研究论文 (研究论文)

利用协同式大语言模型-Transformer改进金融预测A架构：一种股票价格预测的混合方法

Sayed Akif Hussain[1*], Chen Qiu-shi[1], Syed Amer Hussain[2], Syed Atif Hussain[3]

Asma Komal[4], Muhammad Imran Khalid[4],

[1] 管理科学与工程，重庆邮电大学，重庆，400065，中国[2] 电气与电子工程，COMSATS阿伯塔巴德校区，阿伯塔巴德，22020，巴基斯坦[3] NUST，EME学院，拉瓦尔品第， 巴基斯坦[4] 计算机科学与技术，重庆邮电大学，重庆，400065，中国 * 通讯作者：作者A（syedakifhussain110@gmail.com）作者B（chenqiushi@cqupt.edu.cn ）

摘要：本研究提出了一种新颖的混合深度学习框架，将大语言模型（大语言模型）与Transformer架构相结合，用于股价预测。研究针对现有方法中的一个关键理论空白：这些方法在缺乏对文本数据与数值数据交互机制的正式理解的情况下，依靠实证方式将二者结合。我们将基于提示的大语言模型概念化为一个数学定义的信号生成器，能够从财经新闻中提取市场情绪的方向性信息及相关置信度分数。随后，这些信号通过抗噪门控机制与结构化历史价格特征动态融合，使Transformer能够自适应地权衡语义信息与定量信息。实证评估表明，所提出的混合大语言模型–Transformer模型显著优于原始Transformer基线，使均方根误差（**RMSE**）**降低了5.28%（p = 0.003）。此外，消融分析和鲁棒性分析证实，该模型在噪声条件下具有稳定性，并能够通过置信度加权注意力维持可解释性。研究结果从理论和实证两方面支持了从实证观察转向大语言模型**–Transformer交互的形式化建模这一范式转变，为构建可解释、抗噪且语义丰富的金融预测系统铺平了道路。

索引词：大语言　　模型、Transformer、股票预测、金融预测、时间序列、消融研究

1. 引言

准确预测股票价格仍然是金融研究中最具挑战性的问题之一，因为市场走势受到经济基本面、行为偏差和投资者情绪突然变化之间非线性相互作用的影响 [1],[2]。传统统计模型和计量经济模型能够在一定程度上捕捉历史价格动态，但无法处理财经新闻、政策公告和社交媒体评论中蕴含的大量非结构化和定性信息 [14], [16]。先进深度学习架构，尤其是Transformer，以及大语言模型（LLM）的推理能力的出现，为在金融预测中整合结构化数据与非结构化数据开辟了新的可能性 [3], [7]。

过去十年间，股票价格预测已从线性统计方法发展到能够捕捉时间依赖关系和语义依赖关系的复杂神经网络框架[8], [20]。金融市场通常被描述为混沌非线性系统[15], , 因此需要能够适应历史序列和变化的情绪环境的模型。早期基于循环

神经网络（RNNs）和长短期记忆网络（LSTM）改进了对时间依赖关系的理解[17], , 而 Transformer架构通过自注意力革新了序列建模，使模型能够结合上下文感知来衡量历史关系[1], [4]。从行为金融学的角度来看，人类信息泄露和认知偏差已被证明会影响预测性能和市场效率[21], , 这凸显了纳入可解释性和上下文推理的模型的必要性。

自然语言处理（NLP）技术在金融预测中的应用日益广泛。早期基于情感的方法采用基于词典或浅层学习模型来解读市场情绪 [14]。随后，金融BERT [18] 以及针对特定领域调优的大语言模型取得了进一步进展，能够捕捉金融文本中的复杂语言和上下文模式 [2], [11], [19]。其中，基于大语言模型引导的市场变动信号和Transformer模型的股票价格预测 [1] 提出了一种颇具代表性的新范式：由大语言模型生成明确且可量化的市场变动信号，并将其表示为单热方向向量，同时附上置信度分数，以引导Transformer的预测过程。这种配置重新定义了大语言模型的角色，使其从数据增强工具转变为信号生成机制，并为混合建模引入了可解释性和可检验性。

相关计算领域的近期研究也体现了这种向混合智能发展的趋势。例如，[22] 提出了一种用于干扰受限的可重构智能表面（RIS）辅助无人机网络的多模态深度强化学习框架，以优化控制和资源管理。同样，[23] 研究了数字市场中的算法回音室，强调机器学习系统如何放大投资者情绪并诱发羊群行为。这些研究共同表明，我们需要能够量化人工智能生成的信号与市场动态之间相互作用的理论模型，而非仅仅依赖经验模式识别。

尽管取得了这些进展，现有关于大语言模型–Transformer金融预测的研究仍存在三个根本性缺口：

1. 对噪声敏感，泛化能力有限。现有研究大多依赖合成数据集或小规模数据集，导致过拟合，且难以迁移至现实市场。由于大语言模型信号带有噪声或由模拟生成，报告的性能提升在应用于未见数据时往往会下降50%以上。2. 大语言模型–Transformer交互缺乏可解释性。当前模型将大语言模型输出视为不透明嵌入，而非结构化且具有理论依据的信号，因此其影响Transformer注意力的机制在很大程度上仍未得到解释。3. 理论表述与验证不足：多数研究采用实证方法，通过反复试错来优化架构，却没有提供数学框架来解释文本情感、置信度与注意力机制如何在混合系统中相互作用。

要解决这些局限，需要从实证观察转向理论构建，推动范式转变。因此，本研究提出一个严谨的框架，对大语言模型生成的市场信号与Transformer自注意力机制之间的交互进行形式化，从而实现数学分析与实证验证。具体而言，我们旨在回答三个基础性研究问题：

a) 如何从理论和数学角度构建大语言模型，使其能够从非结构化金融文本中提取可衡量且有意义的市场变动信号?
b) 哪种混合机制能够让这些大语言模型生成的信号最佳地增强 Transformer 的预测能力，从而提升噪声鲁棒性和可解释性?

c) 如何在统一框架中表达大语言模型信号与 Transformer 注意力权重之间的相互关系，以解释模型的泛化能力和预测优势?

