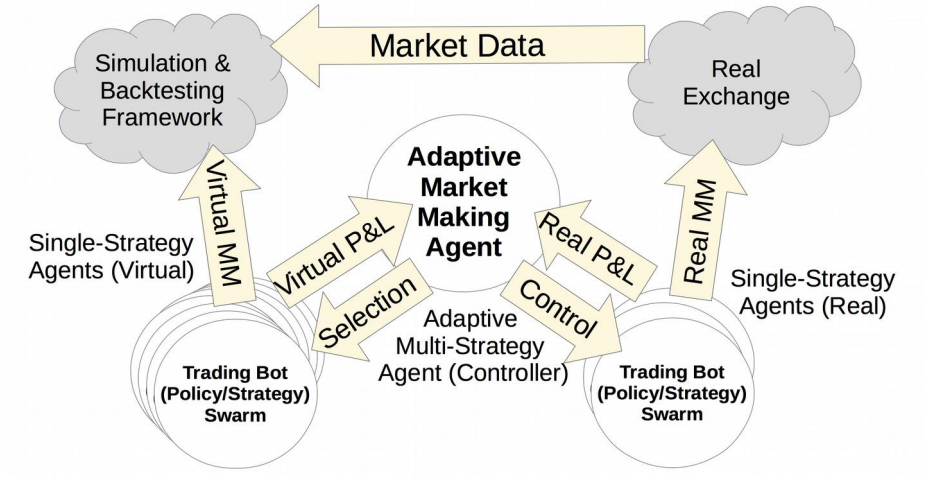


图 1。做市（MM）“自适应多策略智能体”的架构。仿真与回测框架（顶部）收集市场数据，包括已执行交易的记录和限价订单簿结构的快照。“控制器”智能体运行一组交易机器人，在虚拟环境中执行多种做市策略，并返回与这些策略相关的虚拟盈亏（左侧）。在每个策略评估周期，“控制器”都会针对给定的市场动量，选出表现最佳（按盈亏衡量）的策略，并另行创建一组规模较小的做市机器人，在真实交易所执行选定策略以收集真实盈亏（右侧）。

AMSA 代理的环境由市场数据 [Raheman、通用人工智能 2021] 以及社交媒体数据 [Kolonin 构成，2023], 这些数据也可用于价格走势预测。此前已有研究针对市场价格

预测开展了情感分析，参见 [Deveikyte、2020] 和 [Vishwas，2022], 但最新研究 [Kolonin，2023] 表明，认知心理学中所称的“认知扭曲”可能是操纵和恐慌的指标。

