神经随机基于代理的限价订单簿模拟：混合方法论

Zijian Shi 布里斯托
大学 布里斯托尔，英国
ziji
an.shi@bristol.ac.uk

John Cartlidge 布里斯托大
学 布里斯托尔，英国
john.cartlidge@bristol.ac.uk

arXiv:2303.00080v1 [q-fin.TR] 28 Feb 2023

摘要

现代金融交易所使用电子限价订单簿（LOB）来存储特定金融资产的买方报价和卖方报价订单。作为描述资产需求与供给的最细粒度信息，限价订单簿数据对于理解市场动态至关重要。因此，逼真的限价订单簿模拟为解释市场的实证特征提供了宝贵的方法。主流模拟模型包括基于代理的模型（ABMs）和随机模型（SMs）。然而，基于代理的模型往往没有以真实历史数据为基础，而随机模型则往往无法实现动态的代理交互。为克服这些局限，我们提出了一种新颖的混合限价订单簿模拟范式，其特点包括：（1）通过神经点过程模型，在历史限价订单簿数据上对神经随机背景交易者进行预训练，使其表示市场事件逻辑的聚合；（2）将背景交易者嵌入与其他交易代理共同构成的多代理仿真中。我们使用 ABIDES 平台实例化了这一混合 NS-ABM 模型。首先，我们单独运行背景交易者，并展示模拟得到的限价订单簿能够再现一套全面的风格化事实，从而体现逼真的市场行为。随后，我们引入由“趋势型”和“价值型”交易代理构成的群体，使其与背景交易者进行交互。我们表明，这些风格化事实依然存在，并证明了与真实市场实证观察一致的订单流冲击和金融羊群行为。

CCS 概念

• **计算方法** → **代理/离散模型**；**神经网络**；• **应用计算** →**经济学**。

关键词

限价订单簿，市场模拟，神经点过程，基于代理的模型

1 引言

现代金融交易所（例如伦敦证券交易所）和在线商品拍卖平台（例如 StockX）使用连续双向拍卖（CDA）机制来确定资产价格。买方和卖方持续向限价订单簿（LOB）提交订单，订单撮合在其中进行，并最终形成交易。从形式上看，限价订单簿是一个持续更新的限价订单排队系统。买单（即买入订单）和卖单（即卖出订单）按照价格—时间优先级分别排在订单簿的两侧。每当订单价格发生交叉（即新买单的价格高于最低卖方报价，或新卖单的价格低于最高买方报价）时，订单就会被撮合成交易。每当提交新订单或已有订单被取消时，限价订单簿都会更新。这些更新会持续进行，事件之间的时间间隔可能短至纳秒级。从这个意义上说，限价订单簿描绘了与特定金融资产相关的最基础且最精细的供需信息。因此，限价订单簿常被用作金融微观结构研究中的主要数据来源，以探究价格形成机制 [33], 市场的随机属性 [5], 以及高频交易的影响 [35]等主题。

然而，尽管限价订单簿在研究中至关重要，使用历史限价订单簿数据仍存在两个主要问题。首先，由于无法与历史数据互动，因此无法用其进行“假设”反事实分析。因此，基于历史数据对交易算法进行回测，会隐含一个不切实际的假设，即市场不会作出反应。交易大量成交量时，这一假设尤其危险，因为这些交易会“撼动”市场。其次，历史限价订单簿数据的可获取性有限且成本高昂。[1] 模拟和合成生成的数据分别有助于克服这些问题。

限价订单簿仿真和合成数据生成的两种主流模型是基于代理的模型（ABMs）和随机模型（SMs）。基于代理的模型构建交互式交易环境，其中包含具有行为逻辑的异质智能体，这些行为逻辑由人类定义或通过学习获得。尽管定义的智能体通常被建模为现实世界参与者的简化形式，例如做市商、动量交易者和流动性提供者，但基于代理的模型的客观性仍值得质疑，因为我们无法保证仿真会以与现实世界相同的方式运行 [24]。另一方面，随机模型直接从历史数据中学习随机属性，因此在客观性上以现实为依据。先前研究表明，市场特征（例如价格和成交量分布以及市场事件的到达情况）可以通过随机模型加以捕捉，而这些学得的知识可用于生成逼真的合成数据。然而，随机模型的局限在于缺乏交互性。因此，尽管随机模型能够生成无穷无尽的合成数据，但在真实数据上进行回测所涉及的问题依然存在。

本文提出了一种神经随机智能体模型（NS- ABM），用于模拟限价订单簿。NS-ABM 是一种新颖的混合方法论，结合了基于主体的模型和随机模型这两种通用方法。我们的主要贡献总结如下：

(1) 我们提出一种神经随机背景交易者（BT），其行为模拟整个市场汇总后的订单事件。BT 利用先进的状态依赖型并行神经霍克斯过程模型，从历史真实世界的二级限价订单簿数据中学习整个市场的行为模式。结合若干

[1] http://www.nasdaqtrader.com/Trader.aspx?id=DPUS数据

有关订单价格和成交量的实证观察，BT智能体能够随机采样生成逼真的订单事件流。

(2) 我们将 BT 纳入开源 ABIDES [11] 仿真框架。研究表明，BT 能够生成限价订单簿动态，并复现关于现实世界限价订单簿的十项全面风格化事实。以往的基于代理的模型尚未展现出如此高的保真度。

(3) 我们引入了一群采用各种“趋势型”和“价值型”交易策略的交易代理，并证明 BT 能够对其他交易代理引发的内生事件作出符合现实的反应。由此产生的限价订单簿动态仍呈现真实市场的风格化事实，体现了基于主体的模型的行为符合现实。我们还证明，该模型呈现出与真实市场实证观察相似的订单流冲击和金融羊群行为。

2 背景与相关研究

2.1 限价订单簿

连续双向拍卖市场允许市场参与者针对特定资产提交买入或卖出订单，且事件之间的时间间隔不受限制。电子限价订单簿用于记录已提交但尚未执行的订单，并与订单匹配引擎配合，将订单撮合为交易。由于限价订单簿提供了市场中最详尽的供需信息，因此被视为描述市场的终极微观层级 [5]。

限价订单事件 $E(t, s, a, v, p)$ 指定事件时间 t、事件方向 $s \in \{bid, ask\}$、操作 $a \in \{submission, cancellation\}$、成交量 v 和价格 p。每当新事件到达时，限价订单簿都会更新。限价订单簿包含买方报价列表和卖方报价列表，两者均按价格—时间优先级排序，因此买方报价列表首位的买方报价（即最优买价）价格最高，$p^b(1)$，而卖方报价列表首位的卖方报价（即最优卖价）价格最低，$p^a(1)$。最优买价 $p^b(1)$ 和最优卖价 $p^a(1)$ 称为报价价格，且被视为顶层价格。$p^b(1)$ 与$p^a(1)$之差称为买卖价差，$p^b(1)$ 与$p^a(1)$的平均值称为中间价。我们将 $p^b(n)$ 和 $p^a(n)$（其中 $n \in \{2, 3, \ldots\}$）称为深层价格。当新的买方报价 b 以价格 p^b 到达时，若满足 $p^b \geq p^a(1)$，则会与最优卖价成交；否则，b将按价格降序进入限价订单簿的买方一侧。同样，当新的卖方报价 a 以价格 p^a 到达时，若满足 $p^a \leq p^b(1)$，则会与最优买价成交；否则，a将按价格升序进入限价订单簿的卖方一侧。

2.2 限价订单簿仿真

限价订单簿仿真提供了一种生成合成限价订单簿数据并开展交易实验的方法。仿真尤其适用于测试交易算法，并解释真实市场中的一些实证观察结果，例如导致极端价格事件的因素 [36] 以及延迟套利如何影响市场效率 [20, 48]。因此，限价订单簿仿真能够为希望最大化策略盈利能力的市场投资者，以及希望查明市场异常原因并采取预防措施的市场监管者提供见解。尽管存在多种限价订单簿仿真方法，但在此我们将其归为两大类：基于主体的模型（ABM）和随机模型（SM）。

基于代理的模型是进行限价订单簿仿真的常用方法。这些自下而上的模拟包含一个虚拟限价订单簿场所，其中异质交易代理相互交互，限价订单簿动态便从这一系列交互事件中涌现出来。通常，基于代理的模型中的代理类型是对真实市场实体的概括性简化。例如，做市商主体模仿大型证券经纪交易商的角色，在订单簿的买卖两侧提供流动性；而策略性动量交易者或均值回归交易者则模仿投资者跟随价格趋势的常见策略。通过将代理行为建立在现实基础上，代理交互的总体效应能够产生有洞察力的发现，并与真实世界市场的实证研究相一致。例如，Cont [16] 使用基于代理的模型研究了导致资产收益波动率聚集的因素。代理被配置为完全依据感知到的市场波动性做出交易决策。结果表明，市场活动频率与主体阈值行为之间存在联系；而波动率聚集可能是由投资者惰性造成的。Wang 等人 [49] 构建了一个包含零智能（ZI）智能体和启发式信念学习（HBL）智能体的基于代理的模型，以研究欺骗性挂单在价格操纵中的作用。ZI 智能体和 HBL 智能体都利用关于外生基本价值的带噪观测做出交易决策，而 HBL 智能体还利用额外的限价订单簿信息来判断价格何时被高估或低估。结果表明，HBL 智能体依赖限价订单簿的决策机制意味着它们更容易受到欺骗性挂单的误导，因此价格也更容易遭受操纵。McGroarty 等人 [32]开发了一个现实的基于代理的模型，其中包含多种代理类型，包括做市商、流动性消费者、策略交易者和噪声交易者。该模拟生成的数据呈现出真实市场中发现的若干风格化事实，表明其模拟行为具有现实性。然而，尽管基于代理的模型取得了上述成功，人们仍对其主观性表示担忧。尤其是，无法保证真实市场会以与任何特定基于代理的模型相似的方式运行，因为代理的行为模式和参数是主观确定的。此外，一些人认为，尽管采用简单的交易规则，也可能无法准确建模个体的复杂行为 [39]。