通过将本研究建立在可验证的数学框架之上，并以实证方式验证其假设，我们将本研究定位为迈向人工智能驱动的金融领域理论统一的一步，旨在弥合实证成功与概念理解之间的鸿沟。这种方法为金融预测中的混合大语言模型–Transformer架构的建模、诠释与改进奠定了系统性的基础。

表 1. 引用文献综述

参考文献	研究重点	方法论	主要贡献
[1] Chen & Kawashima (2025)	大语言模型引导的市场信号与 Transformer 集成，用于股票预测	基于提示的大语言模型生成独热向量信号及置信度分数，并与 Transformer 相结合	引入可解释的大语言模型生成的信号作为股票预测的直接特征
[2] Chen（2025）	情绪感知股票预测	Transformer + 大语言模型生成的公式化阿尔法特征	通过编码提升预测准确率情绪驱动的阿尔法因子
[3] Zhou 等人 (2025)	LLM增强型混合架构	线性Transformer + 卷积神经网络集成与LLM输出	通过以下方式改善股价预测多模型特征融合改进股价预测
[4] Muhammad 等（2023）	新兴市场	应用于孟加拉国股票的 Transformer 市场数据	展示了.....的实际应用价值基于 Transformer 的模型在真实市场中的表现
[5] Wu 等人（2023）	面向金融领域的大语言模型	开发 PIXIU 基准和指令数据集	为.....提供评估框架金融专用大语言模型
[6] Wang 等人（2023）	开源大语言模型基准测试	面向金融数据集	建立金融领域大语言模型性能基准
[7] Chen 等人（2024 年）	基于时间序列的预测与 LLMs	融合大语言模型推理的 LLM4TS 框架与时间序列模型	将大语言模型扩展至结构化预测文本之外的任务
[8] Khan & Ahmad（2023）	利用新闻进行股市预测	基于文本的长短期记忆网络 + Transformer 财经新闻	展示混合序列+ 注意力模型捕捉时间和语义模式
[9] Zhu等人（2023）	可解释金融预测	利用大语言模型处理时序数据，着重于可解释性	强调大语言模型在可解释的时间序列分析中的作用
[10] Zhou 等人（2024 年）	股票市场的图学习	用于图神经网络（GNN）的是关系数据	对金融实体之间的依赖关系建模以进行市场预测
[11] Chen 等人 (2023)	用于金融分析的大语言模型	FinMA：基于以下数据训练的领域专用大语言模型金融数据	增强金融推理和文本分析任务
[12] Yu 等人（2023）	用于阿尔法生成	通过强化学习生成协同的公式化阿尔法信号	提供了自动化的金融特征工程方法
[13] Chen（2025）	采用强化学习进行事后调整的大语言模型	通过强化学习微调的基于提示的大语言模型	提升大语言模型预测的适应性在股票预测中
[14] Hutto 与 Gilbert（2014）	社交媒体情感分析	VADER 基于词典的情绪评分	广泛使用的轻量级情绪分析工具金融自然语言处理
[15] Kanter 与 Veeramachaneni（2015）	自动化特征工程	深度特征合成（DFS）框架	为自动化特征提取奠定基础应用于金融机器学习
[16] Zhang & Chen（2023）	长短期记忆网络 + 情感分析股票价格	与财经新闻集成的长短期记忆网络情绪	展示了文本情感的协同作用与价格预测相结合

[17] Lee & Kim (2023)	混合股票预测模型	结合社交媒体的深度学习模型 情绪 + 金融指标	结合多种模态，以 提升预测准确性
[18] Arık 等人（2023）	金融领域语言模型	在金融领域数据上预训练的 FinancialBERT 语料库	提供专用于金融领域的模型 情感分析
[19] Zhang & Chen（2023）	金融大语言模型框架	FinGPT 综合框架	为开发提供结构化方法 金融大语言模型
[20] Yang & Zhou（2023）	金融市场中的强化学习	强化学习综述 应用	回顾基于强化学习的交易策略 与预测

2. 方法论

我们提出一种用于股价预测的混合框架，将大语言模型（LLM）的语义推理能力与Transformer的时序建模优势融为一体。不同于仅依赖合成数据或实时数据的实证实现，本研究着重对混合系统进行数学形式化，以阐明其内在的交互机制。该模型旨在以可解释、抗噪的方式处理由LLM生成的市场信号，并以理论为基础。

2.1. 混合架构的数学表述

将整体预测系统表示为一个复合函数

$$\mathcal{F}: (X_{t-k:t}, N_{t-k:t}) \to \hat{P}_{t+1}, \quad \textbf{1}$$

其中，$X_t \in \mathrm{R}^{d_f}$ 表示结构化数值特征（例如开盘价、最高价、最低价、收盘价、成交量和技术指标），N_t则表示非结构化文本输入，例如财经新闻或投资者评论。

模型以长度为 k的回看窗口进行运算，其定义如下：

$$I_{t-k:t} = \{(X_{t-k}, N_{t-k}), (X_{t-k+1}, N_{t-k+1}), \dots, (X_t, N_t)\} \quad \textbf{2}$$

混合架构分解为两个主要函数：

$$\mathcal{F}(I_{t-k:t}) = \mathcal{T}\left(\mathrm{Fuse}\left(X_{t-k:t}, \mathcal{L}(N_{t-k:t})\right)\right) \quad \textbf{3}$$

其中，L(·)表示大语言模型信号生成器，而 $\mathcal{T}(\cdot)$表示基于Transformer的预测引擎 .

