

人工智能在金融领域的预测方法综述

陈夏伊

引用本文

陈夏伊. 人工智能在金融领域的预测方法综述[J]. 计算机科学, 2025, 52(12): 271-284.

CHEN Xiayi. Survey of Data Prediction Methods Using Artificial Intelligence in the Financial Sector[J]. Computer Science, 2025, 52(12): 271-284.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于改进ModernTCN的光伏发电中短期预测](#)

Prediction of Short-and-Medium Term Photovoltaic Power Generation Based on Improved ModernTCN
计算机科学, 2025, 52(11A): 241000164-7. <https://doi.org/10.11896/jsjcx.241000164>

[基于消除语义特征的图像篡改定位模型对抗攻击](#)

Attacking Image Manipulation Localization Model by Eliminating Semantic Features
计算机科学, 2025, 52(11A): 241100104-7. <https://doi.org/10.11896/jsjcx.241100104>

[基于指令流图特征的恶意文件的分类算法研究](#)

Research on Malware Classification Algorithm Based on Instruction Flow Graph
计算机科学, 2025, 52(11A): 240800062-6. <https://doi.org/10.11896/jsjcx.240800062>

[自动化软件缺陷定位技术研究](#)

Advances in Automatic Software Defect Location Techniques
计算机科学, 2025, 52(11A): 250200024-14. <https://doi.org/10.11896/jsjcx.250200024>

[基于语义变化的缺陷生成与缺陷预测模型测试](#)

Semantic Variations Based Defect Generation and Prediction Model Testing
计算机科学, 2025, 52(11A): 241200059-7. <https://doi.org/10.11896/jsjcx.241200059>

人工智能在金融领域的预测方法综述

陈夏伊

悉尼大学商学院 悉尼 2006

摘要 面对金融市场的高度复杂性与数据的高噪声、非线性特性,以机器学习和深度学习为代表的人工智能技术已成为金融数据预测领域的核心驱动力。文中系统性地梳理与总结了近3年人工智能在该领域的最新研究进展与核心方法论。在传统机器学习层面,研究趋势已从单一学习器的应用,发展至以堆叠(Stacking)为代表的模型融合策略,以及结合优化算法进行自动化特征选择与超参数调优的混合范式。在深度学习层面,其应用展现出一条清晰的演进路径,即从作为基石的循环神经网络(RNN)及其与数据分解、注意力机制的融合,到能够捕捉多维度信息的CNN-RNN混合架构;并进一步聚焦于更前沿的图神经网络(GNN)、Transformer架构以及深度强化学习(DRL),系统阐述了它们如何分别在网络关联建模、长序列依赖捕捉以及实现“预测到决策”的范式转变中展现出独特优势。此外,还归纳了关键的特征工程与数据处理技术,并创新性地提出一个旨在反映金融产品内在拓扑结构的“结构化神经网络建模”新范式,以增强模型的可解释性。最后,在对现有成果进行总结的基础上,指出了当前研究在数据质量、模型可解释性与鲁棒性等方面面临的核心挑战,并对深度多模态融合、因果推断、金融大语言模型(LLM)以及可信AI(XAI)等未来关键研究方向进行了展望,以期对相关领域的学术研究与业界实践提供全面且具有前瞻性的参考。

关键词: 金融预测; 时间序列; 投资组合管理; 人工智能; 机器学习; 深度学习

中图分类号 TP39

Survey of Data Prediction Methods Using Artificial Intelligence in the Financial Sector

