

2024-2025年量化交易前沿：机器学习与深度学习在短周期交易中的应用研究报告

1. 市场微观结构的演变与计算范式的转移

1.1 从高频交易的生态位到算法博弈的深水区

全球金融市场的电子化进程在过去二十年中重塑了流动性的生成与消耗机制。截至2024年，高频交易(High-Frequency Trading, HFT)在主要权益市场的成交占比已趋于稳定，但其内部的竞争格局却发生了质的飞跃。传统的HFT策略往往依赖于简单的速度优势和基于规则的做市逻辑，例如通过识别队列位置(Queue Position)或简单的订单流不平衡(Order Flow Imbalance, OFI)来捕捉微小的价差。然而，随着FPGA(现场可编程门阵列)硬件的普及以及交易所撮合引擎的升级，单纯的“速度竞赛”边际收益递减，市场参与者逐渐将竞争维度转向了“智能预测”¹。

当前，市场微观结构呈现出极高的复杂性与非线性特征。一方面，流动性供给策略与流动性消耗策略之间的博弈日益激烈。研究表明，流动性供给型HFT在财报公布等重大事件周围显著改善了价格发现效率，而流动性消耗型策略则可能阻碍信息的有效整合¹。另一方面，外汇(FX)等市场的微观结构异常——如流动性枯竭、闪崩等极端事件——对传统的时间序列分析方法提出了严峻挑战²。这些异常往往由多维度的微观特征共同驱动，传统的线性计量模型(如VAR、Co-integration)难以捕捉变量间的高阶交互作用。

在此背景下，量化交易的研发范式正在经历从“因子挖掘+线性模型”向“端到端深度学习”的深刻转型。传统的量化流程通常是割裂的：研究员首先基于经验构建手工因子(Hand-crafted Features)，然后将这些因子输入到线性回归或简单的机器学习模型中。这种方式不仅严重依赖专家经验，而且往往丢失了原始数据中包含的时空结构信息。相比之下，端到端学习(End-to-End Learning)允许模型直接以原始的极限订单簿(Limit Order Book, LOB)快照或逐笔成交数据为输入，自动提取从微观结构到宏观趋势的层次化特征，从而在极低信噪比(Signal-to-Noise Ratio)的环境中捕捉稍纵即逝的Alpha信号³。

1.2 数据表征的革命：极限订单簿(LOB)的高维建模

极限订单簿(LOB)是短周期交易中最核心的数据资产，它记录了特定时刻市场上所有未成交的买单和卖单，包含了比成交价格丰富得多的供需信息。为了适应深度学习模型，LOB数据通常被表征为高维张量。

标准的L2级别数据包含买卖两侧各 N 档的价格和挂单量。对于一个深度为 D 的订单簿，在时间步 t 的状态向量 x_t 包含了 $4D$ 个特征：

$$x_t =$$

在深度学习应用中，我们通常关注一个历史时间窗口 T ，从而形成一个 $T \times 4D$ 的二维矩阵，这使得LOB数据在结构上类似于单通道的图像。这种表征方式直接催生了计算机视觉(CV)技术在金融领域的跨界应用。然而，与自然图像不同，LOB数据具有独特的属性：

- 非欧几里得空间特性：价格档位之间的距离并非固定，且买卖价差(Spread)是动态变化的。
- 极端的数值范围：挂单量可能在几个数量级间波动，且存在大量的长尾分布特征。
- 时间非平稳性：数据的统计分布随市场状态(Regime)的切换而剧烈变化。

为了应对这些挑战，2024-2025年的研究在数据预处理和归一化方面取得了重要进展。例如，采用自适应的Z-score标准化，或者引入平稳化模块(Stationarization Module)来动态调整输入分布，已成为构建鲁棒模型的标准动作⁴。此外，针对LOB数据的异构性，研究者开始探索将逐笔成交流(Message Flow)与订单簿快照(Snapshot)相结合的多模态输入架构，以期更全面地还原市场的微观动力学。

2. 价格预测架构的演进：从卷积到注意力机制

在短周期交易中，准确预测未来短时间内(如100毫秒至几秒)的价格变动方向或中间价(Mid-price)走势，是构建盈利策略的基石。过去两年，这一领域的主流架构经历了从卷积神经网络(CNN)向时间卷积网络(TCN)，再到Transformer及其变体(ViT, TLOB)的快速迭代。

2.1 卷积神经网络(CNN)的基石地位与局限

DeepLOB模型⁵是利用CNN处理LOB数据的里程碑式工作，确立了深度学习在HFT领域的有效性。DeepLOB的设计灵感来源于LOB数据的局部相关性：

- 空间局部性：买一价的变化往往与买二、买三价的挂单变动紧密耦合。
- 时间局部性：当前时刻的市场状态主要受最近一段历史的影响。

DeepLOB采用了类似Inception的模块化设计，通过并行的卷积滤波器(Convolutional Filters)同时捕捉不同时间尺度的特征。具体而言，它利用 $(1, 1)$ 、 $(3, 1)$ 和 $(5, 1)$ 等不同尺寸的卷积核，分别提取微观的市场噪声、短期的订单流失衡以及中期的趋势信号。经过卷积层提取的特征图(Feature Maps)被展平后，通常输入到一个LSTM(长短期记忆网络)层中，以整合时间序列的长时依赖关系。