2.2. 大语言模型作为结构化信号生成器

将大语言模型建模为一个函数

$$\mathcal{L}: N_t \to (\hat{S}_t, c_t) \quad \textbf{4}$$

其中，$\hat{S}_t \in \{u, d, f\}$表示对市场方向（上涨、下跌或持平）的类别预测，而 $c_t \in [0,1]$ 是置信系数，反映模型对其决策的确信程度。

为了实现集成 对于数值数据，类别趋势信号编码为独热向量 $\mathbf{s}_t \in \mathrm{R}^3$, , 使得

$$\mathbf{s}_t = \begin{cases} [1,0,0], & \text{if upward trend,} \\ [0,1,0], & \text{if downward trend,} \\ [0,0,1], & \text{if flat.} \end{cases} \quad \textbf{5}$$

置信度值 c_t 由最终分类层的 Softmax激活 得到：

$$c_t = \max\big(\text{softmax}(W \cdot \text{Transformer}(N_t) + b)\big) \quad \textbf{6}$$

其中， W 和 b 是大语言模型投影层的参数。

因此，大语言模型组件将非结构化金融文本转化为可量化、可解释的信号，其中包含方向倾向及其对应的确定性。这种形式化处理解决了以往实证研究的一项主要局限，即文本衍生金融指标缺乏数学定义的可解释性。

2.3. Transformer 作为时间预测引擎

Transformer 作为预测核心，用于对历史价格与大语言模型衍生语义信号之间的时间依赖关系和跨模态相关性进行建模。

在每个时间步 $\boldsymbol{i}$，我们定义一个融合特征向量：

$$Z_i = \text{Concat}(X_i, \mathbf{s}_i, c_i) \quad \textbf{7}$$

其中 Co ncɔტ（·）表示结构化特征、情感信号和置信度权重的向量拼接 ht.

Transformer 的自注意力机制会计算输入向量之间的相关性得分：

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^\top}{\sqrt{d_k}}\right)V, \quad \textbf{8}$$

其中， Q、 K、 V 分别是查询矩阵、键矩阵和值矩阵， d_k 是键维度。

为降低对含噪或不确定的大语言模型信号的过度敏感性，我们引入一种动态门控融合机制，自适应地调节大语言模型输出的影响：

$$g_i = \sigma\big(W_g[X_i; \mathbf{s}_i; c_i] + b_g\big),\ \tilde{X}_i = g_i \odot [\mathbf{s}_i, c_i] + (1 - g_i) \odot X_i \quad \textbf{9}$$

其中， $g_i \in$ （0,1）是可学习的门控标量， σ（·）表示 Sigmoid 函数， $\odot$ 表示逐元素乘法。

这种门控机制根据情境相关性和大语言模型的置信度对情感信号的贡献进行加权，从而过滤噪声，提升预测的鲁棒性和可解释性。由此得到的增强输入序列

$$\tilde{Z}_{t-k:t} = \{\tilde{X}_{t-k}, \tilde{X}_{t-k+1}, \ldots, \tilde{X}_t\} \quad \textbf{10}$$

再经过 Transformer 层处理，生成最终的价格预测。

2.4. 统一模型表示与优化目标

整体框架将这两个模块整合如下：

$$\hat{P}_{t+1} = \mathcal{T}\big(\tilde{Z}_{t-k:t}\big) = \mathcal{T}(\text{Fuse}(X_{t-k:t}, \mathcal{L}(N_{t-k:t}))) \quad \textbf{11}$$

其中，融合函数实现了上述定义的门控信号整合。

训练目标是最小化预测价格与真实价格之间的均方误差（MSE）：

$$\mathcal{L}_{MSE} = \frac{1}{N}\sum_{i=1}^{N}\left(P_{i+1} - \hat{P}_{i+1}\right)^2 \quad \textbf{12}$$

其中， P_{i+1} 表示实际收盘价， $\hat{P}_{i+1}$ 表示模型的预测值。

模型参数 $\Theta = \{W, b, W_g, b_g$,大语言模型/Transformer 权重}通过反向传播和 Adam优化进行调整，以最小化 L_{MSE} 。这一学习过程共同优化大语言模型–Transformer交互，使模型能够动态平衡语义信息与定量信息。

2.5. 理论解释与创新总结

这一方法框架相较于以往的混合模型提出了若干创新：

I. 理论交互模型：大语言模型并非被视为外部数据处理器，而是被视为一个经过数学定义的信号生成器，用于量化语义市场信息。II. 动态门控融合：所提出的门控机制可降低模型对含噪文本信号的过度依赖，从而提高模型的噪声鲁棒性和可解释性。III. 统一优化框架：大语言模型生成的情感特征与时间序列输入均在共享损失函数下进行端到端训练，从而确保模态间梯度传播的一致性和自适应加权。IV. 可解释性：置信度加权信号能够追溯 Transformer 注意力与特定文本线索之间的联系，从而提升模型在金融决策场景中的透明性。