CHEN Xiayi

Business School, University of Sydney, Sydney 2006, Australia

Abstract Given the high complexity of financial markets and the inherently noisy, non-linear nature of their data, artificial intelligence (AI), particularly machine learning and deep learning, has emerged as a core driving force in financial data prediction. This paper systematically summarizes the latest research progress and core methodologies in this domain over the past three years. In traditional machine learning, the trend has shifted from applying single learners toward sophisticated model fusion strategies, such as Stacking, and hybrid paradigms that integrate optimization algorithms for automated feature selection and hyperparameter tuning. Deep learning applications demonstrate a clear evolutionary trajectory, starting with foundational Recurrent Neural Networks (RNNs) enhanced by data decomposition and attention mechanisms, and progressing to hybrid architectures like CNN-RNN for capturing multi-dimensional features. This paper further details the adoption of cutting-edge models: Graph Neural Networks (GNNs) for modeling entity relationships, Transformers for capturing long-range dependencies, and Deep Reinforcement Learning (DRL) for shifting the paradigm from prediction to autonomous decision-making. Furthermore, the review outlines key feature engineering techniques and introduces an innovative “structured neural network modeling” paradigm, which proposes aligning the model’s architecture with the intrinsic topology of financial products to enhance interpretability. Finally, this paper synthesizes the core challenges facing the field—including data quality, model robustness, and interpretability—and provides a forward-looking perspective on future research directions such as deep multi-modal fusion, causal inference, financial Large Language Models (LLMs), and explainable AI (XAI).

Keywords Financial forecasting, Time series, Portfolio management, Artificial intelligence, Machine learning, Deep learning

1 引言

在高度全球化和数字化的今天,金融市场已演变为一个瞬息万变、极其复杂的生态系统。对各类金融数据进行精准的预测,不仅是投资者制定有效投资策略、获取超额回报的

基石,更是金融机构进行风险控制、维护市场稳定的核心环节。然而,金融数据以其高噪声、非线性、非平稳以及多源异构等内在特性,对传统的预测方法构成了严峻的挑战。以线性假设为基础的经典计量经济学模型,在捕捉金融市场复杂的动态规律时往往显得力不从心。

随着大数据时代的到来,人工智能(Artificial Intelligence, AI)技术,特别是机器学习与深度学习,为金融预测领域带来了革命性的变革。与传统方法不同,人工智能技术以其强大的数据驱动和模式识别能力,能够从海量、高维的数据中自主学习隐藏的非线性关系和抽象特征,无需过多的先验假设。这为处理金融市场的不确定性和复杂性提供了全新的、更有效的解决方案,也因此成为近年来学术界与业界共同关注的焦点。

近年来,人工智能在金融数据预测领域的应用呈现出百花齐放、纵深发展的态势。在传统机器学习层面,研究者们不仅验证了随机森林^[1-4]等经典集成算法在信用风险和财务预警等任务中的卓越性能,更在模型集成与优化方面进行了大量探索。以堆叠(Stacking)^[5]为代表的集成策略通过多层次模型融合,显著提升了预测的准确性与稳健性。同时,将元启发式优化算法与传统机器学习模型结合^[6],用于自动化的特征选择和超参数调优,也已成为提升模型性能的主流范式。此外,研究的焦点也从模型本身扩展到更广泛的方法论探讨,如融合文本信息的特征工程^[7],构建网络关联特征以捕捉系统性风险,以及应用可解释性 AI(XAI)工具^[5]来增强模型的透明度和可信赖度。在深度学习层面,研究呈现出从基础架构应用到复杂模型创新的清晰演进路径。循环神经网络(RNN)^[8]及其变体,特别是 LSTM^[9-10]和 GRU^[11]作为处理时间序列数据的基石,被广泛应用于价格、波动率和宏观指数的预测中。在此基础上,结合数据分解技术,如 EMD^[12-13]、小波变换^[7]和注意力机制^[14]的混合 RNN 模型,进一步提升了对高噪声、非平稳数据的建模能力。为了捕捉金融市场的多维度信息,融合 CNN, RNN 和自编码器的多模态混合架构^[15]也成为研究热点。

