

深度学习驱动的股价预测：多源融合与特征协同研究综述

杨 刚

上海海事大学，上海 201306

摘要：本文以“数据融合—特征提取—决策协同”为归纳主线，系统梳理了深度学习在股价预测中的研究进展，从早期、晚期和中期融合三个层次归纳了多源数据的整合策略，分别评述了以卷积注意力网络为代表的时序建模方法和以图神经网络为核心的空间关联建模技术，分析了异质特征动态融合从静态加权向自适应调节演进的内在逻辑。在此基础上，针对融合策略静态化和市场拓扑信息利用不足的问题，提出了一种融合卷积注意力网络、知识图谱图神经网络与自适应加权机制的集成预测框架，并展望了动态图学习等前沿方向。

关键词：股价预测；深度学习；多源数据融合；自适应融合

DOI: 10.64649/yh.shfzykjcx.issn3078-8994.202606015

0 引言

股价预测中，股票市场价格波动既受个股历史交易规律的驱动，也受到行业联动、产业链传导和投资者情绪等关联溢出效应的影响^[1]。随着深度学习技术的发展，如何有效整合多源异构数据并实现异质特征的深度协同，成为提升预测精度的关键问题。本文系统梳理了该领域的研究进展，揭示了融合策略静态化和市场拓扑信息利用不足两方面的局限，进而提出相应的集成预测框架，以期为该领域的进一步探索提供参考。

1 研究背景与相关工作

传统统计学方法在处理线性时序关系上具备理论基础，但难以刻画市场的非线性与非平稳性特征；早期机器学习方法提升了非线性建模能力，但仍依赖人工特征工程。

深度学习为股价预测开辟了新的技术路径。以卷积神经网络（CNN）、长短期记忆网络（LSTM）及其注意力增强变体为代表的时序建模方法，能够从历史行情数据中挖掘多尺度波动模式与长程依赖关系^{[2][3]}。孙瑞奇^[4]对比了BP、RNN和LSTM在股价短期预测中的性能，验证了LSTM的选择性记忆机制在捕捉时序依赖关系上的优势。以图神经网络（GNN）为代表的空间建模方法，将股票间的行业归属、概念关联及供应链关系等抽象为图拓扑结构，为刻画市场内部的关联传导效应提供了适配的技术工具^{[5][6]}。财经新闻文本、社交媒体舆情等非结构化数据所承载的市场情绪信息，通过自然语言处理技术被量化为可供模型输入的特征向量，丰富了预测的信息源^{[7][8]}。

然而，不同来源、不同模态的数据在统计分布、语义尺度和时间粒度上存在显著差异，如何实现多源异构信息的有效融合，构成了提

升预测精度的关键瓶颈。现有融合策略在模态对齐、融合层次选择等方面仍面临诸多挑战^[9]。已有综述为理解该领域的整体发展脉络提供了重要参考^[10]。本文在此基础上，围绕“数据融合—特征提取—决策协同”的技术主线，系统梳理了深度学习在股价预测中的研究进展。

本文以“股价预测”“深度学习”“多源数据融合”等为关键词，在中国知网、Web of Science等数据库检索近十年文献，优先选取与多源数据融合和异质特征协同相关的代表性成果进行梳理。

2 多源异构数据融合策略

股票预测数据源具有显著的多元性与异质性，可划分为结构化量化数据（价量行情序列、技术指标）和非结构化文本数据（财经新闻、公司公告、社交媒体舆情）两类。李辰宇^[11]以中国平安股票为例，整合历史交易、基本面、技术面及情感特征四大数据源，验证了多源数据融合相较于单一数据源的性能优势。如何将这些模态各异、分布悬殊的信息进行有效整合，是模型设计的首要问题。依据融合发生的阶段，现有策略可归为早期融合、晚期融合和中期融合三个基本范式。

2.1 早期融合

早期融合在数据进入特征提取网络之前，将来自不同来源的特征向量直接拼接为联合输入空间，交由统一模型处理。例如，Hoseinzade等^[2]将交易数据与技术指标拼接为二维矩阵输入CNN；Jin等^[12]将新闻情感得分与量化指标对齐后送入循环神经网络。李海燕^[13]采用主成分分析与遗传算法优化BP神经网络，在特征输入端实现了多源指标的筛选与融合。蒋雨芯与魏先华^[8]进一步构建了融合历史行情、宏观经济指标及财经新闻的图像化整合框架，验证了

该方法相较于单一数据源模型的优越性。

然而，早期融合的局限性同样显著。模态间的统计分布与语义异质性难以通过简单缩放消除。更重要的是，早期融合隐含“各模态贡献度均等”的假设，但实际市场中量化指标与文本情绪的预测有效性随市场状态显著变化——平稳期技术指标更具参考价值，事件驱动期新闻情感往往扮演主导角色。固化拼接难以适配这种动态变化的贡献度结构，可能导致关键信号被稀释、次要噪声被放大。