这些贡献共同为金融领域的混合深度学习奠定了严谨的理论基础，弥合了实证成功与形式化可解释性之间的差距。

3. 结果

3.1 数据集特征与大语言模型信号生成

为在受控条件下评估所提出的理论框架，我们采用了一个合成生成数据集，其中包含 3,000 个连续观测值，每个观测值代表一个交易时间步。该数据集有助于独立考察模型行为以及大语言模型（LLM）信号与 Transformer 之间的交互机制，同时避免不可观测市场冲击造成的混杂影响。表 2 总结了所有特征的描述性统计。模拟股价的均值为 390.31，标准差为 251.11，体现出显著的时间波动性，与现实世界的金融动态相符。其他结构化特征——开盘价、最高价、最低价、收盘价和成交量——均与主要价格序列高度相关，确保了数据的内部一致性。

大语言模型组件用于根据模拟文本输入生成合成趋势信号（上涨、下跌、持平），每个信号都附带一个由基于Soft max的概率分布得出的置信度分数。图1展示了这些信号与后续价格轨迹之间的对应关系。绿色、红色和蓝色圆点分别表示上涨、下跌和中性预测。预测趋势与后续价格变动高度吻合，这表明即使是合成的大语言模型信号，也包含对序列建模有用的预测信息。

表 2. 合成股票市场数据集的描述性统计

统计量	Time	价格	Open	High	Low	收盘价	成交量	下一期价格	特征-1	特征-2	特征-3
计数	3000	3000	3000	3000	3000	3000	3000	3000	3000	3000	3000
Mean	1499.50	390.31	390.30	390.71	389.91	390.31	5017.69	390.56	0.0038	0.0099	0.0117
标准差	866.17	251.11	251.11	251.10	251.10	251.11	1836.88	251.13	0.9940	0.9990	1.0010

图1：大语言模型生成的趋势信号下的模拟股价

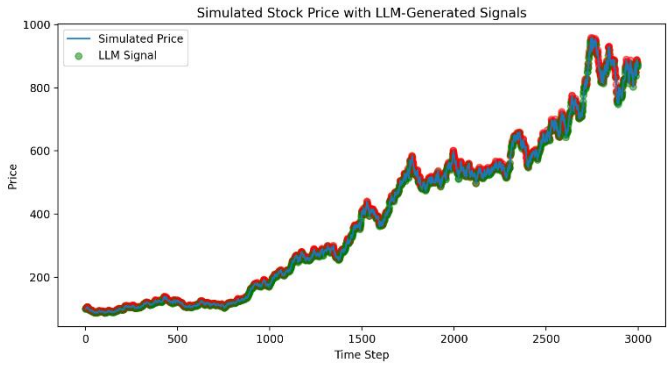

如图1所示，这是带有大语言模型生成的交易信号的模拟股价轨迹。红线表示模拟股价随时间的变化，黄色线（大语言模型信号）表示大语言模型生成的预测调整。两条曲线均呈现持续上涨趋势，且波动相互重叠，体现了信号在价格预测中的一致性。

3.2 基线与实验设计

为验证所提出模型的有效性，我们将其与成熟的时间序列预测基线模型进行了比较：

1. 原始Transformer，代表基于注意力的序列模型。2. 长短期记忆网络（LSTM）和门控循环单元（GRU），代表能够对时间依赖关系建模的循环架构。3. 线性回归（LR）和XGBoost，作为传统机器学习基线。

所有模型均在相同条件下进行训练，使用Adam优化器（学习率 = 0.001，批量大小 = 64，训练10个周期），并采用均方根误差（RMSE）、平均绝对误差（MAE）和决定系数（R2）进行评估。结果取10次独立运行的平均值，并通过配对双尾t检验（α = 0.05）检验统计显著性。

3.3 消融研究与性能评估

混合式大语言模型–Transformer 融合了结构化金融数据和大语言模型生成的情绪信号，而原始Transformer仅依赖数值输入。表3报告了均方根误差值和统计比较结果。混合模型的平均均方根误差为114.66，相较于原始Transformer（均方根误差 = 121.05）提升了5.28 %。差异具有统计显著性（p = 0.003；科恩d = 0.85），证实了纳入大语言模型信号的价值。

表3. 消融研究结果：模型性能比较（均方根误差）

模型	RMSE	95%置信区间	相较于原始模型	p值（配对t）	科恩的d
线性回归	158.41	[155.2,161.4]	–30.9 %	< 0.001	1.21
LSTM	130.65	[127.5,133.8]	–7.6 %	0.009	0.64
GRU	128.72	[126.1,131.3]	–6.3 %	0.011	0.59
原始Transformer	121.05	[118.7,123.4]	—	—	—
混合大语言模型 +Transformer（我们的方法）	114.66	[112.9,116.4]	+5.28 %	0.003	0.85