尽管DeepLOB在FI-2010等基准数据集上超越了传统的SVM和MLP模型，但其局限性也日益凸显。首先，CNN的感受野(Receptive Field)受限于卷积核的尺寸和网络深度，难以捕捉长距离的时间依赖。其次，LSTM模块的串行计算特性限制了模型的推理速度，且在处理超长序列(如数千个Tick)时仍面临梯度消失的风险。此外，DeepLOB对输入数据的排列顺序敏感，缺乏对LOB内部复杂交互机制(如跨档位的非线性冲击)的显式建模能力⁷。

2.2 时间卷积网络(TCN)：因果性与长记忆的平衡

为了克服RNN类模型(如LSTM)在计算效率和长序列建模上的瓶颈，时间卷积网络(TCN)在2024

年的研究中受到了广泛关注⁷。TCN结合了卷积网络的并行计算优势和序列模型的因果约束，成为HFT预测任务的有力竞争者。

TCN的核心架构包含三个关键组件：

1. 因果卷积(**Causal Convolutions**)：确保在 t 时刻的预测仅依赖于 t 时刻及之前的输入，严防未来信息泄露(Look-ahead Bias)。这对于金融时间序列预测至关重要，因为任何形式的未来数据泄露都会导致回测结果的虚假繁荣。
2. 空洞卷积(**Dilated Convolutions**)：通过在卷积核点之间插入空洞(即跳过部分输入)，TCN能够以指数级扩大感受野。例如，随着层数 k 的增加，空洞系数 d 通常设置为 2^k 。这意味着一个较浅的网络也能覆盖极长的历史窗口，从而有效捕捉LOB数据的“长记忆性”(Long Memory)特征——即当前的波动率往往与很久之前的波动率存在相关性。
3. 残差连接(**Residual Connections**)：类似于ResNet，TCN引入残差块以支持深层网络的训练稳定性，防止深层网络退化。

实证研究表明，在相同的历史窗口长度下，TCN的训练和推理速度显著快于LSTM，且内存占用更低。在捕捉非线性特征方面，TCN表现出了比传统CNN更强的能力，特别是在处理具有多重时间尺度的金融数据时⁵。然而，TCN在处理变长序列时仍显得笨拙，且其静态的卷积核权重难以适应金融市场快速变化的动态特性。

2.3 Transformer架构的崛起：全局视野与动态注意力

进入2025年，Transformer架构凭借其强大的全局建模能力和自注意力机制(Self-Attention)，开始在量化交易领域占据主导地位，逐步取代LSTM和CNN成为处理LOB数据的首选方案²。与CNN关注局部特征、RNN关注序列递归不同，Transformer能够直接计算序列中任意两个位置之间的依赖关系，无论它们相距多远。

2.3.1 ViT-LOB：将订单簿视为动态图像

ViT-LOB⁷是Vision Transformer(ViT)在金融领域的创新应用。该模型将 $T \times 40$ 的LOB时空张量视为一张图像，并将其切分为若干个非重叠的“补丁”(Patches)。每个Patch被线性投影为一个向量，形成输入序列。

- 全局感受野：在LOB市场中，深层(如Level 10)的大额挂单(Whale Orders)往往会对市场心理产生瞬间冲击，进而影响Level 1的最优价格。传统的CNN需要多层堆叠才能将这种深层信息传递到浅层，而ViT-LOB的自注意力机制可以在第一层就直接建立这种跨档位的长距离关联。
- 位置编码：由于Transformer本身不具备序列顺序感，必须引入位置嵌入(Positional Embedding)以保留时间顺序信息。研究发现，可学习的位置编码比固定的正弦位置编码更能适应金融数据的非周期性特征。

2.3.2 TLOB：双重注意力机制的精细化刻画

为了进一步提升对LOB微观结构的解析能力，最新的TLOB(Transformer for LOB)模型提出了“双

重注意力”(Dual Attention)机制¹⁰。该架构包含两个并行的注意力模块：

- 1. 时间自注意力(Temporal Self-Attention)：沿着时间轴计算注意力权重，动态识别出历史序列中哪些关键时刻(如突发的大额成交、流动性瞬间枯竭点)对当前预测最为重要。这种机制使得模型能够自动忽略无关的噪声时段，聚焦于信息含量高的微观事件。
- 2. 特征自注意力(Feature Self-Attention)：沿着特征轴(价格档位和量)计算权重，捕捉不同档位之间的相互作用。例如，模型可能会发现“买一量的减少”与“卖三量的增加”之间存在强烈的协同效应，从而预示价格下跌。

实证表现与局限性分析：

在FI-2010和伦敦证券交易所(LSE)的高频数据集上，TLOB在预测准确率(F1-score)和盈利能力上均全面超越了DeepLOB和TCN。特别是在市场剧烈波动(High Volatility)期间，TLOB展现出了更强的鲁棒性，能够迅速适应市场状态的切换。然而，Transformer架构的高计算复杂度($O(T^2)$)是其在超高频交易中落地的主要障碍。尽管ViT-LOB通过Patch化降低了序列长度，但在微秒级的竞争环境中，如何进一步压缩推理延迟仍是工程优化的重点(详见第6节)。