另一方面，随机模型通过对总体订单流进行随机假设或观测来模拟限价订单簿。与基于主体的模型不同，随机模型从根本上以真实数据为基础。人们已使用多种随机模型来模拟限价订单簿。Cont 等人[19] 使用独立泊松过程对订单到达和撤单进行建模。研究表明，该模型能够快速从历史数据中进行推断，并可高效计算价格变动等事件的条件概率。研究还表明，尽管假设极少，该模型生成的模拟数据仍能重现真实限价订单簿的若干动态属性。在 [17], 中，限价订单簿被建模为一个马尔可夫排队系统。这种模型形式可以为各种感兴趣的量提供解析表达式，并揭示价格动态与订单流之间的关系。另一方面，一些研究从深度学习的角度探讨随机限价订单簿仿真。例如，[42, 44] 中提出的限价订单簿重建模型使用一种

连续型循环神经网络变体，根据顶层交易与报价数据预测限价订单簿的成交量。该模型通过拼接连续预测，实现了限价订单簿的静态模拟，但忽略了系统的动态事件驱动特征，因此未能重现市场程式化事实。最近，Shi 和 Cartlidge [43] 使用状态依赖并行神经霍克斯过程（sd-PNHP）对限价订单簿事件流进行建模。研究表明，在预测下一个限价订单簿事件的类型和发生时间方面，该模型的表现优于纯随机模型。此外，该模型生成的合成限价订单簿数据比以往模型更逼真，这一点可由其呈现的风格化事实数量证明。尽管取得了这些成功，随机模型仍存在无法实现动态交互的缺点。

本文提出一种混合随机模型—基于主体的模型。我们假设，这种方法兼具两种模型的优点：一种以现实世界数据为基础、呈现现实世界特征且具有交互性的自底向上的限价订单簿仿真。此前已有研究提出结合不同模型的优势 [23], 然而，尝试将限价订单簿的随机模型嵌入交互式基于主体的模型环境的研究仍然不多。其中包括 Panayi 和 Peters [37], , 他们声称其模型是基于主体的模型与随机模型的混合体；但该模型本质上是一个随机模型，只是将订单流归因于虚拟代理，并未提供与随机系统交互的机制。近期，Kumar [27] 提出了一种基于主体的模型，其中嵌入了一个随机做市商，且该做市商会与其他交易代理进行交互。然而，该研究的重点是将随机模型部署为策略交易者以获取利润；其模型并非旨在作为逼真的市场模拟器来研究市场动态。我们发现，与本文最为相似的研究是 [14]；该研究首先使用真实数据训练一个基于条件生成对抗网络（CGAN）的代理，随后将其用作“世界智能体”。之后，该世界智能体被纳入基于主体的模型仿真中，以开展交互实验。然而，从统计学角度来看，CGAN 代理缺乏依据，完全是一个深度学习“黑箱”。此外，也无法通过将其预测准确度与主流模型进行比较来验证 CGAN 模型，

与此同时，sd-PNHP模型可以依据事件到达时间的对数似然和事件类型预测准确率等标准，利用真实数据进行严格验证。因此，我们认为这里存在一个研究空白，并将在本文中尝试填补这一空白。

3 模型构建

用于限价订单簿仿真的NS-ABM主要包含两个方面。首先，该仿真基于代理，我们使用的基于代理的建模框架是开源限价订单簿仿真平台ABIDES。其次，我们利用历史交易数据训练一个神经随机“背景交易者”，其行为逻辑通过sd-PNHP模型学习得到。随后，我们将背景交易者作为代理整合进ABIDES，并引入其他可与其交互的代理交易者。

3.1 基于代理的交互式离散事件仿真（ABIDES）

ABIDES [11] 是一种基于代理的仿真框架，用于生成高保真限价订单簿数据并开展市场微观结构实验。

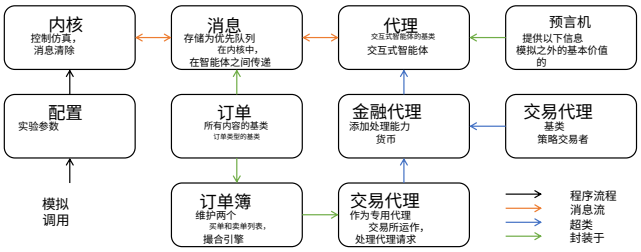

图 1：ABIDES 的模拟工作流程；改编自[11]。

ABIDES 已被应用于多项研究，例如开发和评估交易代理 [26], , 以及调查市场操纵行为 [50]。ABIDES 通过多种方式模拟真实市场环境：(1) 它采用了逼真的消息传递系统，该系统基于纳斯达克公布的股票交易协议 ITCH 和 OUCH；(2) 它对市场环境没有任何假设或限制，例如订单规模或离散事件之间的时间间隔；(3) 它配备了一系列类和函数，可扩展现有代理类型及其操作。图 1 简要展示了 [11] 中所示的仿真逻辑。下文将介绍本文使用的 ABIDES 高频交易代理的两种类型：“趋势”交易代理和“价值”交易代理。

趋势代理假设价格趋势将在不久的将来持续或反转，因此分别称为动量（MM）代理和均值回归（MR）代理。趋势代理通过比较长时间窗口和短时间窗口内的移动平均价格之差，计算当前的价格趋势。趋势代理的交易逻辑如算法 1 所示。这些代理试图维持中性头寸，因此提交的订单规模要么等于能够平仓当前头寸的规模，否则使用标准规模 u。例如，假设某代理持有 -200的股票空头持仓。如果该代理随后决定提交市价买入订单，则订单规模将为 200，以平仓该头寸；相反，如果该代理决定提交市价卖出订单，则订单规模将为 u，以进一步扩大该头寸。通过维持中性头寸，趋势代理试图从高频交易中获利，而不是通过在相对较长的时间跨度内持有大量头寸来赚取资本利得。

价值代理根据对外生于市场的基本价值预言机的观测进行交易 [10]。此类预言机可以是通过随机过程生成的任意时间序列。我们使用 SparseMeanRevertingOracle 类为零智能/HBL 生成基本价值（详见 [10]）。如 [10], 所示，基本价值遵循 Ornstein-Uhlenbeck过程，其在 t_n 时的值表示为：

$$p_{t_n} = \mu + (p_{t_{n-1}} - \mu)e^{-\gamma\delta_n} + u_{t_n} \tag{1}$$

$$u_{t_n} \sim N(0, \frac{\sigma^2}{2\gamma}(1 - e^{-2\gamma\delta_n})) \tag{2}$$

其中 δ_n 表示自上次观测以来经过的时间单位。当 δ_n 增大时，基本价值及其在 t_n处的方差会分别收敛至 μ 和 $\frac{\sigma^2}{2\gamma}$，体现出其均值回复特性。

算法 1趋势代理（做市商和均值回归）的交易逻辑

要求： 窗口大小 l_1 以及 $l_2, l_2 > l_1$，当前股票持仓 h

如果收到来自内核的唤醒信号**则**
  取消所有未成交订单
  向交易代理发送报价价格请求
  从交易代理接收报价价格（$p_t^{a(1)}$，$p_t^{b(1)}$）
  计算中间价 p_t^{mid}并将其追加到代理的内部存储列表 mid_list
  如果 长度(mid_list) >= l_2 **则**
    如果 移动平均l_1 (mid_list) > 移动平均l_2(mid_list) **则**
      如果 代理类型 == MM **则**
        提交市价买入订单，q = 最大值($-h$，u)
      否则如果 类型(代理) == MR **则**
        提交市价卖出订单，q = 最大值(h，u)
      结束如果
    else
      使用逆向逻辑执行步骤 8-11（即，做市商卖出，均值回归买入）
    结束如果
  else
    在内核中排队安排下一个唤醒信号，跳出
  结束 if
  在内核中排入下一个唤醒信号
结束 if

在观察基本价值之前，智能体会先更新内部估计值$\tilde{p}_{t_n}$ 和 $\tilde{\sigma_{t_n}}^2$:

$$\tilde{p}_{t_n} = (1-(1-\gamma)^{\delta_n})\mu + (1-\gamma)^{\delta_n}\tilde{p}_{t_{n-1}} \tag{3}$$

$$\tilde{\sigma}^2_{t_n} = \frac{1-(1-\gamma)^{2\delta_n}}{1-(1-\gamma)^2}\sigma^2 + (1-\gamma)^{2\delta_n}\tilde{\sigma}^2_{t_{n-1}} \tag{4}$$

观察到带噪声 σ_o^2 的基本价值为 o_{t_n} 后，按照贝叶斯方式更新估计:

$$\tilde{p}_{t_n} \leftarrow \frac{\sigma_o^2}{\sigma_o^2+\tilde{\sigma}^2_{t_n}}\tilde{p}_{t_n} + \frac{\tilde{\sigma}^2_{t_n}}{\sigma_o^2+\tilde{\sigma}^2_{t_n}}o_{t_n} \tag{5}$$

$$\tilde{\sigma}^2_{t_n} \leftarrow \frac{\tilde{\sigma}^2_{t_n}\sigma_o^2}{\tilde{\sigma}^2_{t_n}+\sigma_o^2} \tag{6}$$

完成区间值更新后，代理对 $t_n + t_w$ 时的基本价值进行预测:

$$\tilde{p}_{t_n+\Delta t} = (1-(1-\gamma)^{\Delta t})\mu + (1-\gamma)^{\Delta t}\tilde{p}_{t_n} \tag{7}$$