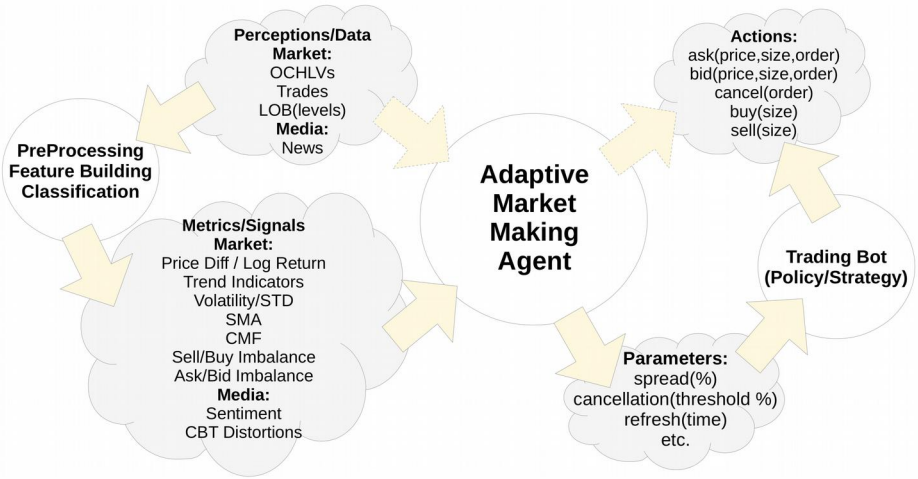


图 2。自适应做市代理作为“狭义通用人工智能”在运行空间中运行，其环境由金融市场数据和相关社交媒体新闻源构成；该代理根据特定参数定义的策略在市场上执行金融交易。

2 高级代理架构

本研究探讨的 AMSA 代理架构扩展了早期工作中提出的架构 [Raheman，如图 2 所示。本研究介绍的代理不仅能够感知市场数据，还能够感知社交媒体数据。为优化性能，代理不会直接使用数据，而是先对其进行预处理。原始市场数据（例如开高低收成交量数据帧、原始交易和限价订单簿快照）会转换为约两百项衍生指标，并以时间序列形式呈现，其中包括买卖量之间，或买入/卖出交易量与卖价/买价限价订单之间的导数和失衡指标。社交媒体数据则经过处理，以识别社交媒体指标和认知扭曲指标，并将其也转换为时间序列，参见 [Vishwas、2022] 和 [Kolonin，2023]。

本研究所用代理策略的参数与早期研究中使用的参数略有不同 [Raheman, AGI 2021] 和 [Raheman, 2023]。我们仍然使用限价订单买价和卖价之间价差的百分比，以及订单刷新频率。但我们将上述研究使用的“订单取消策略”（仅采用三种固定策略）替换为“取消阈值”，该阈值规定了价格变动需要达到何种幅度才会重新创建订单。后者使策略识别更加细致、准确。

除扩展版 AMSA 代理外，我们还尝试应用体验式学习方法 [Kolonin, 2021]，在多智能体仿真的虚拟环境中执行，并基于历史市场数据进行回测，以便代理能够学习特定市场状况与适用于这些状况的最优策略之间的映射关系。

此外，如图 3 所示，我们还探讨了如何将自适应多策略运作的整体原理应用于主动投资组合管理这一通用场景，包括多种资产间的投资组合优化与再平衡。为此，我们从两个方面扩展了智能体设计。首先，我们使其能够通过仿真和回测，在不同市场中评估所有“候选”策略，从而可以在二维空间中呈现投资组合资金的配置：一条轴表示资产或金融工具，另一条轴表示由其参数标识的特定策略。需要指出的是，在下文所述的实验中，所有资产／金融工具均以 USDT 进行交易。

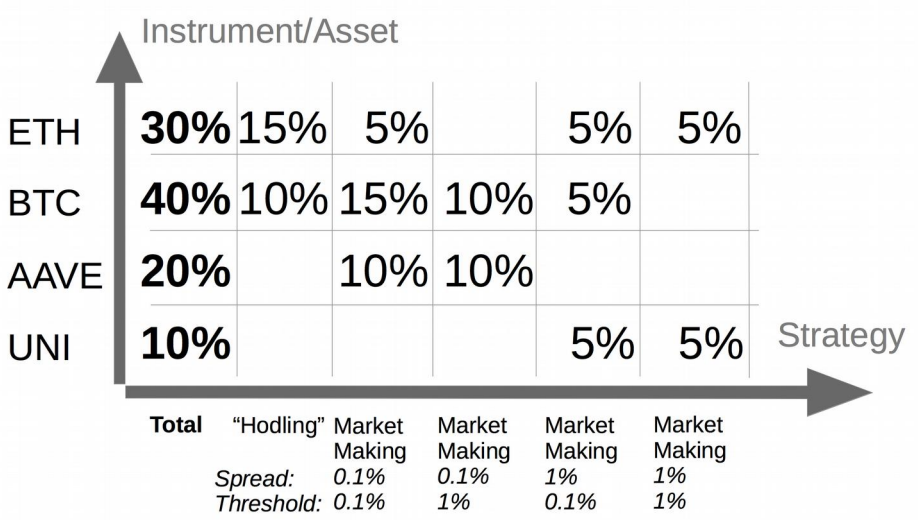


图 3。自适应多资产多策略投资组合管理中的资金配置二维空间。在此情境下，资产指加密货币；策略可以是“长期持有”，即在策略评估或执行期间将资金锁定在某项资产中，也可以是做市，并设定买卖价差或订单取消阈值等具体参数。