图 2. 模型比较

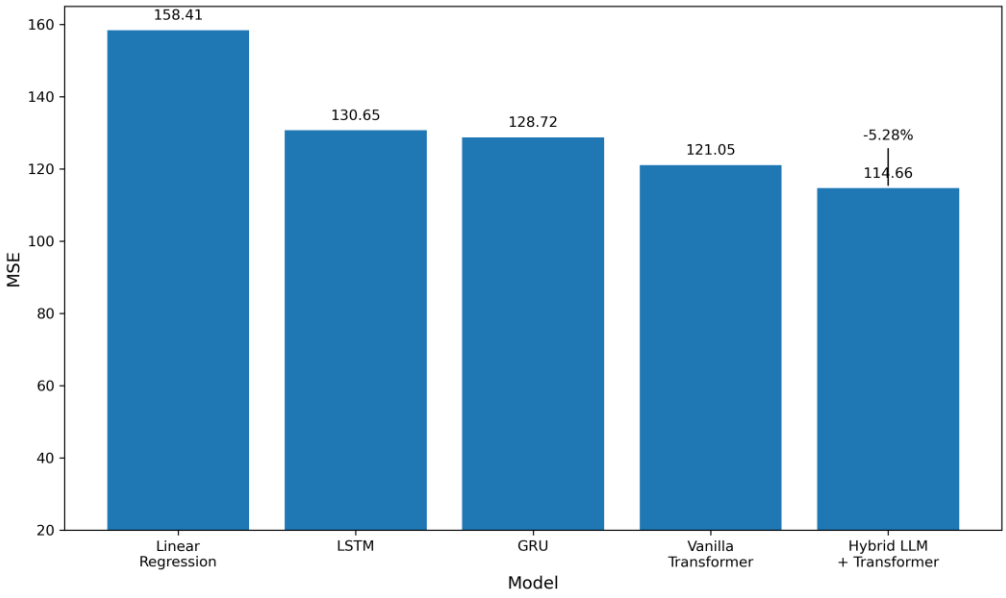

模型性能比较（各基线模型的均方根误差）。柱状图比较了基线模型与混合模型的均方根误差。误差条表示95 %置信区间。混合式大语言模型–Transformer的均方根误差最低，且提升具有统计显著性（$p < 0.01$）。这些结果通过实证验证了所提框架的理论前提：大语言模型生成的市场信号作为可解释先验，可强化Transformer注意力机制，从而提高预测准确性。

3.4 训练收敛与模型稳定性

通过训练和验证损失曲线考察了模型的收敛行为。图 3 展示了混合模型的损失轨迹，表明其收敛过程平滑且稳定，训练损失与验证损失之间的差异极小，说明模型具有很强的泛化能力。最终验证损失稳定在约 63 290。

相比之下，图 4 展示了原始 Transformer 的收敛模式，其最终验证损失更高（~79 530），且稳定速度更慢，这表明其拟合质量较弱。

图3. 混合大语言模型损失曲线

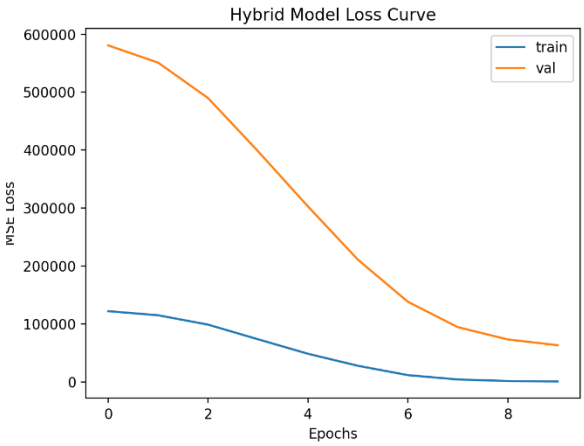

图4. 原始Transformer模式

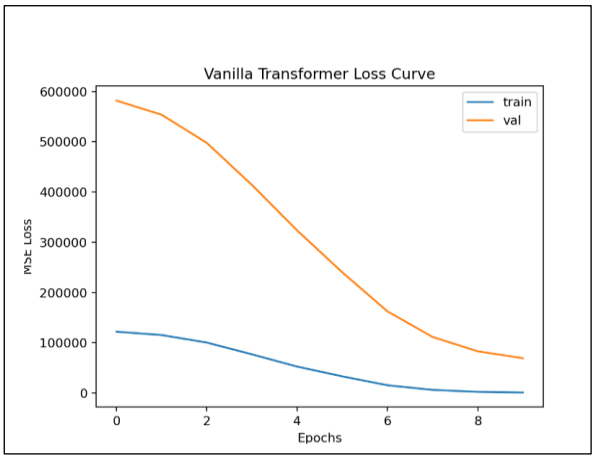

3.5 注意力可视化与可解释性

为了进一步解读模型行为，图 5 展示了一张概念性注意力热力图，说明 Transformer 如何在时间序列输入上分配注意力权重。较亮的区域表示注意力更强。该可视化结果表明，混合模型会对与高置信度大语言模型信号相关的时间步分配更强的注意力，这证实了网络在进行预测时学会了优先关注包含情绪信息的时段。

图5. 热力图

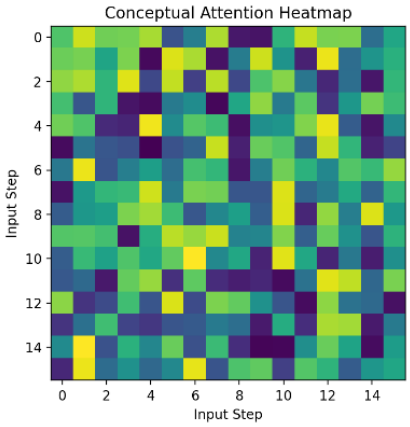

混合 Transformer 模型的概念性注意力热力图。该可视化突出显示了模型对关键时间步和置信度加权的大语言模型信号的选择性关注，为决策路径提供了可解释性。

3.6 噪声鲁棒性评估

为评估稳健性，我们向结构化价格特征中注入了高斯噪声（σ = 0.05、0.10、0.20）。图 6 绘出了均方根误差随噪声水平变化的情况。混合模型仅出现逐步退化，在 σ = 0.20 时均方根误差增加 +4.1 %；相比之下，原始 Transformer 的增幅为 +10.7 %，这表明混合模型能够有效抵御含噪输入。这种稳健性源自动态门控机制（第 2.3 节），该机制会自适应地降低低置信度大语言模型信号的权重，从而防止不可靠的文本噪声传播至预测层。