该数值是价值代理用来与实现的股票价格进行比较的值，并在 t_n 时作出交易决策。在这里，代理关注短期（ Δt内）的利润，与动量交易者相同。估计的基本价值代表股票对代理而言的“公允价格”。如果限价订单簿上的当前价格被低估，代理倾向于买入；否则，代理倾向于卖出。一类价值代理完全基于观测到的基本价值作出决策，我们将其称为零智能（ZI）代理；另一类价值代理利用限价订单簿中的额外信息来提高订单执行的可能性，我们将其称为启发式信念学习（HBL）代理。我们有意移除了基于持仓偏好的私人价值设定。因此，代理不再偏好持有多头头寸，以迫使代理专注于盈利能力。也就是说，在没有价格信息时，代理对持有100

算法 2 价值代理（零智能与 HBL）的交易逻辑

要求： 预期最大剩余 r_{max}、回看期 l、当前股票持仓 h

若 收到来自内核的唤醒信号**则**
  取消所有未成交订单
  向交易代理发送报价价格请求
  从交易代理收到报价价格（$p_t^{a(1)}$，$p_t^{b(1)}$）
  从预言机获取带噪观测，并更新内部以贝叶斯方式对当前价值 p_t 进行估计
  对未来基本价值 $p_{t+\Delta t}$进行估计
  对请求的剩余量进行采样 $r \sim$均匀分布 (0，r_{max})
  如果 随机数(0，1) > 0.5 **则**
    提交限价买入订单，q = max($-h$，u)
    如果type(agent) == ZI **则**
      如果 $p_{t+\Delta t} - p_t^{a(1)} > r$ **则**
        $p = p_t^{a(1)}$
      else
        $p = p_{t+\Delta t} - r$
      结束如果
    否则如果 type(agent) == HBL **则**
      计算所有价格层级上的执行概率向量 $Prob$
      $P = (p_{min}, \ldots\ldots, p_{max})$ 在过去的 L笔交易中
      计算预期剩余 $S = Prob * (p_{t+\Delta t} - P)$
      $p = p_{min}$ +argmax$S$
    结束 if
  else
    使用逆向逻辑执行步骤 9-19（即提交限价卖单）
  结束 if
  在内核中排入下一个唤醒信号
结束 if

单位或 –100 单位股票没有偏好。由于趋势代理在ABDIES实现中没有私人价值设定，移除这一设定也有助于进行更好的比较。价值代理的交易逻辑如算法 2所述。

趋势代理和价值代理类型代表了常见的交易策略，在分析模型和实证研究中均得到广泛研究。为便于分析，我们有意选择了一组精简的交易策略，因此本文仅考虑这两种策略型交易代理。不过，在 ABIDES 中加入其他预定义代理类型，或定义新的交易策略，都很容易。对于更复杂市场的此类探索，我们留待未来工作。

3.2 神经随机背景交易者

纯粹的基于主体的模型中，所有智能体都按照人为定义的规则行动，因此可能缺乏客观依据。尽管仿真框架可以设计得与现实世界高度相似（例如，在 ABIDES 中，消息传递机制源自纳斯达克，限价订单簿按照现实世界的规则运行，代理策略的术语也可见于真实市场），但并不能保证其动态特征符合现实。关键在于，智能体的行为模式、决定这些行为的参数，以及智能体之间复杂的交互，共同形成了整体订单流模式。由于无法获知单个交易者的行为（数据是匿名的，且行为无法关联到具体个人），因此无法根据真实市场的汇总订单流学习单个智能体行为的参数。然而，正如 [43], 所展示的，

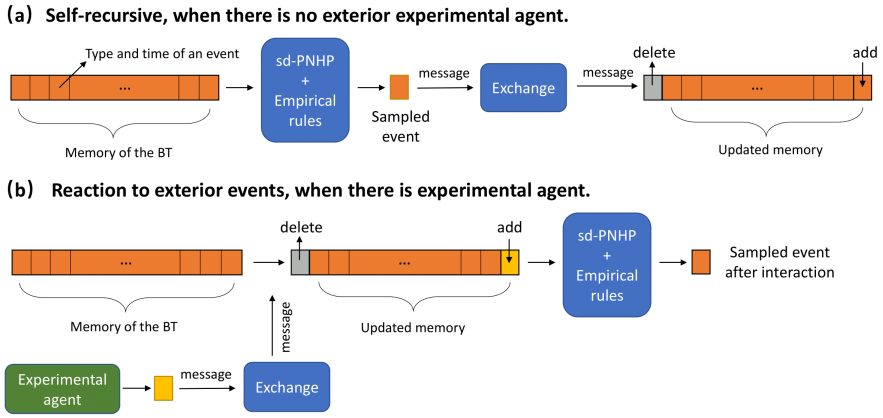

图 2：(a) 展示了 BT 单独运行时如何采样事件。将指定长度的记忆作为 sd-PNHP 模型的输入，并结合有关订单的经验分布，采样一个新事件。随后将该事件发送至交易所；一旦被接受，就会更新到记忆中，以供后续使用。(b) 展示了交互如何发生。其逻辑与 (a) 类似，不同之处在于 BT 会先将实验代理的事件纳入记忆，再采样事件。因此，采样得到的事件会受到其他代理行为的影响。

可以使用 sd-PNHP 模型学习整个市场的整体订单流模式。在这里，我们调整[43] 的方法，以学习真实数据的汇总订单流，然后将该模型部署为基于主体的模型中的自主代理，使其能够与市场中的其他交易代理交互，并适应它们的行为。我们假设，这种“混合式”基于主体的模型方法能够生成更符合现实的市场动态，从而更严格地测试新的交易策略。

为此，我们在 ABIDES 中实现了一个神经随机BT。该代理由一个基于整个市场的历史事件流数据训练得到的 sd-PNHP 模型驱动。代理能够根据指定长度的事件历史，预测下一个事件类型和下一个事件时间。通过不断将新采样的事件纳入记忆并作为输入，代理能够持续生成与真实市场数据高度相似的事件流数据。我们将该代理称为“背景交易者”，原因如下：(1) 当代理单独运行时（作为模拟中的唯一代理），它生成的订单流体现了完整市场的逻辑；(2) 当代理与其他交易代理交互时（即作为多代理仿真的一部分），它产生的反应类似于汇总市场响应。图 2 展示了 BT 单独运行以及与其他代理交互时的逻辑。通过将 BT 定义为 ABIDES 中交易代理类的子类，它继承了与交易所通信、提交和取消订单，以及跟踪其实时盈利能力的全部功能。下文将详细介绍神经随机交易者的逻辑。

对于随机霍克斯过程，某一时刻事件到达的强度率由均值率 μ 加上历史事件产生的、呈指数衰减的累积影响（由 α 和 δ 控制）构成，如公式 8 所示。相比之下，在多变量 sd-PNHP 模型中，某一时刻类型为 k 的事件的强度率，是根据第 k 个连续时间 LSTM 单元的连续潜在状态解码得到的；该状态以指定长度的历史事件和市场状态作为输入，如公式 9 所示。

$$\lambda(t) = \mu + \sum_{h:t_h<t} \alpha * exp(-\delta(t - t_h)) \tag{8}$$

$$\lambda_k(t) = \mathrm{D}_k(h_k(t)) = \mathrm{D}_k(\mathrm{CTLSTM}_k(S, X, t)) \tag{9}$$

$$p_j(t) = P(t_j = t \mid F_{j-}^{S,X}) = \lambda(t)\exp\left(-\int_{t_{j-1}}^{t} \lambda(s)ds\right) \tag{10}$$

根据随机过程理论的基本原理，事件到达时间的概率密度函数可表示为公式 10。模型在历史数据上充分训练后，可以使用 Ogata 瘦化算法等采样方法，抽取最可能的下一个事件类型及其到达时间。在 [43] 中进行的实验表明：（1）该模型在事件类型预测上的准确率可达 50%–60%（对于这一包含四个类别的分类问题——卖单提交、卖单撤销、买单提交和买单撤销——基准准确率为 25%）；（2）该模型可用于迭代采样事件流。结合若干订单价格和订单数量的经验分布后，该模型可用于生成高保真限价订单簿数据，并呈现真实数据中的多种风格化事实。

3.3 实现细节

文献 [43] 展示了首次尝试将 sd-PNHP 作为纯随机模型，用于随机采样限价订单簿事件流并开展限价订单簿仿真。然而，原始实现较为粗糙，缺少与实验代理进行交互所必需的设置。

首先，限价订单簿并未通过索引追踪背景交易者此前提交的订单。给定限价订单簿的初始状态后，每当采样到新事件，实现中只会在订单簿中增加或移除一定成交量的限价订单，而不管某个价格档位上的成交量具体由哪些此前提交的订单

构成。这会导致我们在需要识别哪些此前提交的订单正在成交或被撤销，以及成交或被撤销的订单属于谁时遇到问题。将背景交易者纳入 ABIDES 后，背景交易者和交易所都会为采样到的订单建立索引。这使系统能够追踪特定订单从提交到撤销或成交的全过程，还能利用交易所中存储的代理-订单映射，将相应信息发送给发起订单的智能体。

其次，由于 sd-PNHP模型侧重于从包含五个价格层级的限价订单簿中学习订单模式，当限价订单簿移动到此前未见过的价格层级时，会使用默认订单量（历史平均值）。为确保所有订单均由智能体生成且可由交易所追踪，现已移除此设置。请注意，背景交易者只能生成并响应与限价订单簿顶部五个价格层级相关的事件。如果限价订单簿移动到此前未见过的价格层级（例如，t_{n-1} 时的第6档最优卖价在 t_n时变为第5档最优卖价），该价格层级上的订单数量将从零开始；如果限价订单簿离开了某个价格层级（例如，t_{n-1} 时的第5档最优卖价在 t_n时变为第6档最优卖价），该价格层级上的订单将以撤单的形式逐渐从限价订单簿中移除，而这不会引起背景交易者的进一步响应（因为这些订单已经位于背景交易者的感知范围之外）。