以下表格总结了主流架构在LOB预测任务中的特性对比：

架构特性	DeepLOB (CNN-LSTM)	TCN (Temporal ConvNet)	ViT-LOB / TLOB (Transformer)
核心机制	局部卷积 + 循环递归	因果卷积 + 空洞扩张	自注意力机制 (Global Attention)
感受野	局部受限	指数级扩大	全局覆盖
并行计算	卷积部分并行, LSTM串行	完全并行	完全并行
长记忆捕捉	较弱 (LSTM梯度问题)	强	极强
推理延迟	中等	低	高 (需优化)
微观结构解释性	低 (黑盒特征)	中等	高 (注意力热图可视化)

3. 生成式AI与市场模拟：打破数据稀缺的桎梏

在量化策略研发中, 历史数据虽然庞大, 但往往只能提供一条单一的样本路径(Sample Path)。这导致了两个核心痛点: 一是极端行情(如2010年闪崩、2020年熔断)的样本极其稀缺, 模型难以学习应对此类黑天鹅事件; 二是无法准确评估策略本身对市场的冲击(Market Impact), 即“观测者效应”。2024-2025年, 生成式AI(**Generative AI**), 特别是扩散模型(Diffusion Models)的引入, 为构建高保真的市场模拟器(Market Simulators)提供了革命性的解决方案。

3.1 扩散模型(Diffusion Models)在LOB模拟中的突破

最新的研究提出了利用扩散模型生成LOB数据的方法, 形象地被称为“Painting the Market”¹⁶。与早期的GAN(生成对抗网络)和VAE(变分自编码器)相比, 扩散模型在生成金融时间序列的质量和多样性上取得了显著突破。

3.1.1 扩散机制与LOB生成

扩散模型包含前向扩散过程和逆向去噪过程。

- 前向过程: 逐步向真实的LOB快照序列添加高斯噪声, 破坏数据结构, 直至其变为各向同性的纯噪声。
- 逆向过程: 训练一个神经网络(通常是基于U-Net或Transformer的架构)来预测每一步添加的噪声分量。通过迭代地去除噪声, 模型能够从随机噪声中还原出具有逼真微观结构的LOB序列。

研究显示, 扩散模型生成的LOB数据在统计特性上高度还原了真实市场, 包括:

- 长尾分布(**Fat Tails**): 精确复现了价格回报率的尖峰厚尾特征, 这是许多传统统计模型难以企及的。
- 波动率聚集(**Volatility Clustering**): 生成的数据展现出了真实的波动率自相关性, 即大波动往往伴随着大波动。
- 量价相关性: 保持了买卖价差、挂单深度与中间价变化之间的复杂非线性关系。

3.1.2 Inpainting技术与概率预测

¹⁶ 提出了一种极具创新性的视角: 将LOB的时间序列预测问题转化为图像修复(Inpainting)问题。

- 条件生成: 给定过去 T 时刻的真实LOB数据(作为已知区域), 利用训练好的扩散模型“修复”未来 K 时刻的数据(作为待生成区域)。
- 概率分布构建: 由于生成过程具有随机性, 通过多次运行模型, 可以生成成千上万条可能的未来价格路径。这不仅给出了点预测, 还直接构建了未来市场状态的概率分布。这种能力对于风险管理至关重要, 交易员可以据此计算在特定置信水平下的最大回撤(VaR)或流动性风险。

3.2 模拟器与Sim-to-Real的闭环

基于生成式AI构建的高保真市场模拟器(如基于ABIDES的扩展版本²⁰), 使得“Sim-to-Real”(从模拟到现实)的迁移学习成为可能。

- 反事实推理(**Counterfactual Reasoning**): 交易员可以在模拟器中测试“如果当时下了10倍的单量, 市场会如何反应? ”。扩散模型能够根据条件输入, 生成包含市场冲击效应的逼真反馈。
- 强化学习训练场: 强化学习Agent需要与环境进行数百万次的交互才能收敛。在真实市场中进行探索(Exploration)成本极高且风险不可控。生成式模拟器提供了一个零成本的试错环境, 且可以通过对抗性生成(Adversarial Generation)制造各种极端的压力测试场景(如流动性瞬间枯竭), 迫使Agent学习出更鲁棒的策略²²。

4. 深度强化学习在最优执行与做市中的前沿实践

最优执行(Optimal Execution)和做市(Market Making)是短周期交易中的核心决策问题。传统的解决方案如Almgren-Chriss模型, 通常基于严格的假设(如价格服从布朗运动、线性冲击模型), 这在复杂的现代市场中往往失效。深度强化学习(**Deep Reinforcement Learning, DRL**)通过与环境交互直接学习策略, 能够适应非线性、非平稳的市场动态, 已成为该领域的研究热点²⁰。