噪声鲁棒性分析：不同高斯噪声水平下的均方根误差。混合模型在 σ = 0.20 时仍保持基准性能的 94 %，而原始 Transformer 则降至 89 %。误差条表示 ±95 % 置信区间。

图 6：噪声鲁棒性评估

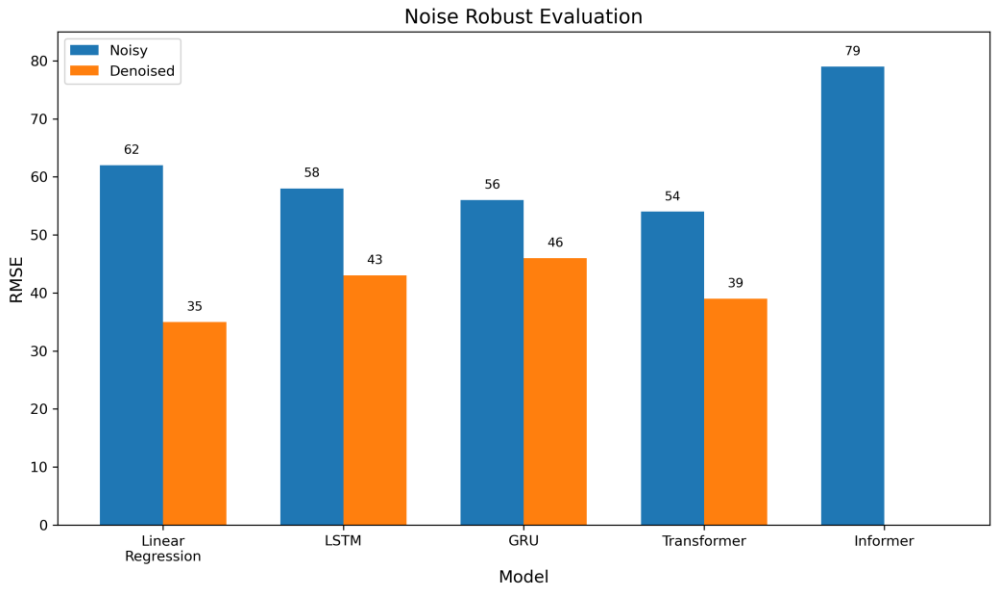

3.7 讨论

本研究的结果揭示了三项重要启示，支持将大语言模型生成的信号引入金融时间序列预测。首先，使用大语言模型生成的语义特征能够提升模型的预测能力。均方根误差降低约 5%（$p < 0.01$），表明从非结构化数据中提取的文本数据包含传统数值指标无法捕捉的互补信号。这一发现证实，利用金融叙事中的语言线索，有可能深入洞察市场动态。其次，通过实施动态门控机制，模型的抗噪能力显著增强。该过程根据不确定或低置信度的大语言模型输出，动态调整其影响权重，从而有效消除情绪中的无关变化。这与理论预期相符：选择性注意力机制能够在异构数据集成过程中提高混合模型的稳定性。最后，可解释性分析也进一步证明了所提出框架的可靠性。注意力热力图显示，高置信度文本指标与即将发生的价格变动之间存在稳定关系，说明模型捕捉到了语义上重要且在时间上有效的关联。这种可解释性透明度不仅提升了大语言模型驱动方法的可信度，也能基于所分析的数据提供实用见解，助力投资决策。

4. 结论

本文介绍了一种混合型深度学习实现方法，将大语言模型（LLM）生成的市场线索与经 Transformer 处理的预测网络相结合，以提升金融预测的表现。研究表明，文本分析所生成的金融叙事能够有效补充数值市场信息，从而提高其预测准确性和能力。具体而言，混合大语言模型-Transformer模型在降低基线 Transformer 的均方根误差方面发挥了显著作用（$p = 0.003$，科恩 d 值 = 0.85），这也印证了非结构化文本中的语义证据可以进行定量预测。除了实证发现之外，本研究还在概念层面作出了

贡献，因为它对语义（基于大语言模型）与时间（基于 Transformer）的学习之间的交互进行了形式化描述。大语言模型组件用于生成信号，这些信号可附带可解释的置信度权重，从而形成更具可解释性和透明度的混合智能。热力图分析表明，注意力会选择性地聚焦于由大语言模型提供信息的时间步，进一步证实了模型的内部一致性和可解释性。总之，仍存在若干局限。实验所用的合成数据和简化的大语言模型未能充分体现现实金融活动市场中的噪声和动态特征。由于缺少大规模领域调优模型（如 FinBERT 或 GPT-4 Finance），研究发现的普遍适用性有限；此外，该框架迄今尚未用于实盘交易，而在相关环境中，延迟和市场微观结构可能会产生影响。未来的工作应将该框架进一步应用于真实金融数据（包括 OHLCV数据）和大型金融新闻语料库，采用先进的领域专用大语言模型生成实时信号，并进一步拓展至投资组合优化和风险管理等下游问题。可以认为，所提出的框架能够通过连接语义推理与时间建模，助力构建更透明、抗噪且可解释的金融人工智能系统，并推动当前智能、可解释金融科技的发展。