2.2 晚期融合

晚期融合采取相反的设计理念：各模态先由独立编码器分别完成特征提取与预测，再在决策层对多模型输出进行加权平均或元学习组合。该方法的核心优势在于充分保留各模态的建模独立性，使子模型专注于自身模态内的规律挖掘。Zhang等^[14]分别训练基于量化数据和文本数据的预测器，再通过线性加权综合输出，实证表明该方法在信息异质性较强的场景下优于单模态模型。

但晚期融合的主要局限在于决策层汇合之前，各模态间缺乏中间表示层面的信息交互，潜在的低层跨模态协同模式可能在独立编码阶段即被忽略。此外，固定权重或简单投票机制同样面临无法适应市场状态动态变化的困境^[15]。

2.3 中期融合与门控机制

中期融合在特征提取的中间层引入跨模态交互，兼顾了早期融合的信息充分交互与晚期融合的模态独立性保护。近年来，基于门控机制的中期融合方法受到广泛关注。Arevalo等^[16]提出的门控多模态单元通过对各模态分别编码后由乘法门控动态决定贡献权重；Kim等^[17]提出的门控信息融合网络则对各模态使用独立卷积处理并联合中间层特征进行动态加权。

在股价预测领域，中期门控融合展现出独特适应性：浅层编码器先对量化和文本特征分别建模，随后在特征图层面通过可学习门控系数加权求和，使模型能根据市场状态自动调节融合比例^[9]。中期融合的设计面临融合层次选择与门控复杂度控制之间的权衡，且门控系数的生成依赖于对当前市场状态的有效表征，如何设计有效的状态感知机制仍是一个开放性问题。

3 时序与空间特征提取方法

依据信息来源的性质，特征提取方法可分为两类：一类聚焦个股自身的历史时序规律，称为时序特征提取；另一类着眼于股票间的市场关联拓扑，称为空间特征提取。两者各具特色且呈日益融合之势。

3.1 时序特征提取

时序特征提取的核心是从量化序列和文本情感序列中捕捉具有预测价值的波动模式。CNN凭借局部连接与权重共享，通过滑动窗口高效提取局部形态特征。Wang等^[18]提出的MA-MSTNet集成了多尺度滑动窗口注意力，在趋势预测中优于单一尺度模型。注意力机制的引入弥补了标准卷积难以区分时间位置重要性的不足。Sun等^[19]的RCSAN模型通过通道—空间自适应注意力降低了预测误差。多头自注意力从多个子空间并行学习，捕捉不同粒度的依赖结构。

罗云芳与张广莹^[20]融合卷积与空间—通道注意力，增强了股价局部与全局特征的表达。阮俊豪等^[21]引入股名编码改进Transformer，实现了个股与板块特征的并行学习。付炫烨^[22]通过时间加权DTW与临近传播聚类精细提取股票空间关系，构建时空注意力网络实现多空间关系的信息共享。徐钦豪^[23]将Transformer与门控机制、CNN结合，利用长序列建模提升了时序特征提取能力。在文本情感特征提取方面，以FinBERT为代表的金融领域微调模型能准确识别情感极性，为时序模型提供了超越价量数据的增量预测信号^[24]。

3.2 空间特征提取

空间特征提取旨在捕捉其他股票的价格变化如何通过关联网络传导至目标股票。图神经网络(GNN)通过消息传递机制聚合邻居节点信息来更新节点表示，是建模市场拓扑关联的理想工具；图注意力网络(GAT)进一步引入注意力机制，使模型能自动学习不同邻居节点的差异化影响权重^[5]。在应用研究方面，黄外流^[25]引入GNN建模同行业股票间的关联信息，验证了行业关联信号对预测效果的提升作用；刘伟^[26]整合股票行情与新闻文本信息，通过图卷积网络对行业关联关系进行建模，提升了股价预测精度；孔壮壮^[27]采用时空图卷积网络捕捉行业板块的局部时空依赖；杨震^[28]融合多视角特征与动态市场关联信息，拓展了空间特征表达的信息维度。

知识图谱的引入为GNN提供了更具语义解释性的先验知识输入。Wang等^[6]基于股东、概念股和行业等维度构建股票知识图谱，以三元组形式刻画股票间的语义关系并量化相关程度，使图结构具备了明确的经济含义。通过多种语义关系类型的组合构建图拓扑，能够在保证图结构覆盖广度的同时增强关联信号的差异性，为GNN的消息传递提供更丰富的先验信息。空间特征提取面临图结构质量与模型复杂度的权衡，过深的图卷积层可能导致节点表示趋于同质化，残差连接等技术被引入以缓解该问题。