关于在 ABIDES 中对背景交易者的更多实现，我们使用 TradingAgent 的基类来构建背景交易者。该基类的主要功能包括能够接收和发送消息（包括从交易所接收市场信息，以及向交易所提交与订单相关的操作）、提交和撤销订单，以及维护其自身的订单历史。背景交易者订阅市场信息。每当限价订单簿因其自身或实验代理的操作而更新时，背景交易者都会收到一条市场订阅消息，并采样一个事件（包含事件类型、订单统计信息和到达时间）。采样得到的事件不一定会提交至交易所，因为其他实验代理提交的事件可能更早到达。在这种情况下，背景交易者将采样一个新事件，而原始事件将被丢弃。新采样的事件被视为交互下的事件（如图2所示）。此外，还存在紧急设置，以防模拟出现错误。在市场开盘期间，当卖方报价（或买方报价）一侧没有订单时，买卖价差将被设定为一个最小变动单位。如果背景交易者采样到卖方报价（或买方报价）撤单操作，则该操作将自动替换为紧急补充操作，即在顶层价格以100的成交量提交买方报价（或卖方报价）限价单。该机制很少被触发，仅在限价订单簿一侧流动性耗尽时启用。

有关背景交易者（BT）的关键参数列于表1的“初始值”一栏。这些值要么通过最大似然估计（MLE）从数据中学习得到，要么在市场开盘时选定：前五个价格档位会随机填入限价订单（数量为100–1000），直到每个价格档位的订单数量达到一个随机汇总值（数量为 $1.5\times10^4-2.0\times10^4$，该值由数据集中前五个价格档位的经验平均值确定）。这些订单的时间间隔设为 10^{-6} 秒，以便快速填充；在此期间不会发布任何市场信息，也不会有智能体作出反应。这些订单可视为开盘前订单，由此形成的限价订单簿将作为后续事件不断累积的初始状态。

4 实验

4.1 模型学习与参数设置

与 [43]一样，sd-PNHP模型基于LOBSTER数据集进行学习。该数据集包含三只股票连续五天的真实世界限价订单簿事件流数据，股票代码分别为INTC（英特尔）、MSFT（微软）和JPM（摩根大通）；数据由金融数据提供商LOBSTER提供。[2] 平均而言，每只股票每个交易日约有50万次事件更新，限价订单簿数据涵盖五个价格档位，而非完整市场深度。我们选择基于INTC数据训练的模型，作为后续实验所用的主模型。

价格和成交量幂律分布的参数通过最大似然估计在真实数据上学习得到。其他参数，例如所有订单中市价单所占的比例，以及限价单缩小买卖价差的概率，也根据真实数据估计。简而言之，对于背景交易者（BT），sd-PNHP模型决定订单流模式，而学习得到的随机参数则决定订单特定的统计特征。实验代理的参数由人工设定，参考了ABIDES中的原始设置。

4.2 ABIDES配置

4.3 敏感性分析

首先，我们对一个所有订单流均由背景交易者（BT）生成的系统进行敏感性分析。我们考察与订单价格和成交量的经验分布、所有订单中市价单所占比例，以及用于确保订单簿不会耗尽流动性的若干对照参数相关的关键参数。需要注意的是，由于神经参数具有“黑箱”特性，主导订单流模式的神经参数未纳入敏感性分析。涉及的具体参数列于表1，分别为：(1) P：订单价格幂律分布的指数；(2) $V1$：顶层价格（报价价格）处订单数量幂律分布的指数；(3) $V2$：深层价格（劣于报价价格的价格）处订单数量幂律分布的指数；(4) Mi：市价单失衡指数（0表示均衡，±100%表示所有市价单均为买单或卖单）；(5) Mo：市价单成交量幂律分布的指数；(6) Lb：每个价格层级成交量的下界值。当成交量低于此值时，后续限价单数量将被强制增加1000，以确保市场中有充足的流动性；(7) Ip：当买卖价差大于1时，限价单落在价差范围内（比最优买价高一个最小变动单位，或比最优卖价低一个最小变动单位）的可能性。买卖价差记作 sp。

我们采用 [32] 中所实施的 Sobol全局敏感性分析。在这种基于方差的分析中，关于 $x=(x_1,\ldots,x_n)$ 的函数 $f(x)$ 的方差分析表示为：

$$f(x)=f_0+\sum_{s=1}^{n}\sum_{i_1<\ldots<i_s}f_{i_i\ldots i_s}(x_{i_1},\ldots,x_{i_s}) \tag{11}$$

其中，第 s 个求和项表示变量 x_{i_1}、…… x_{i_s} 对函数输出产生的第 s 阶协同效应。因此，$f(x)$ 的总方差和偏方差可表示为：

[2]样本数据集可在 https://lobsterdata.com/info/DataSamples.php 找到

表1：敏感性分析的参数

参数	初始值 ($sp = 1$ / $sp > 1$)	波动范围
P - 价格分布	1.5 / 4.7	± 0.25
$V1$ - 成交量分布（顶部）	0.9 ~1.2	± 0.25
$V2$ - 成交量分布（深部）	0 ~1.8	± 0.25
Mi - 市场失衡	0	± 100%
Mv - 市场波动率分布	1.2 / 1.6	± 0.25
Lb - 下界	12500	± 2500
Ip - 内部价差概率	0.05	± 0.025

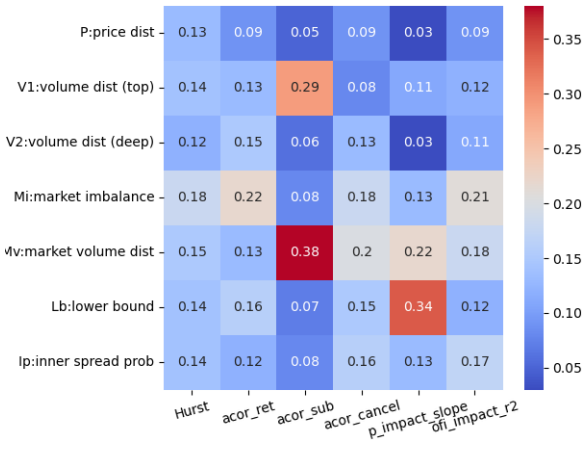

图3：敏感性分析热力图。

$$D = \int (f(x) - f_0)^2 \rho(x) dx \tag{12}$$

$$D_{i_1 \ldots i_s} = \int f_{i_1 \ldots i_s} \rho(x_{i_1}, \ldots, x_{i_s}) dx \tag{13}$$

变量 x_i 对应的总方差及其总敏感性指数可计算为：

$$D_i^{tot} = \sum_{s=1}^{n} \sum_{\langle i \rangle} D_{i_1 \ldots i_s} \tag{14}$$

$$S_i^{tot} = \frac{D_i^{tot}}{D} \tag{15}$$

其中，符号i对所有包含 i的 D 项求和。Sobol[45] 提供了一种高效的蒙特卡洛方法来计算这些指数。根据该方法，从输入空间中均匀抽取 x。随后，我们对 x的每个输入元素添加随机扰动，并使用所有这些 x 模拟 $\dim(x)$ 个 $+1$ 限价订单簿副本。每个限价订单簿相当于一小时的数据，包含约 30 万次事件更新。总共生成 $100 * (\dim(x) + 1)$个限价订单簿样本。我们使用限价订单簿的选定随机属性来评估系统的敏感性，如 [32]所示：(1) 波动率 [25, 30]的赫斯特指数；(2) 中间价收益率 [7]的自相关；(3) 订单提交 [30]的订单符号一阶滞后自相关；(4) 订单撤单 [30]的订单符号一阶滞后自相关；(5) 价格冲击函数 [31]的最佳指数 β；以及(6) 订单流不平衡函数 [18]的 R 平方值。前四项指标与订单流的记忆性或由此产生的中间价序列有关，最后两项指标则与市场价格形成机制有关。图3展示了对敏感性指数标准化后的热力图。

从图3可以看出，对所考察的随机属性产生影响的两个最重要参数是：(1) 市价单成交量分布的指数；以及 (2) 市价单百分比不平衡。在 [32], 中，有研究认为，市价单成交量分布的上限是影响最大的参数，而其影响最显著的随机属性是赫斯特指数和价格冲击函数的指数。市价单成交量分布的指数和市价单成交量的上限都会直接影响市价单的规模。因此，我们发现，尽管所采用的具体方法不同， [32]的结论与我们的发现一致。

4.4 风格化事实

经济学中的“风格化事实”是指具有高度一致性的经验发现（例如，在广泛的金融工具、市场和时间段中均如此），以至于人们将其视为事实。这类事实可用于验证经济模拟的逼真度。在本节中，我们将模拟限价订单簿的行为与十多项风格化事实构成的综合列表进行比较。我们仅使用背景交易者生成所有订单流，采用表1所示的参数设置，并将波动设为零（即所有数值均为最初学习得到的值，未经过扰动）。模拟数据和真实数据的结果均取10个样本的平均值。

我们成功复现了以下风格化事实：

绝对收益的赫斯特指数。这一事实表明，金融市场时间序列 [15]中是否存在长程记忆。可以对绝对收益的时间序列应用去趋势波动分析 [38]，以计算赫斯特指数。赫斯特指数处于（0.5,1）范围内表明存在长记忆。实证研究表明，股票市场中的赫斯特指数大于0.5 [25]。我们发现，模拟数据中的指数为0.53，而真实数据中的指数为0.61。

订单符号序列的自相关。这一事实表明，提交订单和撤单的订单符号序列中分别存在正自相关。实证研究表明，自相关系数大致处于（0.2,0.3）范围内 [30]。我们发现，在模拟数据和真实数据中，自相关系数均具有显著性。在模拟数据中，我们发现提交订单和撤单的系数分别为0.25和0.18。对于真实数据，这两个系数分别为0.41和0.35。

订单流失衡影响。这一事实表明，订单流失衡（OFI）往往会导致价格发生变化 [18]。供需失衡通过十秒间隔内增强买方的事件（买单提交和卖单撤销）与增强卖方的事件（卖单提交和买单撤销）之间的差值来衡量。收益率与订单流失衡（OFI）之间回归的R平方值平均为