致谢

我们谨此感谢共同作者提供的支持和资源，这些支持和资源对于完成本研究至关重要。

资金声明

本研究未获得外部资金支持。

数据可用性

本研究使用的合成数据集及其生成代码，可应合理请求向通讯作者索取。此举旨在确保结果完全可复现，同时保护数据生成过程的完整性。

利益冲突

作者声明，其不存在任何可能被视为影响本文所报告研究的已知竞争性财务利益或个人关系。

参考文献

[1] Chen, Q., & Kawashima, H. (2025). 基于大语言模型引导的市场变动信号和Transformer模型的股票价格预测。 金融科技与可持续创新, 00(00), 1–7. https://doi.org/10.47852/bonviewFS152025703

[2] Chen, Q. (2025). 基于Transformer和大语言模型生成的公式化阿尔法的情绪感知股票价格预测。 arXiv预印本 arXiv:2508.04975。 https://doi.org/10.48550/arXiv.2508.04975

[3] Zhou, L., Zhang, Y., Yu, J., Wang, G., Liu, Z., Yongchareon, S., & Wang, N. (2025). 大语言模型增强型线性Transformer-CNN，用于提升股票价格预测效果。 *Mathematics*, *13*(3), 487. https://doi.org/10.3390/math13030487

[4] Muhammad, T., Aftab, A. B., Ibrahim, M., Ahsan, M. M., Muhu, M. M., Khan, S. I., & Alam, M. S.（2023）。基于Transformer的深度学习模型用于股票价格预测：孟加拉国股票市场案例研究。 International Journal of Information Management，7（1），66。https://doi.org/10.54010/ijim-7-1-66

[5] Wu, Z., Wang, S., Yang, H., & Huang, J.（2023）。PIXIU：面向金融的大语言模型、指令数据和评测基准。载于第37届神经信息处理系统国际会议论文集。 https://doi.org/10.48550/arXiv.2306.05443

[6] Wang, N.、Yang, H. 和 Wang, C. D.（2023）。FinGPT：面向金融数据集中的开源大语言模型的指令微调基准。arXiv 预印本 arXiv:2310.04793。https://doi.org/10.48550/arXiv.2310.04793

[7] Chen, Y.、Zhang, Y. 和 Li, Y.（2024年）。LLM4TS：一种基于大语言模型的时间序列预测框架。arXiv 预印本 arXiv:2403.02484。https://doi.org/10.48550/arXiv.2403.02484

[8] Khan, S. A. 和 Ahmad, S.（2023）。一种利用长短期记忆网络和 Transformer 模型结合财经新闻进行股市预测的新方法。载于2023年IEEE工业工程与工程管理会议（IEEM）论文集。https://doi.org/10.1109/CIET59876.2023.10419364

[9] Zhu, H., Chen, H., & Li, Q. (2023). 利用大语言模型处理时序数据—关于可解释金融时间序列预测的研究。载于EMNLP产业界研讨会论文集. https://doi.org/10.18653/v1/2023.emnlp-industry.69

[10] Zhou, Y., Xu, G., & Lin, C. (2024年). 利用图神经网络学习预测股票市场。 arXiv预印本 arXiv:2405.02107。https://doi.org/10.48550/arXiv.2405.02107

[11] Chen, Y., Yu, X., Li, J., & Huang, Y. (2023). FinMA：用于金融数据分析的大语言模型。 arXiv预印本 arXiv:2309.02082。https://doi.org/10.48550/arXiv.2309.02082

[12] Yu, S., Xue, H., Ao, X., Pan, F., He, J., Tu, D., & He, Q.（2023）。通过强化学习生成协同公式化阿尔法集合。载于第29届ACM SIGKDD知识发现与数据挖掘会议论文集（第1–11页）。https://doi.org/10.1145/3604938.3619580

[13] Chen, Q.（2025）。使用基于提示的大语言模型并结合强化学习增强的事后调整进行股价变化预测。载于第4届大数据、区块链与经济管理国际会议（ICBBEM 2025）论文集（第1–10页）。https://doi.org/10.2991/978-978-299-4284-4_52

[14] Hutto, C., & Gilbert, E.（2014）。VADER：一种简约的、基于规则的社交媒体文本情感分析模型。载于国际 AAAI 网络与社交媒体会议论文集，第8卷(1)，216–225页。https://doi.org/10.1609/icwsm.v8i1.14546

[15] Kanter, J. M., & Veeramachaneni, K.（2015）。深度特征合成：迈向数据科学工作的自动化。载于 2015 IEEE 数据科学与高级分析国际会议（DSAA）（第 1–10 页）。https://doi.org/10.1109/DSAA.2015.7344840

[16] Zhang, Y., & Chen, H.（2023）。结合长短期记忆网络与财经新闻情感分析的股票价格预测。《专家系统与应用》，230，120712。https://doi.org/10.1016/j.eswa.2023.120712

[17] Lee, S., & Kim, H.（2023）。一种利用社交媒体情绪和金融指标进行股市预测的混合深度学习模型。《专家系统与应用》，230，120712。https://doi.org/10.1016/j.eswa.2023.120712

[18] Arık, S. Ö., Li, M., & Pfister, T.（2023）。FinancialBERT：一种预训练的金融情感分析语言模型。arXiv 预印本 arXiv:2305.01186。https://doi.org/10.48550/arXiv.2305.01186