4 异质特征融合：从静态到自适应的演进

时序特征反映个股自身的历史运动规律，具有“内向性”和“连续性”；空间特征反映市场结构对个股的溢出效应，具有“外向性”和“关联性”。两者的相对重要性随市场状态动态变化，如何调节二者的贡献比例是多支路建模的核心挑战。早期融合多采用固定权重或投票机制，隐含“各支路贡献度恒定”的假设，与市场非线性动态特征不符^[15]，往往导致优势支路信息被稀释、弱支路噪声被放大。

近年来，基于注意力机制和门控网络的自适应融合策略将融合权重由固定参数转变为由当前输入动态决定的变量，通过轻量化权重生成网络输出归一化融合权重，实现样本级自适应组合^[9]。若额外引入波动率指数、换手率等市场状态指标，可进一步增强权重生成的状态感知能力。自适应融合面临“强支路优势保持”与“多支路信息互补”之间的权衡难题。两阶段训练策略在一定程度上缓解了信息稀释问题，但如何在训练目标中显式建模这一权衡，仍是值得深入探索的研究方向。

综合上述分析，当前研究在以下两个维度上仍存在改进空间。其一，在数据融合层面，多数策略采用固定拼接或简单门控机制，缺乏对不同模态特征在动态市场环境下重要性差异的自适应权衡能力。其二，在特征协同层面，将局部时序特征提取与全局关联网络推理置于统一框架内进行端到端建模的系统性研究尚不充分。针对上述不足，本文提出一种融合卷积注意力网络、知识图谱图神经网络与自适应加权机制的集成预测框架。该框架以卷积注意力网络捕捉个股时序特征，以知识图谱图神经网络提取市场空间拓扑特征，并通过自适应加权机制实现异构特征的动态协同，从“数据融合”到“特征协同”的递进式设计回应了现有研究的不足。

5 研究挑战与未来趋势

尽管进展显著，股价预测在多源信息融合中仍面临若干挑战。

动态图学习。当前多数研究采用静态图结构，但股票间关联强度是时变的。将静态图扩展为动态演化图，通过时序图注意力机制对边权重时变规律建模，有望提升模型对市场结构

变迁的适应能力。

大语言模型的深度融入。Bao等^[10]指出，大语言模型在股票预测中的应用是当前综述文献中尚未充分覆盖的新兴方向。未来可利用其推理能力从新闻中抽取实体关系以自动构建知识图谱，或通过提示工程生成可解释的预测理由。同时，大语言模型的融入也将为金融知识普及和个性化投资分析工具的构建提供技术基础，降低专业金融分析的使用门槛，服务于更广泛的投资者群体。

可解释性增强。“黑箱”特性是制约预测模型在实际投资决策中应用的瓶颈。将注意力权重和融合系数与具体金融事件进行语义关联，构建因果可解释的预测框架，是推动深度学习从“预测工具”走向“决策辅助系统”的关键路径。

小样本与分布偏移。金融数据具有显著非平稳性，迁移学习、元学习和在线自适应等技术的引入，有望增强模型对分布偏移的鲁棒性，使模型在数据稀缺或市场剧变的情况下保持可靠的预测性能。王沛钰^[29]基于多源数据融合构建了氢能股票的预测与推荐系统，其实用化设计思路为解决小样本和特定领域预测问题提供了有益参考。

6 结语

深度学习推动股价预测从单一数据源走向多模态信息的深层整合。在数据融合层面，策略选择正经历从早期拼接、晚期汇合到中期门控交互的范式跃迁；在特征提取层面，时序卷积注意力网络与图神经网络分别从个股规律和市场拓扑两个维度刻画股价变动的内在逻辑；在决策协同层面，自适应加权融合使异质特征的动态整合成为可能。本文提出的集成框架以卷积注意力网络捕捉个股时序特征，以知识图谱图神经网络提取市场空间拓扑特征，通过自适应加权机制实现异构特征的动态协同，从“数据融合”到“特征协同”的递进式设计回应了现有研究的不足。未来，动态图学习、大语言模型融入和可解释性增强等方向的协同推进，有望弥合“数据丰富”与“信息有效利用”之间的鸿沟，推动股价预测走向更加稳健和透明的智能决策支持。

参考文献：

- [1] 刘颖, 李惠迪, 谭博元. 基于多源数据深度融合的金融时间序列预测 [J]. 统计与决策, 2022, 38(23): 52-56.
- [2] HOSEINZADE E, HARATIZADEH S. CNNpred: CNN-based stock market prediction using a diverse set of variables [J]. Expert Systems with Applications, 2019, 129: 273-285.
- [3] QIU J, WANG B, ZHOU C. Forecasting stock prices with long-short term memory neural

network based on attention mechanism[J]. PloS One, 2020, 15(1): e0227222.