更前沿的研究则聚焦于更先进的深度学习架构。图神经网络(GNN)^[16]因能够直接对金融实体间的关联网络进行建模,在系统性风险预警、市场波动性传导等涉网问题的研究中展现出独特优势。Transformer 模型^[17]则凭借其强大的长序列依赖捕捉能力,在金融长序列预测和资产配置等领域迅速崛起;其高效变体,如 Fx-spot^[18]和 Linformer^[19]与数据分解技术的结合,正成为新的研究前沿。最终,深度强化学习(DRL)^[20]将研究范式从“预测”推向了“决策”,通过构建能够与市场环境交互、以最大化长期回报为目标的智能体,在算法交易和投资组合管理领域开辟了全新的应用场景。

本文旨在系统性地回顾和梳理近三年来人工智能在金融数据预测领域的最新研究进展,所选文献分布如图 1 和图 2 所示。第 2 章对金融数据预测进行概述,详细阐述了金融数据的特征与挑战、当前研究的主要任务以及科学的评价体系;第 3 章聚焦于传统机器学习方法,从单一学习器的应用,到基于集成学习的混合与优化模型,再到关键的辅助技术与方法论,对该领域的研究进行了全面梳理;第 4 章深入探讨深度学习的应用,分别从循环神经网络、多模态与混合架构、图神经网络、Transformer 架构以及深度强化学习 5 个主流方向,系统回顾了其在金融预测中的创新与实践;第 5 章单独探讨金融预测中具有共性的关键技术、方法论,并对重要的领域综述

进行评述;第 6 章给出了金融预测的结构化神经网络建模范式;第 7 章对当前研究面临的挑战进行归纳,并对未来的研究方向如多模态融合、因果推断、金融大语言模型等进行展望,为未来的研究和实践提供参考。




图 1 本综述所选文献的人工智能方法分布

Fig. 1 Distribution of artificial intelligence methods in the selected literature for this review




图 2 本综述所选文献的金融预测任务分布

Fig. 2 Distribution of financial forecasting tasks in the selected literature for this review

2 金融数据预测:挑战、任务与评价体系

金融数据预测作为连接金融理论与市场实践的关键桥梁,旨在利用历史和当前信息,对未来的市场走势、风险状况或金融实体的表现进行科学的推断。本章将首先剖析金融数据的独特特征及其带来的处理策略,随后归纳当前人工智能在金融预测中的主要任务,最后对衡量模型性能的常用评价指标进行总结,为后续章节的方法论探讨奠定基础。

2.1 金融预测的数据困境与处理策略

金融数据预测之所以被公认为极具挑战性的任务,其根源在于金融数据本身具有复杂性。这些特性不仅对预测模型的构建提出了严苛要求,也催生了多样化的数据处理策略。

金融数据最显著的特征是高噪声、非线性与非平稳性。市场中充满了大量的随机波动和无规律的“噪声”,使得从数据中提取有效的、可预测的“信号”变得异常困难。同时,驱动市场变化的因素之间往往存在复杂的非线性关系,金融时间序列的均值、方差等统计特性也会随时间发生改变,呈现出典型的非平稳特征。为此,许多研究采用数据分解技术作为预处理步骤,先将复杂的原始序列分解为多个相对平稳的子序列,再进行建模,如协整分析^[21]和小波变换或希尔伯特-黄变换^[22]等。

影响金融市场的因素数量庞大,从宏观经济指标、行业数

据、公司财报到各类技术指标,构成了一个高维度的特征空间,其中也常常伴随着特征冗余。如何从众多特征中筛选出有效的预测因子,避免“维度灾难”和模型过拟合,是特征工程的关键挑战。因此,特征选择成为多数研究的必要环节,方法涵盖了基于信息增益的过滤法、基于 LASSO^[23]的嵌入法,以及基于神经网络的演化多尺度图神经网络^[24]。

此外,在许多金融风险预测任务中,风险事件本身是小概率事件,这导致训练数据中正负样本极度不平衡。标准的分类模型在这种情况下往往会倾向于预测多数类,从而失去对关键风险事件的预警能力。为此,研究中普遍采用特殊方法来应对,主要包括数据层面的采样技术,如 SMOTE 过采样、随机欠采样,以及算法层面的成本敏感学习。