在我们的实验设计中，我们将资金分配扩展为在不同资产之间以及单个资产内的不同策略之间进行不均衡分配。这样一来，每个策略执行周期投入的资金量就能与上一个策略评估周期观察到的正收益成正比，事实证明这有助于提升效果。

总而言之，我们探索的智能体架构可称为基于多种策略的自适应预测型主动投资组合管理，这些策略会在仿真和回测的虚拟环境中并行执行。随后，根据各项资产和策略在虚拟执行中获得的收益，按比例使用分配给实盘执行的资金执行所选策略，

其资金分配比例与虚拟执行中基于各项资产和策略获得的收益成正比。

3 实验结果

3.1 多资产多策略自适应投资组合管理

为了探索在加密货币市场中采用所提出的多资产、多策略自适应主动投资组合管理智能体架构的可行性，我们使用来自币安交易所的三个月历史数据进行了回测实验，数据涵盖 2021 年九月、十月和十一月。数据包括完整的历史交易记录以及逐分钟的限价订单簿快照。实验选取了四种资产，即比特币、ETH、AAVE 和 UNI，其市场动态如图 4 所示。

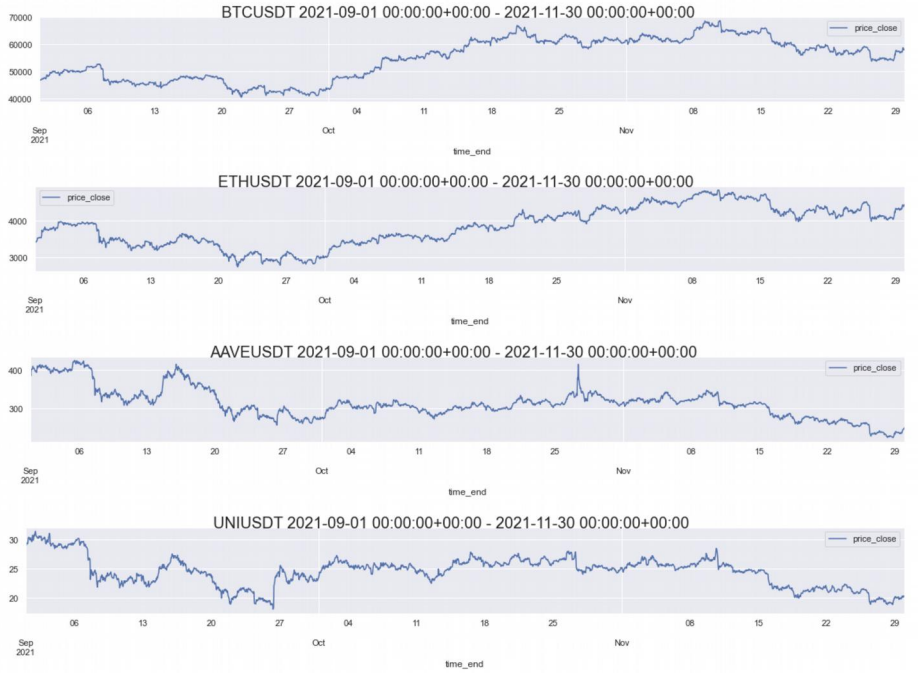


图 4. 2021 年九月、十月和十一月期间比特币、ETH、AAVE 和 UNI 加密货币的市场动态。

回测实验基于上文所示的数据进行，订单每小时刷新一次，采用了几种不同的投资组合配置，累计结果见图5。一种配置是分别对四种加密货币进行普通的单资产 AMSA 实验。另一种配置是由比特币和 ETH 组成的双资产投资组合。第三种配置则是包含全部四种加密货币的四资产投资组合。对于每种配置，策略

评估采用了不同的时间区间和加权策略。策略评估的时间区间为1、3、5、7.5和15天，分别覆盖三个月中的90天。实验采用了两种不同的加权策略。第一种策略是在每次策略评估迭代时，将当前投资组合资金价值平均分配给资产和策略；适用于上一轮迭代中取得正收益的每种资产与策略组合，在图5中标记为“固定”。第二种策略是根据各资产与策略组合的正收益大小，按比例分配整个投资组合资金价值，在图5中标记为“加权”。