4.1 马尔可夫决策过程(MDP)的精细化设计

DRL的成功与否很大程度上取决于MDP的设计, 即状态空间(State)、动作空间(Action)和奖励函数(Reward)的定义。

4.1.1 状态空间的多维感知

一个鲁棒的Agent必须具备全方位的市场感知能力。前沿研究建议状态空间 S_t 应包含以下维度²⁶:

- 微观结构特征: 前10档的量价数据、买卖价差(Spread)、中间价变化率。
- 订单流特征: 近期的订单流不平衡(OFI)、成交流不平衡(TFI)。这些指标是预测短期价格走势的强信号。
- 私有状态(**Private States**): Agent当前的持仓量(Inventory q_t)、剩余执行时间(Time Remaining $T - t$)、已实现盈亏(Realized P&L)。
- 市场环境特征: 波动率预测值、市场流动性指数。

4.1.2 动作空间的连续化

传统的DRL应用多采用离散动作空间(如: 买入/卖出/持有, 或调整挂单档位 ± 1)。然而, 现代算法(如PPO、DDPG、SAC)支持连续动作空间, 使得策略控制更加精细²⁴:

- 挂单价格: 输出相对于中间价的连续偏移量 δ , 即 $P_{limit} = P_{mid} \pm \delta$ 。
- 挂单数量: 输出具体的下单手数, 允许Agent根据市场深度动态调整单量大小。

4.2 奖励函数工程: 引导策略进化的指挥棒

奖励函数的设计直接决定了Agent的行为模式。在最优执行任务中，目标是在规定时间内完成交易并最小化成本。奖励函数 R_t 通常由以下几部分加权组成²⁷：

$$R_t = \underbrace{\Delta W_t}_{\text{财富增量}} - \underbrace{\lambda_1(IS_t)}_{\text{实现缺口惩罚}} - \underbrace{\lambda_2 q_t^2}_{\text{库存惩罚}} - \underbrace{\lambda_3 \text{Volatility}_t}_{\text{风险厌恶}}$$

- 1. 实现缺口 (Implementation Shortfall, IS)：衡量实际执行价格与基准价格(如决策时刻的到达价 Arrival Price)之间的差额。这是评估执行质量的核心指标。
- 2. 非线性库存惩罚 (Inventory Penalty)： $\lambda_2 q_t^2$ 项迫使做市商保持库存中性，避免单边持仓过大带来的市场风险。对于执行算法，该惩罚项的权重 λ_2 通常随时间 t 呈指数级增长，迫使Agent在交易截止前清仓，防止违约。
- 3. 稀疏与密集奖励：研究表明，引入每一步的密集奖励 (Dense Reward) 比仅在执行结束时给予稀疏奖励 (Sparse Reward) 能显著加速收敛，并减少策略的方差²⁹。

4.3 主流算法的博弈：PPO vs DDPG

在算法选择上，PPO (Proximal Policy Optimization) 目前是金融DRL的主流选择²⁵。

- 稳定性优势：PPO通过截断策略比率 (Policy Ratio)，限制每次参数更新的幅度。在噪声极大的金融数据中，这至关重要，因为一次基于错误信号的激进更新可能导致策略彻底崩塌。
- DDPG (Deep Deterministic Policy Gradient) 与 SAC (Soft Actor-Critic)：这类 Off-policy算法在样本利用率上更高，且天然支持连续动作空间。SAC引入了最大熵项，鼓励Agent探索更多样的策略，防止过早收敛到局部最优²⁴。

下表总结了不同RL算法在交易场景中的适用性：

算法	类型	动作空间	优点	缺点	适用场景
DQN	Value-based	离散	训练相对简单，样本效率中等	难以处理高维/连续动作，训练不稳定	简单的方向预测，离散档位做市
PPO	Policy-based	连续/离散	稳定性高，鲁棒性强，超参数不敏感	样本效率较低 (On-policy)	复杂的做市策略，多目标优化执行
DDPG/SAC	Actor-Critic	连续	样本效率高，支持精细	对超参数极其敏感，易	需要极高精度的最优执

			控制	发散	行算法
--	--	--	----	----	-----

5. 跨截面Alpha: 图神经网络(GNN)的时空挖掘

传统的高频交易模型多关注单一资产的时间序列特征。然而，现代金融市场是一个高度关联的复杂系统。产业链传导、板块轮动、宏观因子的共振等机制，使得股票之间存在着复杂的联动关系。图神经网络(GNN)为显式建模这种资产间的依赖关系提供了强大的工具，成为挖掘跨截面Alpha(Cross-sectional Alpha)的前沿方向³¹。

5.1 图结构的构建: 从显式到隐式

GNN的核心在于图(Graph)的构建，即定义节点(Nodes, 代表股票)和边(Edges, 代表关系)。

- 静态显式图: 基于基本面数据构建。例如，利用供应链数据将供应商和客户相连，或利用行业分类标准将同行业公司相连。这种图结构稳定，但可能滞后，无法反映市场的瞬时动态。
- 动态隐式图(Learnable Graphs): 最新的研究倾向于从数据中自动学习图结构³³。
 - 相关性驱动: 在每个时间窗口计算股票间的皮尔逊相关系数或互信息，动态更新邻接矩阵。
 - 端到端学习: 将邻接矩阵 A 视为模型的可训练参数。通过损失函数的反向传播，模型会自动发现那些人类直觉难以察觉的潜在关联(例如，某只科技股可能与某只看似无关的能源股存在统计套利关系)。