金融预测所依赖的数据类型也日益多样化,早已超越传统的价格和交易量数据。当前研究广泛应用的数据类型包括:结构化的历史交易数据、公司财务报表数据、宏观经济指标,以及非结构的新闻文本、社交媒体情感数据等^[25]。有效地处理和融合这些多源异构数据,已成为提升预测模型性能的前沿研究方向。例如,将新闻文本量化后的情感指数与历史价格数据结合,或将描述实体间关系的网络图数据引入模型,都已被证明能够为预测提供更丰富的信息维度。

2.2 人工智能在金融预测的应用

基于上述数据特征和挑战,近年来人工智能在金融预测领域的应用主要集中在以下几个核心任务。

首先是最经典的任务,涵盖了对股票、股指、外汇、商品期

货和加密货币等各类资产未来价格或变动方向的预测^[8]。其目标是为投资决策提供直接依据,例如采用 LSTM 模型预测加密货币价格,或利用混合模型预测股票指数的涨跌趋势。

其次是微观层面的任务:信用风险、财务困境与欺诈检测。这类任务旨在评估公司或个人的违约概率或陷入财务困境的可能性,是银行信贷、供应链金融和投资决策中的关键环节。研究者们利用机器学习和深度学习模型,结合财务指标、文本信息和网络关联特征,构建了高效的财务预警和信用评级系统。此外,识别财务报表舞弊等欺诈行为^[26]也是其重要应用方向。

然后是宏观层面的任务:波动率、协方差与系统性风险预测。波动率是衡量市场风险和不确定性的核心指标,对于衍生品定价、风险管理和资产配置至关重要。研究者们利用 GNN 和 Transformer 等模型,结合高频数据或宏观不确定性指标,对市场未来的波动性进行预测。此外,对高维资产协方差矩阵的精准预测也是投资组合优化^[27]的关键一环。

最后这类任务不仅要求模型进行预测,还需要基于预测做出最优的交易或资产配置决策。深度强化学习在该领域展现出巨大潜力,能够构建直接与市场交互、以最大化长期回报为目标的端到端决策智能体。

综上所述,人工智能在金融预测领域的应用可以被概括为一个系统性的框架(见图 3)。该框架始于多源异构数据的输入,经过一系列针对金融数据特有挑战的预处理和特征工程后,将处理后的高质量数据送入核心的人工智能预测模型,最终输出针对不同金融任务的预测结果。

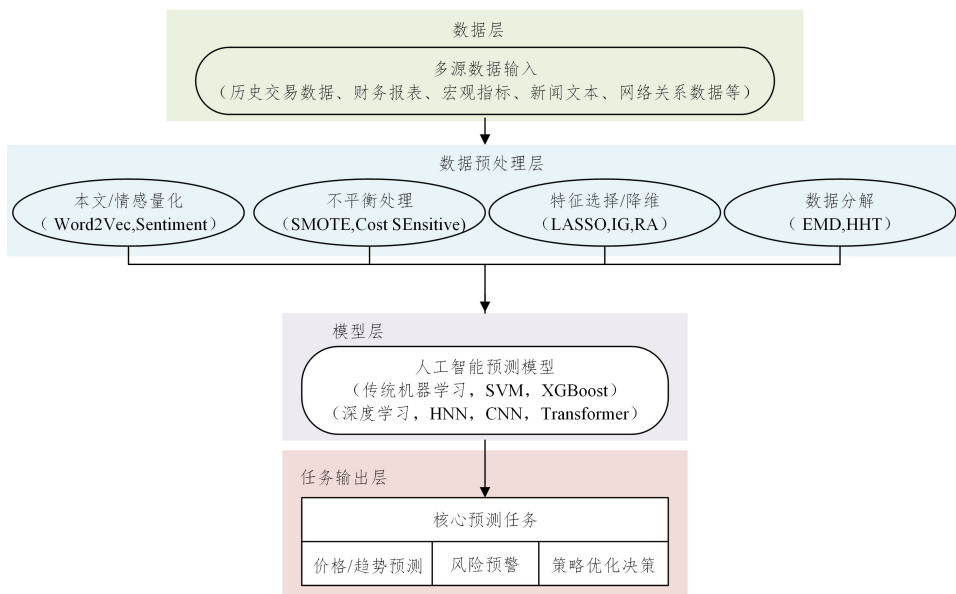


图 3 基于人工智能的金融预测通用框架

Fig. 3 General framework for financial forecasting based on artificial intelligence