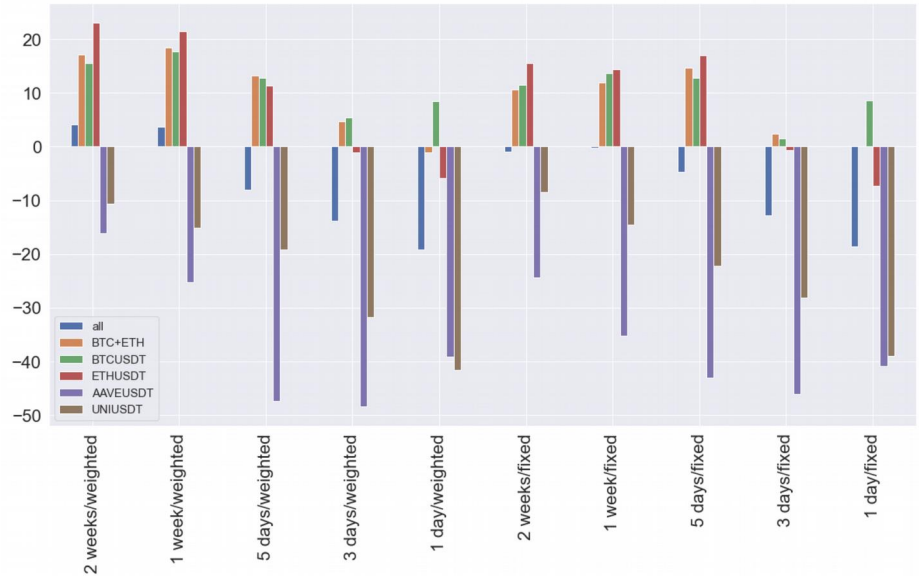


图5。通过对历史数据进行多策略回测，实现多资产自适应主动投资组合管理时，不同类型投资组合的投资回报率（ROI）百分比。每个区间中的不同柱形代表不同类型的投资组合（all——由比特币、ETH、AAVE 和 UNI 组成的投资组合；BTC+ETH——由两种资产组成的投资组合；其余四个柱形代表单一资产投资组合）。左侧五个区间对应资产/策略网格上的“加权”资金配置，右侧五个区间对应“固定”配置。左右两侧的每五个区间分别对应策略评估和执行迭代的不同时长。

对图5结果的解读得出以下结论。首先，在由 BTC 和 ETH 构成的双资产投资组合中，采用“加权”资金配置似乎更为高效：在每周和每两周策略评估的情况下，投资回报率最高可达 20%。其次，每周和每两周的策略评估期似乎优于更短的评估期。第三，只有“加权”资金配置与较长策略评估期相结合，才有可能在由全部四种资产构成的投资组合中获得正收益。第四，无论其他实验设置如何，投资组合中仅包含两种主要高流动性币种（BTC+ETH）的组合都能提供非负投资回报率，其表现

通常等于其中各项资产表现的平均值，但 3 天“加权”设置的情况除外：BTC+ETH 投资组合的表现最终优于其中的各项资产。同时，在所有情况下，将低流动性山寨币加入投资组合都会损害投资回报率。

3.2 基于仿真和回测的体验式学习

以下实验使用与上一节所述相同时间段的数据，仅关注 BTC/USDT市场。实验涉及回测期间按小时和按分钟采样的市场数据，以及订单刷新频率。在回测环境中，多个采用不同策略的智能体并行运行，依托历史数据模拟真实交易所的运行情况，相关方法见早期研究，例如 [Raheman、AGI 2021], [Raheman、KNOTH 2021], 和 [Raheman，2023]。每种策略由订单刷新频率（1 小时或 1 分钟）、买卖价差（0.1%、0.5%、1%、2%、10%）和订单取消阈值（0%、0.01%、0.1%、1%、10%）定义。评估了每种策略的每日收益（投资回报率），同时每天计算从原始市场数据得出的各项指标的平均值。