[18]中的0.65。在这里，模拟数据中的R平方值为0.64，真实数据中的R平方值为0.68。

价格冲击函数。 这一事实表明，交易量对价格变化的影响呈凹性。实证研究表明，交易量对报价价格变化的影响在成交量较小时随成交量变化增加得更快，而在成交量较大时增加得更慢。交易量对数与价格变化对数之间拟合曲线的斜率范围为 (0.1,0.5)，并且由于市场协议的不同，该斜率在不同市场之间存在差异 [31]。根据模拟数据计算出的斜率为 0.25，而根据真实数据计算出的斜率为 0.11，二者均符合凹曲线特征。

此前在 [43] 中验证的事实：

中间价演化。 这一事实表明，流动性金融资产的中间价演化基本遵循随机游走，并且中间价在任何交易时段内都保持波动 [29]。如图 4(a) 所示，模拟数据和真实数据的中间价均在大约 10 分钟的时间间隔内波动。

收益率序列自相关。 这一事实反映了“有效市场”假说 [22], , 表明流动资产的价格变动不具有显著且强烈的自相关。对数收益率时间序列的自相关绝对值 $f(\tau) = \mathrm{corr}(r_{t+\tau,\Delta t}, r_{t,\Delta t})$ 小于 0.1，并且随着时间滞后的增加，该系数趋近于零 [15]。其他研究发现，收益率序列的自相关系数较弱但具有显著性 [46]。对于模拟数据，我们发现，滞后一期自相关约为 -0.1，并且对于频率为一秒的数据，随着滞后的增加会快速衰减。对于真实数据，一些样本显示出较弱但具有显著性的自相关，而另一些样本则未表现出显著的自相关。

对数收益率的正态性。 这一特征表明，资产对数收益率的分布服从正态分布；同时，采样频率从低频变为高频时，峰度会增加 [47]。图 4(c) 显示，采样频率较高（Δt = 1 秒）和较低（Δt = 1 分钟）时，$r_{t,\Delta t}$ 的分布均可用高斯分布拟合。高频收益率的分布峰度较高、尾部较低（峰度为 > 10），而低频收益率的分布峰度较低、尾部较高（峰度为 < 1）。

事件间隔时间。 这一特征表明，事件间隔时间的分布服从指数分布或威布尔分布 [1]。图 4(d) 展示了时间分布的经验密度曲线（蓝线），并使用最大似然估计分别拟合指数分布（红色）、威布尔分布（绿色）和指数化威布尔分布（橙色）。模拟数据和真实数据均以指数化威布尔分布拟合效果最佳（詹森-香农散度分别为 0.22 和 0.27）。

波动率与成交量正相关。 这一事实表明，对数收益率的标准差$\sigma_{\tau,\Delta t}$ 与成交量 V_τ 呈正相关，也就是说，大成交量的交易活动可能会引发更高的波动率 [9]。在 [47], 历史数据的相关系数均值约为 0.4。图 4(b) 绘制了以分钟为尺度的标准差与平均交易量。模拟数据和真实数据的相关系数分别为 0.57 和 0.72，这证实了这一事实的存在。

波动率聚集。这一特征表明，高波动事件往往会在时间上聚集。用于量化这一特征的函数为 $f(\tau) = \mathrm{corr}(r^2_{t+\tau,\Delta t}, r^2_{t,\Delta t})$ [15]。该函数保持为正值，并随着时间延迟 τ 的增加而呈下降趋势。图 4(e)证实，模拟数据和真实数据（Δt = 1 秒）均表现出这一特性，且与 [15]所示的情况相似。

我们无法再现以下风格化事实：

波动率与收益负相关。这一特征也称为“杠杆效应” [6], , 表明波动率与资产收益负相关。这里通常使用的波动率是根据特定波动率指数（例如 VIX）或金融衍生品价格推导出的隐含波动率。对于模拟资产，不存在隐含波动率。因此，我们遵循 [21], , 考察已实现波动率（定义为对数收益率平方之和）与收益之间的关系。我们发现，模拟数据和真实数据中，这两个变量之间均未呈现显著的负相关性。这可能表明已实现波动率并不能很好地替代隐含波动率。尽管此前已有研究使用基于主体的模型证明了杠杆效应 [12], , 但这种情况并不常见。 [12], 指出，许多基于代理的模型无法再现这一特征，可能是因为模拟中缺乏非对称交易行为。

参考 [14],，我们还利用了模拟限价订单簿的一些数值特性。这些特性在不同金融市场和金融资产之间差异很大，通常无法用具有公认参数范围的特定分布来概括。因此，我们将 BT 智能体生成的模拟数据与用于训练该智能体的真实数据进行比较，而不是直接与 [14] 进行比较。

买卖价差随时间的变化。 由于模拟数据和真实数据都来自市值相对较低的高流动性股票，买卖价差随时间基本维持在一个最小变动单位，如图 4(f) 所示。只有当市价单吃掉或代理取消了所有停留在最优价位上的订单时，买卖价差才会大于一个最小变动单位。

限价订单提交的流入成交量。 流动性较高的金融资产通常具有较大的限价单流入成交量，且成交量会随时间波动。从图 4(g) 可以看出，模拟数据和真实数据都呈现出较大的流入成交量和较高的波动率；模拟数据的均值相对较高，而相对变异程度较低。这些差异主要源于模拟中将限价订单提交的分布形式设定为稳定分布，而在真实市场中，此类特性的分布可能会随时间动态变化，具体取决于市场

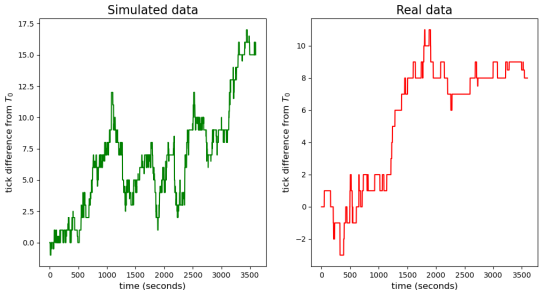

(a) 模拟数据与真实数据的中间价演化。

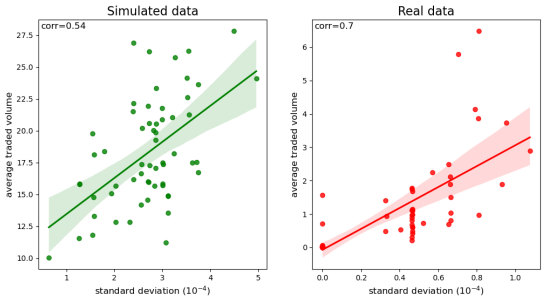

(b) 波动率-成交量：模拟数据（左）与真实数据（右）中，收益率标准差和平均成交量呈正相关。

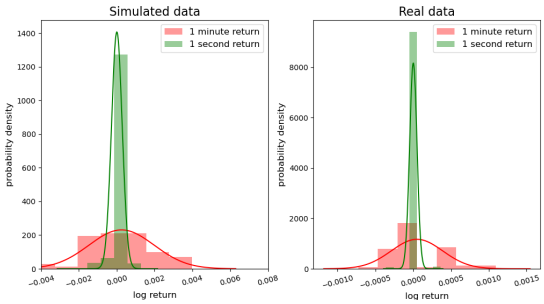

(c) 对数收益率：模拟数据（左）与真实数据（右）的对数收益率均服从正态分布。随着采样频率提高，峰度也随之增加。

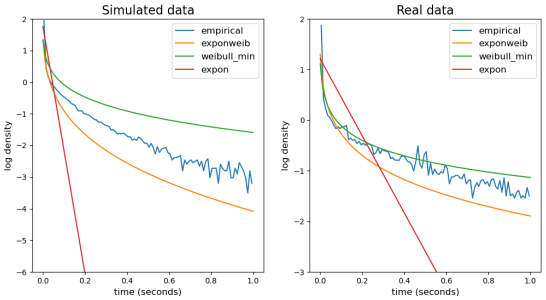

(d) 到达间隔时间：模拟数据（左）与真实数据（右）的最佳拟合分布均为指数化韦布尔分布。

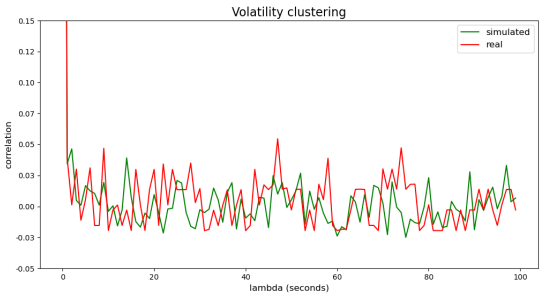

(e) 波动率聚集：模拟数据（绿色）；真实数据（红色）。绝对收益率在较短时间滞后下呈相关性，随着时间滞后增加，相关性逐渐衰减至零。

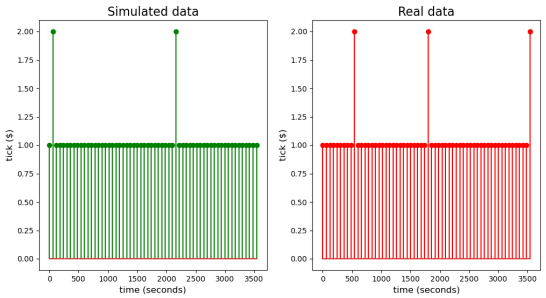

(f) 买卖价差：随着时间推移，买卖价差主要为一个最小变动单位。

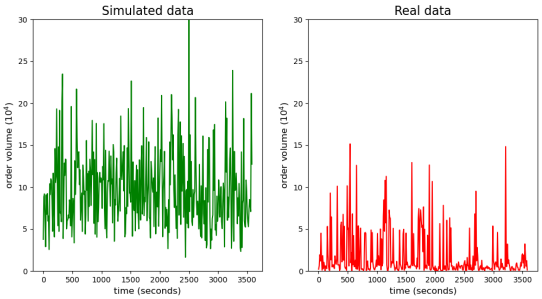

（g）报价上的流入订单量：模拟数据（左）和真实数据（右）均显示出较高且波动较大的流入订单量；模拟数据（左）的均值更高，但相对变异更低。

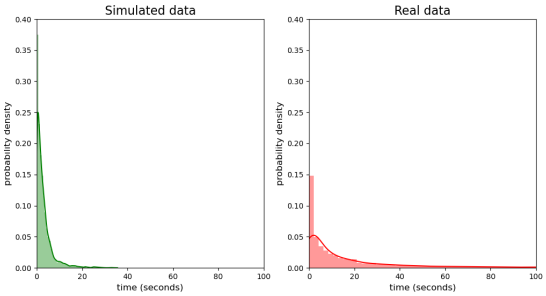

（h）首次成交时间的幂律分布。

图 4：模拟和真实限价订单簿数据的风格化事实与数值特性验证。

条件下，无法得出稳定的分布形式。

首次成交时间。 首次成交时间是指订单提交至部分成交之间的时间间隔。该指标表明资产是否具有流动性，流动资产的首次成交时间通常较短。此处，模拟数据和真实数据中大多数订单的首次成交时间均不到一秒，如图 4(h) 所示。实证研究还表明，首次成交时间服从幂律分布 [1]，此处模拟数据和真实数据均符合文献结论（KS检验 p 值 < 0.05）