2.3 金融预测模型的评价体系

为了科学地衡量和比较不同预测模型的性能,研究中采用了多种评价指标,这些指标大致可分为两类。

分类任务中,如趋势预测、风险预警中常用的指标包括:准确率、精确率、召回率和综合两者的 F1 分数。考虑到金融风险事件的稀缺性,能够更好地衡量不平衡数据分类性能的

ROC 曲线下面积(Area Under the Curve, AUC)和 G-mean^[28]也备受青睐。

回归任务中,如价格预测中常用的指标包括均方误差(Mean Squared Error, MSE)、均方根误差(Root Mean Squared Error, RMSE)和平均绝对误差(Mean Absolute Error, MAE)等,它们用于度量预测值与真实值之间的差距。

在算法交易和投资组合管理等应用场景中,仅有统计上的高精度是不够的,模型必须能够转化为可盈利的策略。因此,研究者们普遍采用基于模拟交易回测的金融学指标来评估模型的经济价值。最常用的指标包括累积回报率、年化回报率、夏普比率,其用来衡量经风险调整后的回报以及最大回撤,以衡量策略在最坏情况下的亏损程度。这些指标能够更直观地反映模型在真实金融市场环境下的实用性和稳健性。

为了科学地衡量和比较不同预测模型的性能,研究中普遍采用一个包含统计学和金融学两个维度的综合评价体系(见图4)。

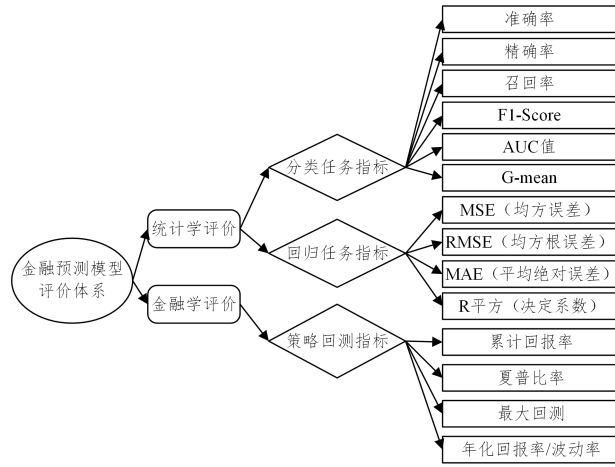


图4 金融预测模型的双维度评价体系

Fig. 4 Dual dimensional evaluation system for financial forecasting models

统计学评价主要从模型的分​​类或回归精度出发,而金融学评价则更侧重于模型在模拟交易中的经济价值和风险控制能力,两者共同构成了对模型有效性的全面评估。下面对这些指标进行更精确的定义。

针对二分类任务,假设 TP (True Positive), TN (True Negative), FP (False Positive) 和 FN (False Negative) 分别代表真正例、真负例、假正例和假负例的数量。

准确率为:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

精确率(Precision)为:

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

召回率(Recall)为:

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1 分数 (F1-Score) 为:

$$F1 = 2 \cdot \frac{Precision \cdot Recall}{Precision + Recall} \quad (4)$$

针对回归任务,假设 y_i 是第 i 个样本的真实值, \hat{y}_i 是预测值,样本总数为 n 。

均方误差 (MSE) 为:

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (5)$$

平均绝对误差 (MAE) 为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (6)$$

3 基于传统机器学习的金融数据预测方法

3.1 基于单一学习器的预测模型

尽管集成学习是当前的主流趋势,但将单一的、经典的机器学习算法应用于特定金融场景,以验证其有效性和适用性的研究,仍具有重要价值。这类研究的重点在于深入挖掘特定算法的潜力,并常常通过与其他基准模型进行对比来凸显其性能。