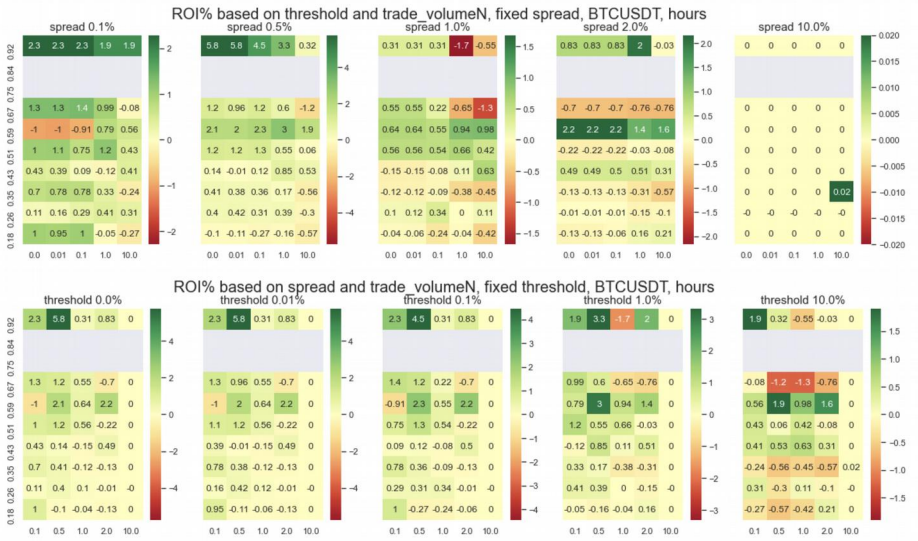


图6。投资回报率%作为策略参数（买卖价差和订单取消阈值）及市场状况（此处称为“volumeN”的归一化交易量）的函数，以三维（“spread”对“threshold”对“volumeN”）立方体的二维切片形式呈现，展示了与最高投资回报率值相对应的“盈利点”（例如，当“threshold”最高为1%且“volumeN”高于0.9时，“spread”为0.5）。

按策略参数每日收集每日收益，并与针对特定市场状况的指标每日评估结果相结合，从而能够在交易所运营的90天内，按市场策略和市场指标构成的多维空间汇总平均投资回报率。该空间中的每个点都

可以根据该点汇总的投资回报率数值，进一步分析其代表亏损还是盈利。图6展示了将该空间的维度降至三维后的分析示例。

最具信息量的市场指标似乎包括：市场价格的标准差、限价订单簿（LOB）卖盘和买盘订单量之间的不平衡、买方和卖方交易量之间的不平衡、所有交易量与所有限价订单量之间的不平衡，以及标准化交易量。图6以后一项为例，表明做市最有利可图的情形与异常高的交易量、约0.5%的价差以及最高达1%的撤单阈值相关。