5.2 STGAT: 时空图注意力网络的架构解析

STGAT(Spatial-Temporal Graph Attention Network)³¹是该领域的代表性模型，它创新性地结合了图注意力机制(GAT)和时间序列模型(如TCN或LSTM)。

- 空间聚合(Spatial Aggregation): 对于目标股票 i ，GAT层通过注意力机制聚合其邻居节点 $j \in \mathcal{N}(i)$ 的特征。注意力权重 α_{ij} 是动态计算的，反映了邻居 j 在当前时刻对股票 i 的影响力。例如，当板块龙头股异动时，其对板块内跟风股的注意力权重会自动增加，从而捕捉“领涨/跟跌”效应。
- 时间演化(Temporal Evolution): 经过空间聚合后的特征包含了全市场的关联信息，随后被输入到时间模块(如TCN)中，以捕捉股票自身的历史演变规律。
- 残差机制: 为了防止过度平滑(Oversmoothing)，STGAT通常引入残差连接，保留节点自身的原始特征。

Alpha增益与系统性风险预警:

实证研究显示，引入空间信息的STGAT在构建多因子选股策略时，显著优于独立的LSTM或CNN模型。特别是在市场发生系统性风险(如突发宏观利空)时，图结构能够模拟风险在网络中的传播路径，从而提前预警并调整投资组合的风险暴露。STGAT证明了“溢出效应”(Spillover Effect)是短

周期交易中不可忽视的Alpha来源。

6. 极致性能：FPGA硬件加速与边缘计算

在HFT领域，“速度即Alpha”是永恒的真理。即便拥有预测准确率极高的深度学习模型，如果推理延迟(Inference Latency)过高，交易机会也会在计算过程中稍纵即逝。传统的CPU/GPU架构受限于操作系统调度、PCIe总线传输和缓存机制，通常只能提供毫秒级的延迟，且存在不可控的抖动(Jitter)。为了将复杂的Transformer或CNN模型部署到实战中，基于FPGA(现场可编程门阵列)的硬件加速技术成为了必选项³⁶。

6.1 LightTrader系统：软硬协同设计的典范

LightTrader³⁸是一个具有里程碑意义的AI-HFT系统，展示了如何通过软硬协同设计(Co-design)突破性能极限。

- **全流水线架构(Fully Pipelined)**：LightTrader在FPGA上实现了从数据包解析(UDP Parsing)、订单簿构建(Book Building)、特征提取、模型推理到订单生成(Order Generation)的全流程硬件化。数据流在FPGA内部直接流转，完全绕过了CPU和操作系统，消除了PCIe传输的巨大开销。
- **定制化AI加速器(CGRA)**：针对金融模型计算密集型的特点，LightTrader在FPGA内部构建了基于CGRA(粗粒度可重构阵列)的专用加速器。这种架构针对矩阵乘法进行了极致优化，最大化了片上SRAM的复用率，减少了对慢速DRAM的访问。
- **性能飞跃**：实验数据显示，LightTrader将**Tick-to-Trade**(从收到行情到发出订单)的端到端延迟降低到了**10微秒(μs)**以内，相比于高性能GPU方案快了近两个数量级，且延迟波动极小。

6.2 模型量化(Quantization)：精度与速度的权衡

FPGA的片上资源(DSP乘法器、BRAM存储器)是极其有限的。为了将庞大的深度网络塞入FPGA，必须进行激进的模型压缩，其中最关键的技术是量化⁴¹。

1. **INT8量化**：将模型原本的32位浮点权重(FP32)转换为8位定点整数(INT8)。在FPGA上，定点运算不仅速度快，而且消耗的逻辑资源远少于浮点运算。研究表明，经过校准(Calibration)的INT8模型在LOB预测任务上的精度损失通常小于0.5%，完全在可接受范围内。
2. **二值/三值网络(Binary/Ternary Networks)**：更激进的方法是将权重限制为 $\{-1, 1\}$ 或 $\{-1, 0, 1\}$ 。这种量化将复杂的乘法运算转化为简单的位运算(XNOR和Popcount)，理论上可提升数十倍的吞吐量。虽然这会带来一定的精度下降，但在极高频的纯速度博弈场景中，这种牺牲往往是值得的。
3. **混合精度(Mixed-Precision)**：针对Transformer等对数值敏感的架构，采用混合精度策略：在注意力机制的关键计算(如Softmax)保留较高精度，而在全连接层使用低精度。LightTrader等系统通过自动化的硬件搜索工具，能够为每一层网络寻找最优的位宽配置。

下表展示了不同计算平台在HFT场景下的典型性能对比：

平台	架构特点	Tick-to-Trade 延迟	抖动 (Jitter)	灵活性	开发难度
CPU	通用计算, 串行优化	10 - 100 μs	高 (受OS影响)	极高	低 (C++/Python)
GPU	众核并行, 高吞吐	100 μs - 1 ms	中	高	中 (CUDA)
FPGA	空间并行, 流水线	< 1 μs	极低 (确定性)	低 (需重配置)	极高 (Verilog/HL S)
ASIC	专用集成电路	< 0.5 μs	极低	极低 (不可改)	极高 (流片成本)