在基于树的模型方面,其因强大的非线性关系捕捉能力和相对较好的可解释性而备受青睐。例如,Sebastião 等^[29] 在一项关于加密货币可预测性的研究中,系统地比较了包括随机森林(Random Forest, RF)在内的多种经典机器学习模型。他们在一个覆盖了市场牛熊转换的完整周期内,检验了模型在动态变化市场条件下的稳健性,并构建了基于模型集成的交易策略,发现在熊市等不利条件下,机器学习策略依然能够获得正收益。Chi 等^[30] 展开的研究则采用极限梯度提升(XGBoost),结合粒子群优化算法(PSO)进行超参数调优,构建了高效的上市公司违约风险预测模型。此外,Yin 等^[31] 则聚焦于如何系统性地优化随机森林模型,以提升其中长期股票趋势预测的能力。他们还提出了一个名为 D-RF-RS 的完整优化流程,该流程创新地结合了指​​数平滑法进行数据预处理,结合决策树进行特征筛选,并结合随机搜索进行超参数调优。实验证明,经过该流程优化的随机森林模型的预测准确率显著高于基准模型。

在其他经典模型的应用上,研究者们同样取得了丰富的成果。Cheng 等^[32] 对比了多种模型在比特币价格预测任务上的表现,其中包括经典的季节性差分自回归移动平均模型(SARIMA)和 Facebook 开源的 Prophet 模型。他们的研究覆盖了多个极端市场环境,为不同技术流派的模型在高度波动市场中的适用性提供了宝贵的实证依据。而在企业信用评级这一重要领域,Dag 等^[33] 将树增强朴素贝叶斯(TAN)模型应用于价格趋势分类,通过允许特征间存在树状依赖结构,有效提升了传统贝叶斯模型的预测能力。与此同时,Henrique 等^[23] 的研究对多种经典模型在真实预测场景下的表现进行了系统性评估,强调了在一个务实的前向验证框架下,严谨的特征工程和验证流程比追求“开箱即用”的模型更为重要。而在信用评分领域,Abdoli 等^[28] 则提出了一种基于监督自编码器(SAE)的新颖模型,将深度学习的特征表示能力与 Bagging 集成等处理不平衡数据的方法相结合,为信用评分提供了一个强大的新范式。

3.2 基于集成学习的混合与优化预测模型

为了突破单一学习器的内在局限性并进一步提升预测模型的准确性与稳健性,将多种算法进行有效结合的集成学习(Ensemble Learning)策略^[34] 已成为金融预测领域的主流研究方向。近年来,研究者们不再满足于简单的投票或平均法,而是探索了更为复杂的模型融合、堆叠以及结合优化算法的混合框架,旨在解决金融领域中普遍存在的数据不平衡、高维度和非线性等挑战。

Stacking 作为一种先进的集成策略,通过一个多层次的结构来组合多个不同的预测模型,在金融风险预警领域得到了广泛应用。其核心思想可通过图 5 所示的框架进行理解。该框架通过一个多层次的结构来组合多个不同的预测模型。Park 等^[35]针对深度学习模型在高维输入下面临的过拟合问题,提出了一个名为 LSTM-Forest 的新颖框架。该框架借鉴了随机森林的思想,但创新性地用 LSTM 模型替换了其中的决策树。通过对训练数据和输入特征进行随机抽样来训练多个低相关性的 LSTM 模型,并将它们的预测结果进行集成,该框架有效结合了 LSTM 强大的时序模式学习能力和随机森林防止过拟合的鲁棒性。此外,他们还将每个基础 LSTM 模型进一步设计为能够同时预测收益率(回归)和涨跌方向(分类)的多任务学习器,从而在学习过程中捕捉到更泛化的特征表示,显著提升了模型的综合预测性能和交易策略的盈利能力。针对公司财务困境问题,Wang 等^[3]将 Stacking 方法与成本敏感学习进行了深度融合,提出了名为 CSSStacking 的新框架。该框架在 Stacking 的每一层都嵌入了成本敏感策略,为错误分类少数类(财务困境公司)赋予更高的惩罚成本,从而在处理不平衡金融数据,尤其在识别财务困境公司的能力方面表现出强大的优势。在个人信用风险评估领域,Emmanuel 等^[36]也构建了一个基于 Stacking 的预测引擎系统,该系统将多种经典机器学习模型通过堆叠集成的方式进行组合,并结合了信息增益进行特征选择,利用 SMOTE 算法处理数据不平衡问题,构建了一个完整的、自动化的信用风险预测流程。