3.3 预测性自适应做市

另一项实验使用了2022年10月和11月比特币（BTC）加密货币的最新市场数据进行，结果如图7所示。

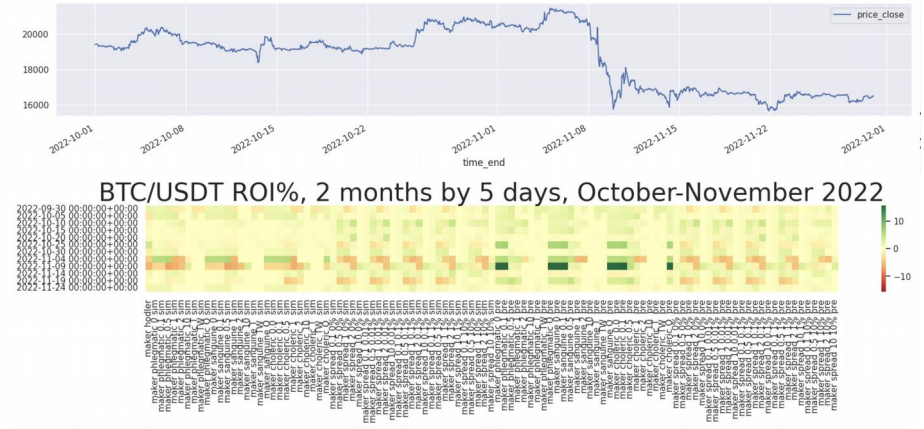


图7。2022年10月和11月比特币（BTC）加密货币的市场动态（上图），以及各策略在策略评估期为5天时的收益与亏损热力图（下图）。热力图的纵轴对应这60天内的12个策略评估周期，每个周期为5天，按从上到下的顺序排列。热力图的横轴对应不同的策略。基于实际价格走势的策略位于左半部分，而依赖预测价格走势的策略位于右半部分。可以清楚地看到，在与市场崩盘相关的时期（从底部数第四行），非预测性策略（左侧）出现亏损，而预测性策略（右侧）则获得了丰厚利润。

采用了与前一项实验相同的一系列策略，但每种策略都由独立的智能体以两种不同方式实现。第一类智能体根据当前市场价格及其变动来处理限价订单。第二类智能体则根据市场价格的预期走势来处理订单，依托于根据先前关于社交媒体分析和因果推断的研究成果所作出的价格预测

[Vishwas，2022] 和 [Kolonin，2023]。实验采用了与上文所述相同的 AMSA 代理智能体设置和仿真与回测框架，并使用了不同的策略评估周期（15、10、5 天）、订单刷新频率（天、小时）和资金分配策略（“固定”和“加权”），结果见图8。

研究发现，与无法获取预测信息时执行的同类策略相比，依赖市场价格预测的自适应多策略做市相当有利可图（2个月内投资回报率最高可达25%）。唯一的例外是，在某种情况下，即使没有预测信息，采用固定资金分配、每5天评估一次策略并每日刷新订单的方案，也获得了2.5%的投资回报率。

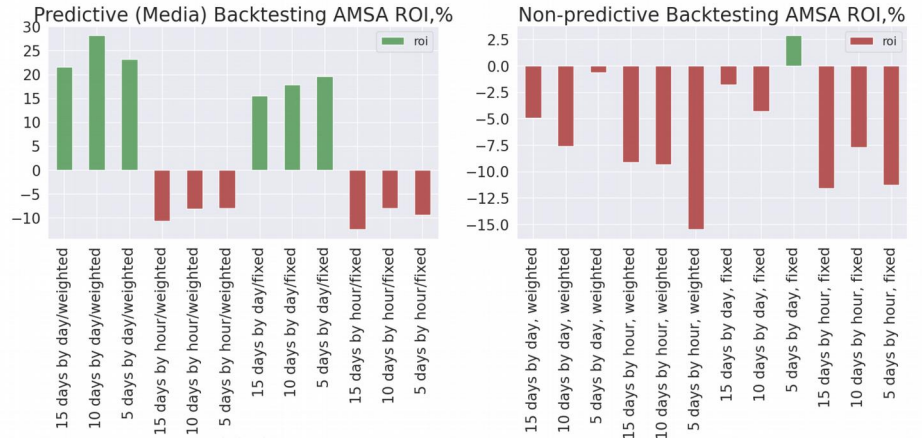


图8。2022年十月和十一月比特币自适应多策略做市的投资回报率（ROI%）：左侧为预测型策略（基于社交媒体），右侧为非预测型策略。

4 结论与未来工作

首先，我们发现，自适应多策略做市这一概念可以扩展至主动投资组合管理，以实现风险缓解。在未来的工作中，我们计划纳入更多策略，包括基于做空和做多头寸的传统交易。我们还计划在更长的时间范围内，更可靠地评估该方法，或采用更丰富的资产清单。

此外，我们还探讨了如何在通过针对真实历史市场数据进行回测而模拟出的虚拟交易环境中开展体验式学习。如今，我们已经能够发现做市策略、市场状况以及与之相关的利润或亏损之间具有意义的联系。未来，我们将致力于使本研究涵盖更广泛的资产和金融策略。