7. 挑战与展望：在非平稳与黑盒中寻找确定性

尽管深度学习和强化学习在量化交易中取得了显著进展，但在实际部署中仍面临两大核心挑战：环境的非平稳性(Non-stationarity)和模型的不可解释性(Black-box nature)。

7.1 征服非平稳性：适应不断变化的市场

金融市场是动态演化的，数据分布随宏观政策、市场情绪和参与者结构的变化而发生漂移(Concept Drift)。一个上个月表现完美的模型，可能因为市场Regime的切换而在本月彻底失效。

- 在线增量学习(Online Incremental Learning)：模型不再是一次训练终身使用，而是随着新数据的到来实时微调参数。这对系统的计算能力提出了极高要求。
- 域适应(Domain Adaptation)：将不同的市场状态视为不同的“域”。利用对抗性域适应(Adversarial Domain Adaptation)技术，模型可以学习提取与具体市场状态无关的“不变特征”(Invariant Features)，从而在未见过的市场环境中也能保持稳定的预测能力⁴⁵。
- 非平稳Transformer：最新的学术研究开始探索针对非平稳时间序列设计的Transformer架构，通过引入平稳化模块(Stationarization Module)和去平稳化模块(De-stationarization Module)，使模型在归一化的潜在空间中学习时序依赖，然后再恢复出真实的数值预测⁴⁸。

7.2 可解释性AI(XAI)：建立信任的基石

对于掌管巨额资金的量化基金而言，完全无法解释的黑盒模型是风控的噩梦。XAI技术旨在打开这个黑盒，为交易决策提供依据⁴⁹。

- **Shapley Values (SHAP)**: 基于博弈论的方法，能够精确计算每个输入特征（如“买一档挂单量”）对模型最终预测结果的边际贡献。如果模型预测价格上涨，SHAP值可以告诉交易员是因为“买单激增”还是“卖单撤回”⁵¹。
- **Attention可视化**: 对于Transformer模型，通过绘制注意力 heatmap (Attention Heatmap)，可以直观地展示模型在做出决策时关注了历史上的哪个时间段或订单簿的哪个区域。这不仅增强了人类对模型的信任，还能反向启发研究员发现新的市场逻辑⁵³。

结语

2024年至2025年，机器学习与深度学习在短周期量化交易中的应用已经完成了从实验探索向工业级落地的跨越。**Transformer**与**GNN** 赋予了模型前所未有的时空感知能力，使其能够解析LOB深处的微观密码；生成式**AI** 通过“Painting the Market”解决了极端场景数据稀缺的难题，为策略回测和RL训练提供了逼真的虚拟演练场；深度强化学习 正在重塑最优执行与做市的边界，使算法能够在复杂的博弈中动态进化；而**FPGA**与模型量化 技术则为这些高智商的AI大脑装上了极速的引擎，确保了Alpha在微秒级的战场中得以变现。

未来，随着硬件算力的进一步提升和算法对非平稳环境适应能力的增强，AI将在量化交易中扮演更加核心的角色，从单纯的辅助预测工具进化为具备自主决策能力的全自动交易智能体。对于量化机构而言，构建集高质量数据流、高性能算力、前沿算法与低延迟硬件于一体的AI基础设施，将是决定未来十年竞争力的关键胜负手。

Works cited

1. Data-Driven Measures of High-Frequency Trading - arXiv, accessed January 27, 2026, <https://arxiv.org/pdf/2405.08101>
2. A Deep Learning Approach to Anomaly Detection in High-Frequency Trading Data - arXiv, accessed January 27, 2026, <https://arxiv.org/pdf/2504.00287>
3. From Deep Learning to LLMs: A survey of AI in Quantitative Investment - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2503.21422v1>
4. An Efficient deep learning model to Predict Stock Price Movement Based on Limit Order Book - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2505.22678v1>
5. DeepLOB: Deep Convolutional Neural Networks for Limit Order Books - IDEAS/RePEc, accessed January 27, 2026, <https://ideas.repec.org/p/arx/papers/1808.03668.html>
6. [1808.03668] DeepLOB: Deep Convolutional Neural Networks for Limit Order Books - arXiv, accessed January 27, 2026, <https://arxiv.org/abs/1808.03668>
7. DeepLOB: Deep Convolutional Neural Networks for Limit Order Books - Semantic Scholar, accessed January 27, 2026, <https://www.semanticscholar.org/paper/DeepLOB%3A-Deep-Convolutional-Neural-Networks-for-Zhang-Zohren/085870597c8a8421390d6590425003a13deefdd4>
8. TCN-LOB: Temporal Convolutional Network for Limit Order Books | Semantic