[4] 孙瑞奇. 基于 LSTM 神经网络的美股股指价格趋势预测模型的研究 [D]. 北京: 首都经济贸易大学, 2016.

[5] PATEL M, JARIWALA K, CHATTOPADHYAY C. A systematic review on graph neural network-based methods for stock market forecasting[J]. ACM Computing Surveys, 2025, 57(2): 1-38.

[6] WANG T, GUO J, SHAN Y, et al. A knowledge graph - GCN - community detection integrated model for large-scale stock price prediction[J]. Applied Soft Computing, 2023, 145: 110595.

[7] 耿立校, 刘丽莎, 李恒昱. 多源异构数据融合驱动的股票指数预测研究 [J]. 计算机工程与应用, 2021, 57(20): 142-149.

[8] 蒋雨芯, 魏先华. 融合多源数据的股指预测研究 [J]. 科技促进发展, 2022, 18(3): 322-331.

[9] LIU M, SHIN S. Adaptive multi-modal deep learning for financial market prediction: a multi-scale attention approach[J]. Journal of the Korea Society of Computer and Information, 2025, 30(12): 297-304.

[10] BAO W, CAO Y, YANG Y, et al. Data-driven stock forecasting models based on neural networks: a review[J]. Information Fusion, 2025, 113: 102616.

[11] 李辰宇. 基于多源数据融合的股票价格预测模型及应用研究 [D]. 济南: 山东财经大学, 2023.

[12] JIN Z, YANG Y, LIU Y. Stock closing price prediction based on sentiment analysis and LSTM[J]. Neural Computing and Applications, 2020, 32: 9713-9729.

[13] 李海燕. 基于 PCA-GA-BPNN 模型对股价预测的研究 [D]. 西安: 西安理工大学, 2018.

[14] ZHANG X, ZHANG Y, WANG S, et al. Improving stock market prediction via heterogeneous information fusion[J]. Knowledge-Based Systems, 2018, 143: 236-247.

[15] NTI I K, ADEKOYA A F, WEYORI B A. A novel multi-source information-fusion predictive framework based on deep neural networks for accuracy enhancement in stock market prediction[J]. Journal of Big Data, 2021, 8(1): 17.

[16] AREVALO J, SOLORIO T, MONTES-Y-GÓMEZ M, et al. Gated multimodal networks[J]. Neural Computing and Applications, 2020, 32: 10209-10228.

[17] KIM J, KOH J, KIM Y, et al. Robust deep multi-modal learning based on gated information fusion network[C]//Computer Vision - ACCV 2018: 14th Asian Conference on Computer Vision, Perth, Australia, December 2-6, 2018, Revised Selected Papers, Part IV. Cham: Springer, 2018: 90-106.

[18] WANG X, ZHANG X, LIU J, et al. MA-MSTNet: mixed attention-based multi-scale temporal network for stock trend prediction[J]. The Journal of Supercomputing, 2025, 81: 1207.

[19] SUN W, LIU Z, YUAN C, et al. RCSAN: residual enhanced channel spatial attention network for stock price forecasting[J]. Scientific Reports, 2025, 15(1): 21800.

[20] 罗云芳, 张广莹. 基于卷积与注意力增强的股票价格预测方法 [J]. 云南民族大学学报(自然科学版), 2025, 34(5): 572-581.

[21] 阮俊豪, 王康, 丰天韵, 等. 基于 Transformer 的股票预测方法 [J]. 计算机与数字工程, 2025, 53(5): 1375-1380, 1433.

[22] 付炫烨. 基于时空注意力网络的股票趋势预测模型的研究与实现 [D]. 北京: 北京邮电大学, 2024.

[23] 徐钦豪. 基于 CNN-GRU 的 Transformer 股价预测模型 [D]. 南昌: 江西财经大学, 2025.

[24] MARADIYA D, JINDAL A, JOS C. Integrating price and textual data for next-day stock movement prediction: a study using StockNet dataset[J]. Discover Data, 2025, 3(1): 34.

[25] 黄外流. 融合同行业数据的图神经网络股票价格预测研究 [D]. 成都: 电子科技大学, 2024.

[26] 刘伟. 基于图卷积混合网络模型的股票趋势预测 [D]. 哈尔滨: 哈尔滨理工大学, 2022.

[27] 孔壮壮. 基于时空图卷积神经网络的股票相关性预测研究 [D]. 沈阳: 辽宁大学, 2023.

[28] 杨震. 结合股票多视角数据特征与动态市场相关性信息的股票趋势预测模型 [D]. 济南: 山东大学, 2023.

[29] 王沛钰. 基于多源数据融合的氢能股票预测与推荐系统的实现 [D]. 成都: 四川师范大学, 2025.

作者简介: 杨刚 (1995.08—), 男, 汉族, 重庆人, 在读硕士研究生, 研究方向: 深度学习。