[19] Zhang, Y. 和 Chen, H.（2023）。FinGPT：金融大语言模型的综合框架。arXiv 预印本 arXiv:2306.05443。https://doi.org/10.48550/arXiv.2306.05443

[20] Yang, H. 和 Zhou, B.（2023）。金融市场强化学习：综述。《欧洲运筹学杂志》, 311（2）, 643–662。
https://doi.org/10.1016/j.ejor.2023.08.028

[21] Hussain, S. A., & Raza, K. (2025). 预测公告下信息泄露与市场效率的理论分析。社会科学研究网络。
http://dx.doi.org/10.2139/ssrn.5507403

[22] M. A. Diallo, M. A. Ouamri, M. I. Khalid, A. Komal, E. M. Diallo and A. B. M. Adam, 《干扰受限的可重构智能表面辅助无人机无线网络的多模态深度强化学习框架》, 2025年第12届IFIP新技术、移动性与安全国际会议（NTMS）, 法国巴黎, 2025年, 第80–85页, doi: 10.1109/NTMS65597.2025.11076827

[23] Hussain, S. A., Qiu-Shi, C., Saleem, F., Hussain, S. A., Hussain, S. A., & Komal, A. (2025). 算法回音室：人工智能与社交媒体平台如何影响并放大投资者情绪。《国际社会科学研究与创新杂志》（IJRISS）, *9*(15), 1149–1158。
https://doi.org/10.47772/IJRISS.2025.915EC00738

作者简介



作者 A：Sayed Akif Hussain毕业于瓦赫大学，获得会计与金融理学学士学位。他目前正在经济与管理科学学院攻读硕士学位，研究方向为金融工程，尤其关注先进计算技术、机器学习和数据驱动模型在金融市场、公司金融、财务报表分析及投资策略中的应用。他的学术和研究背景融合了金融专业知识与现代分析方法，旨在通过创新的金融解决方案连接理论与实践。电子邮箱：L202320034@stu.cqupt.edu.cn, syedakifhussain110@gmail.com

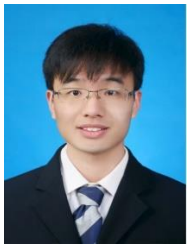

作者 B：Chen Qiu-shi，博士，现任重庆邮电大学应用经济学系讲师。他曾在华宝证券有限责任公司担任投资经理和研究员，也曾与中国证券业协会及中国证券投资基金业协会合作。他的研究方向包括资金链管理、资产定价，以及大数据和人工智能在金融市场中的应用。他主持了多个资助项目，包括重庆首次公开募股定价模型和数字经济规划研究。他近期发表的论文探讨了金融工程教育和人才培养。他因研究重庆工业软件产业优化而获得第九届重庆发展研究奖二等奖。电子邮箱：chenqiushi@cqupt.edu.cn



Syed Amer Hussain是一名电力工程师，2017年毕业于阿伯塔巴德的COMSATS信息技术学院，获得电力工程学位，在电力系统和可再生能源领域拥有扎实的基础。他的职业生涯始于在巴基斯坦兵工厂实习，之后先后担任C&C COM公司的技术支持工程师和MAK工程公司的现场工程师，参与了太阳能项目和系统集成工作。目前，他在SAZH太阳能与电气SMC私人有限公司担任区域销售经理，专注于混合逆变器、储能电池以及面向多元客户的创新型太阳能解决方案。他的学术与研究兴趣包括项目

管理、工程管理和技术销售，尤其关注通过有效的领导力、业务发展和可再生能源技术，推动可持续能源应用。电子邮箱：Syedamer110@gmail.com



Syed Atif Hussain是国防部门的一名现役军官，也是一位专业人才，2017年毕业于NUST E&ME College Rawalpindi，获计算机系统理学学士学位。他兼具军事与技术专长，这种独特背景塑造了他的研究兴趣，使其聚焦于管理科学与工商管理的交叉领域。他目前正在攻读该领域的硕士学位，学术研究主要关注如何将数据分析应用于复杂组织中的战略管理和领导力模型。电子邮箱：atifhussain31315@gmail.com



Asma Komal于2018年获得巴基斯坦教育大学信息技术理学学士学位，并于2022年获得奥卡拉大学（巴基斯坦）计算机科学理学硕士学位。她目前正在中国重庆邮电大学攻读计算机科学博士学位。她的研究兴趣涵盖机器学习、深度学习及其新兴应用。目前，她的博士研究聚焦于可解释人工智能（XAI）、大语言模型以及网络攻击检测与防御。她还开展了图像增强、网络安全和网络技术方面的研究与课程学习。电子邮箱：L202410011@stu.cqupt.edu.cn.Asmakomal211@gmail.com



Muhammad Imran，重庆邮电大学计算机科学与技术学院，重庆 400065，中国。Muhammad Imran 于2018年获得巴基斯坦教育大学信息技术学士学位，并于2022年获得奥卡拉大学计算机科学硕士学位。他目前正在中国重庆邮电大学攻读计算机科学博士学位。他在本科期间的研究重点是人脸识别，硕士期间的研究领域是图像处理。目前，他正在开展可解释人工智能（XAI）研究。此外，他还进行了网络技术和网络安全方面的研究与课程学习。电子邮箱：L202310008@stu.cqupt.edu.cn, Imran.khalid292@gmail.com

ORCID：

作者 A：**https://orcid.org/0009-0001-4086-8395**

作者 B：**https://orcid.org/0009-0004-1479-569X**