4.5 实验代理交互

4.5.1 交互实验设置。 通过将采用各种交易策略的智能体纳入ABIDES框架，与背景交易者进行交互，我们可以了解系统对外部刺激的反应，以及这些反应与真实市场的比较情况。此处考虑五项标准：(i) 智能体的平均盈利能力（不考虑交易成本）；(ii) 智能体交易量占市场总交易量的比例；(iii) 实际中间价时间序列的标准差；(iv) 背景交易者的卖买订单失衡：以 $\max(AS+BC,\ BS+AC)/\min(AS+BC,\ BS+AC)-1$ 衡量，其中 $AS,\ AC,\ BS,\ BC$ 分别表示卖单提交、卖单撤销、买单提交和买单撤销的数量；以及 (v) 价值代理的内在股票基本价值与实际股票价格之间的相关性。

每种实验条件重复 20 次，并取均值。结果如表2所示。我们将智能体数量设为 $n \in \{1,\ 15,\ 50\}$，并将订单流冲击设为 是（即 BT 会对智能体订单作出反应）。作为对照组，我们还比较了订单流冲击为 否（即 BT 不会对智能体订单作出反应）的 $n = (15)$ 个智能体市场。除非另有说明，智能体群体均为同质群体。

*4.5.2 ABIDES*配置。 考虑四类代理：做市商（MM）、均值回归（MR）、零智能（ZI）和HBL。为确保公平比较，所有代理均按照指数方案（泊松过程）唤醒，平均间隔为 $\Delta t = 30secs$。实验代理产生的平均订单事件数占市场全部订单事件数的比例范围为 $[0.1\%,\ 5\%],$，从而确保由背景交易者（BT）产生的市场动态不会被实验代理主导。其他参数为：$l_1 = 20$、 $l_2 = 50$、 $r_{max} = 5$、 $l = 8$。对于ABIDES相关配置，我们参考参考市场仿真配置示例文件。我们设置：均值 $\mu = 10^3$、 $\sigma^2 = 2 \times 10^{-10}$、回归速率 $\gamma = 10^{-12}$。原始默认值分别为：10_5、 10^{-8}、 1.7×10^{-16}。由于我们的初始资产价值较低，为10英镑，因此降低了 μ 和 σ^2。我们提高 γ，使预言机在1小时的模拟窗口内表现出更强的均值回归。观测方差设置为 $\sigma_o = 10$。 $R_min = 0$、 $R_max = 5$、 $eta = 1$ 用于控制代理的贪婪程度。代理的持仓限额和初始现金设置得足够大，使其决策不受这些因素限制。除非另有说明，以下所有发现均由Wilcoxon符号秩检验支持（p值<0.05），检验方法为比较组 $n = 1$ 与组 $n = 50$中的统计量，或比较组 $n = 15$ 与组 $n =$ （15）。

4.5.3 羊群效应。 市场实证研究已充分记录金融羊群行为这一现象：投资者倾向于跟随市场中的群体或趋势，而不是进行自己的分析 [8, 51]。在此，我们参考表2，考察持有相同交易策略的代理数量发生变化时，对智能体盈利能力和限价订单簿行为的影响。

就智能体盈利能力（i）而言，我们发现，在同时包含趋势策略和价值策略的市场中，平均盈利能力会随着智能体数量的增加而提高。关于新兴市场和效率较低市场的实证研究表明，羊群行为的强度与交易盈利能力呈正相关，尤其是对趋势策略而言 [3, 13]。对多种技术交易策略盈利能力的研究还发现，提高策略所依据数据的频率可以提升交易策略的盈利能力 [40]。此外，采用某种特定趋势策略（如动量交易）的智能体越多，市场价格就越容易朝有利（即可预测）的方向受到影响。在所有智能体中，做市商（MM）获得的利润最高。这些利润主要来自引发极端单向价格变动后股票头寸产生的资本利得，因为 MM 智能体在动量引爆后很少会对头寸进行平仓。

就限价订单簿波动性 (iii) 而言，我们发现，增加做市商代理的数量会导致波动性上升，而其他类型的代理则会产生相反的效果。对于动量交易者来说，这一结果并不意外，因为价格变动会推动价格沿同一方向进一步变动。对真实市场的实证研究表明，极端市场条件下的羊群行为更为强烈，这种现象由动量交易行为引发，并可能导致市场崩盘等尾部事件 [4]。 [4] 的作者认为，同质化交易行为更可能在短时间内引发价格过度反应，使价格偏离长期均值。相比之下，均值回归智能体和价值代理遵循均值回归基本价值预言机。因此，增加智能体数量往往会降低市场波动性。

就基本价格与实现的限价订单簿价格之间的相关性 (v) 而言，实证研究表明，高频交易者羊群行为的强度越高，其订单流的相关性往往越强 [41]，，从而赋予他们更大的价格影响力。关于期货市场的研究也表明，高频交易者有助于价格向基本价值收敛 [28]。由于价值代理根据其内在基本价值与实际股票价格的比较进行交易，增加智能体数量本质上会增强这一群体推动价格向基本价值靠拢的能力。我们可以从零智能和 HBL 的相关性上升中看到这种羊群行为的影响。请注意，仅包含趋势代理的市场中，基本价值与实现的限价订单簿价格之间的相关性为零。这是意料之中的，因为这些交易者不会考虑基本价值。

4.5.4 订单流冲击。我们可以利用 BT智能体（iv）生成的订单失衡统计量，判断智能体是否会影响订单流。通过将 $n = 15$ 与对照组 $n = (15)$进行比较，可以清楚地看到，当订单流冲击设置为*True*时，订单流中的失衡程度显著更大。

在由趋势代理主导的市场中，订单流冲击表现为引发更多趋势跟随事件（即推动价格进一步偏离，或将价格拉回均值）。我们

表2：包含一个背景交易者（BT）和 n 个 T型同质交易代理的市场中的智能体与限价订单簿（LOB）统计数据。括号中显示 n 时，实验在无订单流冲击的情况下进行。标有 * 的指标为 10^{-3}。

	（i）盈利能力*				（ii）交易比例*				（iii）中间价的标准差				（iv）订单失衡*				（v）相关性			
T \ n	1	15	(15)	50	1	15	(15)	50	1	15	(15)	50	1	15	(15)	50	1	15	(15)	50
MM	23.1	43.1	22.7	91.1	2.0	25.2	27.8	67.2	13.4	24.6	14.0	47.1	6.9	19.6	4.6	55.5	0	0	0	0
MR	-15.2	-7.9	-20.3	0.4	2.3	34.0	29.9	113.8	12.2	8.1	10.9	3.9	7.9	15.1	7.9	27.2	0	0	0	0
ZI	-6.0	-5.5	-7.4	-0.7	1.3	13.9	14.2	43.9	11.7	9.7	10.4	5.0	6.2	9.3	7.2	21.2	0.12	0.18	-0.22	0.56
HBL	-4.2	-4.1	-6.3	0.8	1.0	13.1	13.1	44.2	13.4	9.4	9.6	4.1	6.3	11.0	8.4	26.2	-0.04	0.06	0.06	0.58

可以从中间价的波动率（iii）中看到这种影响。当不考虑订单流冲击时，充斥着MM交易者的市场，其波动率往往会被低估；而充斥着MR交易者的市场中，同一统计量则往往会被高估。MM市场中波动率被低估，是因为忽略了动量引爆这一实证发现 [2]。动量引爆表明，投资者往往会跟随高频交易者形成的价格趋势。按照类似的逻辑，MR市场中被高估的波动率，也源于未将市场对均值回归订单的反应纳入考量。

对真实市场的研究表明，大型机构“价值”交易者对价格发现有重要贡献 [34]。我们在模拟结果中观察到了类似的效应。我们发现，市场中价值代理数量增加，会使实现的限价订单簿价格与基本价值 (v) 之间的相关性增强。此外，在排除订单流冲击的对照组中，相关性较低。这一结果表明，纳入订单流冲击有助于模拟价值代理在价格发现中的作用。

4.5.5 代理策略之间的竞争。为了解策略交互，我们还在存在订单流冲击的情况下进行了异质性实验：(1) 包含 15 个 MM *vs* 15 MR 的“趋势”市场；以及 (2) 包含 15 个 ZI *vs* 15 HBL 的“价值”市场。在趋势市场中，我们发现两种策略的利润都低于其在同质市场中产生的利润，因为这两类智能体相互竞争，试图使价格朝各自有利的方向变动。此外，与同质 MM 市场相比，市场波动性下降了近 50%，这表明均值回归智能体产生了均值回归冲击。在价值市场中，两种策略的利润与各自同质市场中的利润相比，没有显著差异。不过，相对而言，HBL 的盈利能力仍高于 ZI。这并不令人意外，因为与 ZI 相比，HBL 的交易策略相对更复杂。