- Scholar, accessed January 27, 2026,
<https://www.semanticscholar.org/paper/TCN-LOB%3A-Temporal-Convolutional-Network-for-Limit-Zheng-Yu/93dbead3174a13d9f1944cfd097844a4b2513056>
9. Temporal Convolutional Networks and Forecasting - Unit8, accessed January 27, 2026,
<https://unit8.com/resources/temporal-convolutional-networks-and-forecasting/>
 10. (PDF) TLOB: A Novel Transformer Model with Dual Attention for Stock Price Trend Prediction with Limit Order Book Data - ResearchGate, accessed January 27, 2026,
https://www.researchgate.net/publication/389315687_TLOB_A_Novel_Transformer_Model_with_Dual_Attention_for_Stock_Price_Trend_Prediction_with_Limit_Order_Book_Data
 11. Vision Transformer (ViT) Architecture - GeeksforGeeks, accessed January 27, 2026,
<https://www.geeksforgeeks.org/deep-learning/vision-transformer-vit-architecture/>
 12. ViT-LOB: Efficient Vision Transformer for StockPrice Trend Prediction Using Limit Order Books | Request PDF - ResearchGate, accessed January 27, 2026,
https://www.researchgate.net/publication/381417250_ViT-LOB_Efficient_Vision_Transformer_for_StockPrice_Trend_Prediction_Using_Limit_Order_Books
 13. TLOB: A Novel Transformer Model with Dual Attention for Price Trend Prediction with Limit Order Book Data - IDEAS/RePEc, accessed January 27, 2026,
<https://ideas.repec.org/p/arx/papers/2502.15757.html>
 14. TLOB: A Novel Transformer Model with Dual Attention for Price Trend Prediction with Limit Order Book Data - arXiv, accessed January 27, 2026,
<https://arxiv.org/html/2502.15757v3>
 15. TLOB: A Novel Transformer Model with Dual Attention for Stock Price Trend Prediction with Limit Order Book Data - arXiv, accessed January 27, 2026,
<https://arxiv.org/html/2502.15757v2>
 16. Painting the market: generative diffusion models for financial limit order book simulation and forecasting - IDEAS/RePEc, accessed January 27, 2026,
<https://ideas.repec.org/p/arx/papers/2509.05107.html>
 17. [2509.05107] Painting the market: generative diffusion models for financial limit order book simulation and forecasting - arXiv, accessed January 27, 2026,
<https://arxiv.org/abs/2509.05107>
 18. Painting the market: generative diffusion models for financial limit order book simulation and forecasting - arXiv, accessed January 27, 2026,
<https://arxiv.org/html/2509.05107v1>
 19. Painting the market: generative diffusion models for financial limit order book simulation and forecasting | Request PDF - ResearchGate, accessed January 27, 2026,
https://www.researchgate.net/publication/395339618_Painting_the_market_generative_diffusion_models_for_financial_limit_order_book_simulation_and_forecasting
 20. Optimal Execution with Reinforcement Learning in a Multi-Agent Market

- Simulator - arXiv, accessed January 27, 2026, <https://arxiv.org/pdf/2411.06389>
21. Neural Stochastic Agent-Based Limit Order Book Simulation with Neural Point Process and Diffusion Probabilistic Model - University of Bristol Research Portal, accessed January 27, 2026, <https://research-information.bris.ac.uk/en/publications/neural-stochastic-agent-based-limit-order-book-simulation-with-ne/>
 22. Limit Order Book (LOB) Data - Emergent Mind, accessed January 27, 2026, <https://www.emergentmind.com/topics/limit-order-book-lob-data>
 23. Reinforcement Learning for Trade Execution with Market Impact - arXiv, accessed January 27, 2026, <https://arxiv.org/pdf/2507.06345>
 24. [2410.13493] Deep Reinforcement Learning for Online Optimal Execution Strategies - arXiv, accessed January 27, 2026, <https://arxiv.org/abs/2410.13493>
 25. REINFORCEMENT LEARNING FOR OPTIMAL EXECUTION IN FOREIGN-EXCHANGE MARKETS - Lund University Publications, accessed January 27, 2026, <https://lup.lub.lu.se/student-papers/record/9210384/file/9210386.pdf>
 26. Deep Reinforcement Learning for Online Optimal Execution Strategies - ResearchGate, accessed January 27, 2026, https://www.researchgate.net/publication/385010665_Deep_Reinforcement_Learning_for_Online_Optimal_Execution_Strategies
 27. Optimal Execution with Reinforcement Learning - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2411.06389v1>
 28. Optimal Execution with Reinforcement Learning in a Multi-Agent Market Simulator - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2411.06389v2>
 29. An End-to-End Optimal Trade Execution Framework based on Proximal Policy Optimization - IJCAI, accessed January 27, 2026, <https://www.ijcai.org/proceedings/2020/0627.pdf>
 30. [2101.07107] Deep Reinforcement Learning for Active High Frequency Trading - arXiv, accessed January 27, 2026, <https://arxiv.org/abs/2101.07107>
 31. STGAT: Spatial-Temporal Graph Attention Neural Network for Stock Prediction - MDPI, accessed January 27, 2026, <https://www.mdpi.com/2076-3417/15/8/4315>
 32. A Short Survey on Graph Neural Networks Based Stock Market Prediction Models - UPV, accessed January 27, 2026, https://personales.upv.es/thinkmind/dl/conferences/iciw/iciw_2024/iciw_2024_1_30_20016.pdf
 33. STGAT: Spatiotemporal Graph Attention Network for Non - Stationary Financial Systems and Its Application in Stock Price Prediction - Preprints.org, accessed January 27, 2026, <https://www.preprints.org/manuscript/202507.1736>
 34. Stock Trend Prediction with Machine Learning: Incorporating Inter-Stock Correlation Information through Laplacian Matrix - LSEC, accessed January 27, 2026, <https://lsec.cc.ac.cn/~lubz/Publication/2024-BDCC-StockPred-correlationMatrix.pdf>
 35. Stock Market Forecasting with Differential Graph Transformer | by Kevin Xiang Li - Medium, accessed January 27, 2026, <https://medium.com/stanford-cs224w/stock-market-forecasting-with-differential>