最后，我们确认了基于社交媒体数据的市场价格预测在回测模拟环境中对做市过程的价值——

在未来的工作中，我们计划通过基于实时交易所数据进行做市来验证其表现。

参考文献

[Raheman 2023] Raheman, A., Kolonin, A., Glushchenko, A., Fokin, A., Ansari, I. 面向波动市场的自适应多策略做市智能体。载于：Goertzel, B., Iklé, M., Potapov, A., Ponomaryov, D.（编）《通用人工智能》。AGI 2022。《计算机科学讲义》（），第13539卷。Springer，Cham。https://doi.org/10.1007/978-3-031-19907-3_24 2023 - - , [2021] Raheman, KNOTH Raheman, A., Kolonin, A., Goertzel, B., Hegyközi, G., and Ansari, I.: 自动化加密金融智能体架构。载于：2021年知识、本体与理论国际研讨会（KNOTH），第10-14页，doi：10.1109/ KNOTH54462.2021.9686345，2021。[Oswald 2023] Oswald, J.T.（2023）。市场预测作为通用人工智能智能体的任务。载于：Goertzel, B., Iklé, M., Potapov, A., Ponomaryov, D.（编）《通用人工智能》。AGI 2022。《计算机科学讲义》（），第13539卷。Springer，Cham。https://doi.org/ 10.1007/978-3-031-19907-3 32 [2018] Tsantekidis, Tsantekidis A. 利用深度学习和静态限价订单簿特征进行价格预测。arXiv:1810.*09965 [*cs.LG*]* 23 2018年10月。[Ganesh, 2019] Sumitra Ganesh, Nelson Vadori, Mengda Xu, Hua Zheng, Prashant Reddy, Manuela VelosoSumitra Ganesh, Nelson Vadori, Mengda Xu, Hua Zheng, Prashant Reddy, Manuela Veloso。多智能体经销商市场中的做市强化学习。arXiv:1911.*05892 [*q-fin.TR*], 14* 2019年11月。[Sadighian, 2019] Sadighian J.：加密货币市场做市中的深度强化学习。arXiv:1911.08647 [q-fin.TR] 20 2019年11月。[Sadighian, 2020] Sadighian J.：扩展加密货币市场做市中的深度强化学习框架。arXiv:2004.06985 [q-fin.TR] 15 2020年4月。[Raheman, AGI 2021] Raheman A., Kolonin A., Ansari I. 自适应多策略做市智能体。载于：Goertzel B., Iklé, M., Potapov A.（编）《通用人工智能》。AGI 2021。《计算机科学讲义》，第13154卷。Springer，Cham。https://doi.org/ 10.1007/978-3-030-93758-4_21，2021。[Vityaev, 2015] Evgenii E. Vityaev。目的性作为脑活动原理 //《预期：从过去中学习》。（编）M. Nadin。《认知系统专著》，第25卷，第13章。Springer，第231-254页，2015。[Kolonin, 2021] Kolonin A.：离散与功能环境中的体验式学习神经符号架构。载于：Goertzel B., Iklé, M., Potapov A.（编）《通用人工智能》。AGI 2021。《计算机科学讲义》，第13154卷。Springer，Cham。https://doi.org/10.1007/978-3-030-93758-4_12，2021。[Kolonin, 2023] Kolonin, A., Raheman, A., Vishwas, M., Ansari, I., Pinzon, J., Ho, A. 应用于市场预测的通用时间序列数据因果分析。载于：Goertzel, B., Iklé, M., Potapov, A., Ponomaryov, D.（编）《通用人工智能》。AGI 2022。《计算机科学讲义》（），第13539卷。Springer，Cham。https://doi.org/10.1007/978-3- 031-19907-3_4，2023。[Deveikyte, 2020] Deveikyte, J., Geman, H., Piccari, C., Provetti, A. 市场波动性预测的情感分析方法。arXiv:2012.05906 [q-fin.ST], 2020。[Vishwas, 2022] Raheman, A., Kolonin, A., Fridkins, I., Ansari, I. Vishwas, M. 用于加密货币市场预测的社交媒体情感分析。arXiv:2204.10185 [cs.CL], 2022