4.5.6 存在交互时的风格化事实。最后，我们测量了模拟市场中的风格化事实，其中背景交易者通过订单流冲击与智能体进行交互。我们考虑包含各类交易者的同质市场，其中 $n = 15$ 且订单流冲击设为真。结果如下：(1) 赫斯特指数： $[0.48, 0.65]$；(2) 订单方向自相关：提交订单时为 $[0.24, 0.26]$，撤单时为 $[0.17, 0.18]$；(3) OFI决定系数： $[0.54, 0.71]$；(4) 价格冲击函数斜率： $[0.18, 0.48]$。此外，模型还呈现了此前在 [43] 中验证的六项风格化事实。

4.6 系统的响应性

这里，我们严格遵循 [14] 的方法来检验系统对价格冲击的响应能力。我们引入一个按成交量百分比（POV）交易的代理，用以模拟可能推动市场价格的大额交易者。POV代理由两个参数定义：时间间隔 T秒，以及市场成交量的百分比 λ。在 t时，POV被指示买入/卖出总成交量$V = \lambda M$，其中 M 表示整个市场在前 T秒内的总交易量。POV会尝试在接下来的 T秒内交易 V的成交量，并将其拆分为多个较小订单。

我们进行时长为一小时的实验，并将 POV 设置为在时间 $t = 1800$ 秒时开始交易，交易间隔为 $T = 600$ 秒；也就是说，POV 在最初 30 分钟内不执行任何操作，随后在第 30 至 40 分钟之间集中交易，之后直到模拟结束都不再交易。我们探究增加交易量所带来的价格冲击，其中 $\lambda \in [0.01, 0.1, 0.2, 0.5]$。

对于每组实验，我们在以下三种条件下运行模拟：（1）仅包含 BT智能体 的市场。此时不存在 POV代理，因此我们能够追踪市场在不受影响时的演变过程；（2）包含 POV代理 和 BT智能体 的市场，并将其配置为不产生订单流冲击，使 BT 不会对 POV 发布的外生订单作出反应。在这种情况下，市场中的任何价格变化都直接源于 POV 的订单提交；（3）包含 POV代理 和 BT智能体 的市场，并将其配置为产生订单流冲击。在该系统中，市场价格的变化既源于 POV 的订单提交，也源于 BT 的响应性市场行为。

通过比较配置 (1) 和 (2) 之间市场价格的差异，我们可以研究仅仅向市场中加入订单所产生的价格冲击，并将这种价格差异称为“纯粹”价格冲击。这种影响类似于传统的回测：订单消耗订单簿中的流动性，且不会被补充，因为市场无法作出响应。通过比较配置 (2) 和 (3) 之间市场价格的差异，我们可以研究市场对 POV 订单数量的响应。我们将这种“额外”的价格冲击称为“订单流”冲击。将总价格冲击分解为这两个组成部分的做法独具特色，与 [14] 采用的方法不同。

结果如图5所示：左侧展示的是通过计算（1）和（2）中生成的中间价之差得出的“纯粹”影响，右侧展示的是通过计算（2）和（3）中生成的中间价之差得出的“订单流”影响。黑线、红线和灰色阴影区域分别表示均值、

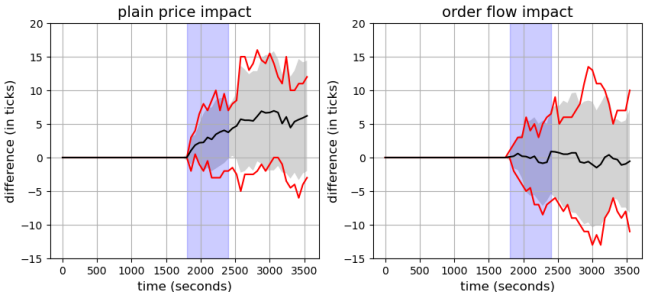

(a) 当 $\lambda = 0.01$时的中间价差

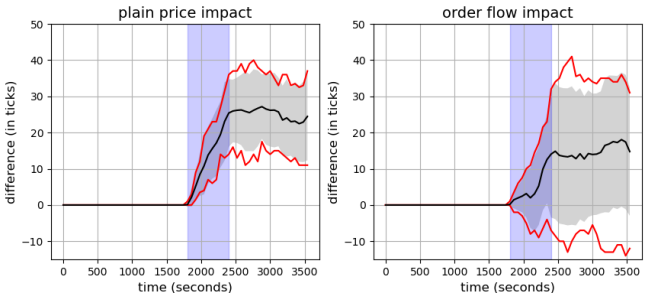

(b) 当 $\lambda = 0.1$时的中间价差

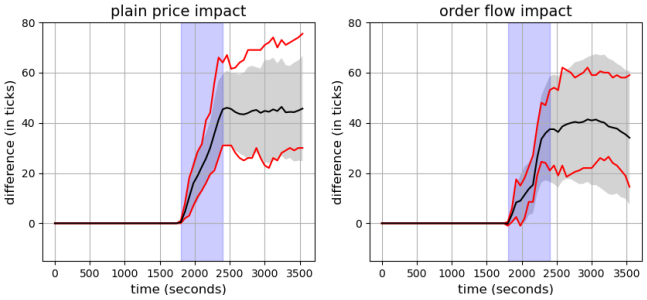

(c) 当 $\lambda = 0.2$时的中间价差

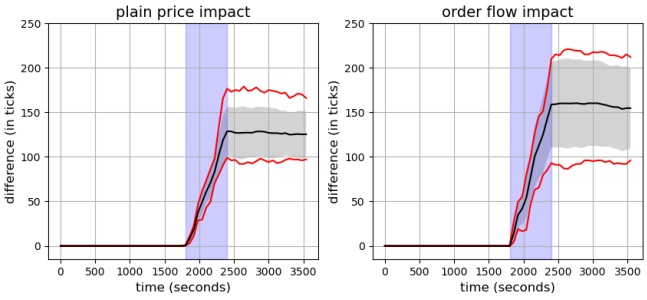

(d) 当 $\lambda = 0.5$时的中间价差

图5：普通价格冲击和订单流冲击对资产价格的影响（占成交量的百分比） λ 变化。

第10和第90百分位数，以及均值上下一个标准差的范围。POV代理在蓝色阴影区域内提交订单。每个模拟重复进行10次，且POV代理仅提交买单。

对于普通价格冲击，我们看到 POV 交易时价格会上涨，并且随着 λ单调增长。价格冲击是永久性的，即使 POV代理停止交易后仍会持续存在。对于订单流冲击，我们看到，当 $\lambda = 0.01$ 较低时，市场不会作出反应。随着 λ 增加，订单流冲击呈超线性增长。这表明市场会对买方压力增加作出不利反应，推动市场价格升至高于原本水平。

5 结论与未来工作

我们提出了用于真实限价订单簿仿真的混合 NS-ABM 模型，并使用 ABIDES 框架实现了该模型 [11]。NS-ABM 将基于主体的模型的优势与数据驱动的仿真方法相结合，其中包含一个基于真实数据预训练的神经随机BT。研究表明，BT交易者能够真实地模拟现实世界的限价订单簿动态，并近似再现了十项风格化事实——即市场中经验证观察到且被视为事实的属性（见第 4.4 节）。此外，BT交易者还能够对内生市场事件作出真实反应；在向仿真中加入趋势交易代理和价值交易代理群体后，风格化事实依然成立（见第 4.5.6 节）。由于 NS-ABM 模型能够真实地复现市场特征，因此无需再加入那些用于近似刻画市场动态的随机“噪声”代理群体（例如 [32]）。NS-ABM 还可以充当“动态回测”框架，使单个交易策略能够基于历史数据进行评估，并且市场能够根据该交易策略的行为作出真实反应。

在我们进行的实验中，使用均值回归随机过程生成了一个外生的基本价值。不过，ABIDES 支持使用历史数据作为基本价值。采用这种配置，NS-ABM 为金融交易算法的动态回测这一“圣杯”提供了一条潜在路径：在这种回测中，待测策略生成的交易事件会对交易产生影响。此外，开展更多样化的交互实验也很有意义，例如纳入更多异质交易策略的模拟，以观察各策略如何相互影响，以及由此产生的市场统计数据如何变化。就背景交易者（BT）而言，我们也希望探究能否复现训练数据中嵌入的结构性变化（例如市场崩盘），从而有望在限价订单簿仿真中复现更真实、甚至异常的市场动态。我们计划在未来的工作中探索这一令人振奋的研究方向。

致谢

ZS 的博士学位由中国国家留学基金管理委员会与布里斯托大学联合奖学金资助。

参考文献

[1] Frédéric Abergel、Marouane Anane、Anirban Chakraborti、Aymen Jedidi 和 Ioane Muni Toke。2016。《限价订单簿》。剑桥大学出版社，英国剑桥。[2] Bruno Biais、Thierry Foucault 等。2014。高频交易与市场质量。《银行家、市场与投资者》128，1（2014），5–19。[3] Sushil Bikhchandani 和 Sunil Sharma。2000。金融市场中的羊群行为。《国际货币基金组织工作人员论文集》47，3（2000），279–310。