- [-graph-transformer-62d095ebc821](#)
36. Accelerating Machine Learning for Trading Using Programmable Switches - Department of Engineering Science, accessed January 27, 2026, <https://eng.ox.ac.uk/media/ofrbihrr/hong2024trading.pdf>
 37. FPGA For High-Frequency Trading Reducing Latency in Financial Systems - Scribd, accessed January 27, 2026, <https://www.scribd.com/document/905201042/FPGA-for-High-Frequency-Trading-Reducing-Latency-in-Financial-Systems>
 38. LightTrader: A Standalone High-Frequency Trading System with Deep Learning Inference Accelerators and Proactive Scheduler | Semantic Scholar, accessed January 27, 2026, <https://www.semanticscholar.org/paper/LightTrader%3A-A-Standalone-High-Frequency-Trading-Yoo-Kim/31c47f249e353c0f27226475d41fd4fb2026b3cc>
 39. LightTrader: A Standalone High-Frequency Trading System with Deep Learning Inference Accelerators and Proactive Scheduler - IEEE Xplore, accessed January 27, 2026, <https://ieeexplore.ieee.org/document/10070930/>
 40. LightTrader: A Standalone High-Frequency Trading System with Deep Learning Inference Accelerators and Proactive Scheduler - Rebellions AI, accessed January 27, 2026, https://rebellions.ai/wp-content/uploads/2023/11/RebellionsIONHPCA23_LightTrader.pdf
 41. Ultra-low Latency DNN Accelerator for High-Frequency Trading, accessed January 27, 2026, https://arbor.ee.ntu.edu.tw/static/gm/20241104_%E6%9E%97%E5%AE%B6%E9%8A%98.pdf
 42. Delivering the AI Edge for High-Frequency Trading - DDN, accessed January 27, 2026, <https://www.ddn.com/resources/whitepapers/delivering-the-ai-edge-for-high-frequency-trading/>
 43. TSPTQ-ViT: Two-Scaled Post-Training Quantization for Vision Transformer - ResearchGate, accessed January 27, 2026, https://www.researchgate.net/publication/374947816_TSPTQ-ViT_Two-Scaled_Post-Training_Quantization_for_Vision_Transformer
 44. FPGA-Aware Automatic Acceleration - Framework for Vision Transformer with Mixed-Scheme Quantization, accessed January 27, 2026, <https://par.nsf.gov/servlets/purl/10323475>
 45. Domain Adaptation for Time Series Under Feature and Label Shifts - Zitnik Lab, accessed January 27, 2026, <https://zitniklab.hms.harvard.edu/projects/Raincoat/>
 46. Test-time Adaptation in Non-stationary Environments via Adaptive Representation Alignment - NIPS, accessed January 27, 2026, https://proceedings.neurips.cc/paper_files/paper/2024/file/abe31a12e83111fdf2cfd54deed5a2ce-Paper-Conference.pdf
 47. Non-stationary Domain Generalization: Theory and Algorithm - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2405.06816v1>
 48. NeurIPS Poster DDN: Dual-domain Dynamic Normalization for Non-stationary

- Time Series Forecasting, accessed January 27, 2026,
<https://nips.cc/virtual/2024/poster/95167>
49. Explainable AI for time series prediction in economic mental health analysis - PMC - NIH, accessed January 27, 2026,
<https://pmc.ncbi.nlm.nih.gov/articles/PMC12241169/>
 50. [2407.15909] A Survey of Explainable Artificial Intelligence (XAI) in Financial Time Series Forecasting - arXiv, accessed January 27, 2026,
<https://arxiv.org/abs/2407.15909>
 51. Explainable AI Deep Dive: Your Friendly Guide to SHAPley Values — Unpacking Theory, Code, and Real-World Impact | by Inkollu Sri Varsha | Medium, accessed January 27, 2026,
<https://medium.com/@inkollusrivarsha0287/explainable-ai-deep-dive-your-friendly-guide-to-shapley-values-unpacking-theory-code-and-a5cb1ebef3d3>
 52. shap/shap: A game theoretic approach to explain the output of any machine learning model. - GitHub, accessed January 27, 2026,
<https://github.com/shap/shap>
 53. EL-VIT: Probing Vision Transformer with Interactive Visualization - arXiv, accessed January 27, 2026, <https://arxiv.org/html/2401.12666v1>