[4] Ekkehart Boehmer、Dan Li 和 Gideon Saar。2018。高频交易公司的竞争格局。《金融研究评论》31，6（2018），2227–2276。[5] Jean-Philippe Bouchaud、Marc Mézard 和 Marc Potters。2002。股票订单簿的统计特性：实证结果与模型。《定量金融》2，4（2002），251。[6] Jean-Philippe Bouchaud 和 Marc Potters。2001。金融市场的更多风格化事实：杠杆效应与下行相关性。《物理学A辑：统计力学及其应用》299，1-2（2001），60–70。[7] Jean-Philippe Bouchaud 和 Marc Potters。2003。《金融风险与衍生品定价理论：从统计物理学到风险管理》（第2版）。剑桥大学出版社，剑桥。[8] Naomi E Boyd、Bahattin Büyükşahin、Michael S Haigh 和 Jeffrey H Harris。2016。羊群行为的普遍性、来源及影响。《期货市场杂志》36，7（2016），671–694。[9] Olivier Brandouy、Angelo Corelli、Iryna Veryzhenko 和 Roger Waldeck。2012。对金融风格化事实形成过程中“零即足够”假说的重新检验。《经济互动与协调杂志》7，2（2012），223–248。[10] David Byrd。2019。解释基于代理的金融市场模拟。arXiv: 1909 11650 1 10 48550 1909 11650 。v。[11] https://doi.org/。/arXiv。。David Byrd、Maria Hybinette 和 Tucker Hybinette Balch。2020。ABIDES：迈向高保真多智能体市场仿真。载于《2020年ACM SIGSIM高级离散仿真原理会议论文集》（西班牙佛罗里达州迈阿密）（SIGSIM-PADS '20）。计算机协会，纽约州纽约市，美国，11–22。[12] Jun-Jie Chen、Bo Zheng 和 Lei Tan。2013。具有非对称交易和羊群行为的复杂金融系统基于代理的模型。《公共科学图书馆·综合》8，11（2013），e79531。[13] Qiwei Chen、Xiuping Hua 和 Ying Jiang。2018。中国股票市场中的反向策略与羊群行为。《欧洲金融杂志》24，16（2018），1552–1568。[14] Andrea Coletta、Aymeric Moulin、Svitlana Vyetrenko 和 Tucker Balch。2022。从数据中学习模拟真实限价订单簿市场：作为世界智能体。载于《第三届ACM金融人工智能国际会议论文集》。计算机协会，纽约州纽约市，美国，428–436。[15] Rama Cont。2001。资产收益的经验特性：风格化事实与统计问题。《定量金融》1，2（2001），223。[16] Rama Cont。2007。金融市场中的波动率聚集：实证事实与基于代理的模型。载于《经济学中的长记忆》，Gilles Teyssière 和 Alan P. Kirman（编）。施普林格，柏林，海德堡，289–309。[17] Rama Cont 和 Adrien De Larrard。2013。马尔可夫限价订单市场中的价格动态。《SIAM金融数学杂志》4，1（2013），1–25。[18] Rama Cont、Arseniy Kukanov 和 Sasha Stoikov。2014。订单簿事件的价格冲击。《金融计量经济学杂志》12，1（2014），47–88。[19] Rama Cont、Sasha Stoikov 和 Rishi Talreja。2010。订单簿动态的随机模型。《运筹学》58，3（2010），549–563。[20] Matthew Duffin 和 John Cartlidge。2018。碎片化金融市场中延迟套利的基于代理的模型探索。载于《2018年IEEE计算智能研讨会系列》（SSCI）。IEEE，纽约州纽约市，美国，2312–2320。[21] Jean-Marie Dufour、René Garcia 和 Abderrahim Taamouti。2012。衡量收益、已实现波动率与隐含波动率之间的高频因果关系。《金融计量经济学杂志》10，1（2012），124–163。[22] Eugene F Fama。1991。有效资本市场：II。《金融杂志》46，5（1991），1575–1617。[23] Ling Feng、Baowen Li、Boris Podobnik、Tobias Preis 和 H Eugene Stanley。2012。连接金融市场的基于代理的模型与随机模型。《美国国家科学院院刊》109，22（2012），8388–8393。[24] Martin D Gould、Mason A Porter、Stacy Williams、Mark McDonald、Daniel J Fenn 和 Sam D Howison。2013。限价订单簿。《定量金融》13，11（2013），1709–1742。[25] Gao-Feng Gu 和 Wei-Xing Zhou。2009。修正Mike-Farmer模型中股票波动率长记忆的涌现。《EPL（欧洲物理快报）》86，4（2009），48002。[26] Michaël Karpe、Jin Fang、Zhongyao Ma 和 Chen Wang。2020。真实限价订单簿市场模拟中的多智能体强化学习。载于《首届ACM金融人工智能国际会议论文集》。计算机协会，纽约州纽约市，美国，1–7。[27] Pankaj Kumar。2021。用于高频做市的深度霍克斯过程。https://doi.org/ 10 48550 2109 15110 。/ARXIV。。[28] Eun Jung Lee。。韩国指数期货市场中的高频交易。《期货市场杂志》35，1（2015），31–51。[29] Junyi Li、Xintong Wang、Yaoyang Lin、Arunesh Sinha 和 Michael Wellman。2020年。生成逼真的股票市场订单流。载于《AAAI人工智能会议论文集》，第34卷（01）。AAAI出版社，美国加利福尼亚州帕洛阿尔托，727–734。[30] Fabrizio Lillo 和 J Doyne Farmer。2004年。有效市场的长记忆。《非线性动力学与计量经济学研究》8，3（2004），1–33。[31] Fabrizio Lillo、J Doyne Farmer 和 Rosario N Mantegna。2003年。价格冲击函数的主曲线。《自然》421，6919（2003），129–130。[32] Frank McGroarty、Ash Booth、Enrico Gerding 和 VL Chinthalapati。2019年。高频交易策略、市场脆弱性与价格尖峰：基于智能体的模型视角。《运筹学年鉴》282，1（2019），217–244。[33] Randi Næs 和 Johannes A Skjeltorp。2006年。订单簿特征与成交量—波动率关系：来自限价订单市场的实证证据。《金融市场杂志》9，4（2006），408–432。[34] Samarpan Nawn 和 Ashok Banerjee。2019年。自营和代理算法交易者的限价订单是在发现还是遮蔽证券价格？《实证金融杂志》53（2019），109–125。https://doi.org/10.1016/j.jempfin.2019.06. 003[35] Ingmar Nolte、Mark Salmon 和 Chris Adcock。2016年。高频交易与限价订单簿动态。Routledge出版社，英格兰阿宾顿。[36] Mark Paddrik、Roy Hayes、Andrew Todd、Steve Yang、Peter Beling 和 William Scherer。2012。应用于闪电崩盘分析的E-Mini标普500基于智能体的模型。载于2012年IEEE金融工程与经济计算智能会议（CIFEr）。IEEE，美国纽约州纽约市，1–8。[37] Efstathios Panayi 和 Gareth W Peters。2015年。使用流动性驱动型智能体的限价订单簿随机模拟框架。《国际金融工程杂志》2，02（2015），1550013。[38] C-K Peng、Sergey V Buldyrev、Shlomo Havlin、Michael Simons、H Eugene Stanley 和 Ary L Goldberger。1994年。DNA核苷酸的镶嵌组织。《物理评论E辑》49，2（1994），1685。[39] Tobias Preis、Sebastian Golke、Wolfgang Paul 和 Johannes J Schneider。2007年。资产交易多智能体订单簿模型中金融收益的统计分析。《物理评论E辑》76，1（2007），016108。[40] Stephan Schulmeister。2009年。股票技术交易的盈利能力：它是否已从日内数据转向日内交易？《金融经济学评论》18，4（2009），190–201。[41] Antonio Sánchez Serrano。2020年。高频交易与系统性风险：研究发现与政策的结构化综述。《经济学评论》71，3（2020），169–195。[42] Zijian Shi 和 John Cartlidge。2021年。限价订单簿重建模型（LO-BRM）：扩展分析。载于《欧洲机器学习与数据库知识发现联合会议》。施普林格，瑞士查姆，204–220。[43] Zijian Shi 和 John Cartlidge。2022。用于限价订单簿事件流预测与模拟的状态依赖并行神经霍克斯过程。载于《第28届ACM SIGKDD知识发现与数据挖掘会议论文集》。计算机协会，美国纽约州纽约市，1607–1615。[44] Zijian Shi、Yu Chen 和 John Cartlidge。2021年。LOB重建模型：使用常微分方程循环神经网络根据TAQ历史数据预测限价订单簿。载于《AAAI人工智能会议论文集》，第35卷（1）。AAAI出版社，美国加利福尼亚州帕洛阿尔托，548–556。[45] Ilya M Sobol。2001。非线性数学模型的全局敏感性指数及其蒙特卡洛估计。《数学与计算机模拟》55，1 3 2001 271 280 -（），–。[46] H Eugene Stanley、Vasiliki Plerou 和 Xavier Gabaix。2008年。金融波动的统计物理学视角：标度与普适性的证据。《物理学A辑：统计力学及其应用》387，15（2008），3967–3981。[47] Svitlana Vyetrenko、David Byrd、Nick Petosa、Mahmoud Mahfouz、Danial Der-vovic、Manuela Veloso 和 Tucker Balch。2020年。求真：稳健限价订单簿市场模拟的逼真度指标。载于《首届ACM金融人工智能国际会议论文集》。ACM，美国纽约州纽约市，1–8。[48] Elaine Wah 和 Michael P Wellman。2016年。碎片化市场中的延迟套利：基于智能体的策略分析。《算法金融》5，3-4（2016），69–93。[49] Xintong Wang、Christopher Hoang、Yevgeniy Vorobeychik 和 Michael P Well-man。2021年。操纵限价订单簿：基于智能体的策略分析。《游戏》12，2（2021），46。[50] Carter Yagemann、Simon P Chung、Erkam Uzun、Sai Ragam、Brendan Saltafor-maggio 和 Wenke Lee。2020年。自动化股票市场操纵的可行性研究。载于《年度计算机安全应用会议》。计算机协会，美国纽约州纽约市，277–290。[51] Rhea Tingyu Zhou 和 Rose Neng Lai。2009年。羊群行为与基于信息的交易。《实证金融杂志》16，3（2009），388–393。