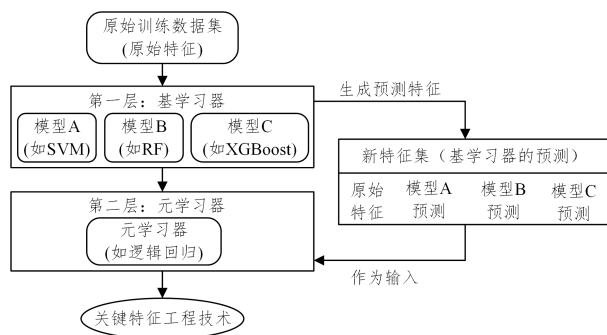


图 5 堆叠集成学习框架示意图

Fig. 5 Schematic diagram of Stacking learning framework

除了并行的集成策略,许多研究开始探索两阶段或序列化的集成框架,以实现一种层层递进、逐步优化的预测流程。在小微企业信用评分领域,Zhou 等^[37]设计了一个巧妙的两阶段专家系统:第一阶段利用随机森林进行重要性排序和预筛选,第二阶段将筛选后的重要特征输入到逐步逻辑回归模型中,构建最终的评分卡,兼具了准确性与可解释性。在投资组合优化领域,Chou 等^[4]同样采用了一种序列化的集成框架,在利用元启发式算法进行特征选择后,按顺序应用随机森林、XGBoost 和 LightGBM 这 3 种模型,旨在逐步提炼预测信号。此外,将数据分解与模型集成相结合也是一种有效的两阶段策略。例如,Çelik 等^[5]提出的 EMD-ANNRC-RF 模型,先采用经验模态分解和神经网络对股价序列进行分解和初步预测,再将这些结果作为新特征输入到随机森林中进行

最终预测,并通过可解释性 AI 工具 LIME 对结果进行可靠性评估,极大地增强了模型的实用性。

另一大主流研究方向是将经典的机器学习预测器与先进的优化算法相结合,用于特征选择和超参数调优。在股票市场趋势预测中,Kuo 等^[6]提出了一种名为 JS-PSO 的新型混合元启发式算法,用于同时优化支持向量机的特征选择和超参数。在国际金融压力预警领域,Del 等^[38]首次系统地检验了气候风险这一非传统因子对多国金融系统压力的预测能力。面对包含大量预测变量(本国压力滞后项、多国溢出效应以及气候风险指标)的复杂模型,他们采用随机森林进行预测。该研究不仅证实了气候风险的预测价值,还通过分位数随机森林进一步发现这种预测能力具有状态依赖性,即其预测能力在市场平稳时更强,在动荡时减弱。这项研究成功地将机器学习应用于前沿的宏观金融问题,为气候金融领域的风险管理提供了新的视角和工具。同样,在网络小额贷款的个人信用风险评估中,Lv 等^[39]采用了一种流程化的组合模型,依次使用 SMOTEENN 算法处理数据不平衡、极端随机树(ExtraTrees)以进行特征选择,最后将优化后的数据输入到深度神经网络中进行风险评估,为应对该领域的特定挑战提供了系统性的方案。

3.3 核心算法的改进与方法论探讨

除了优化预测流程,对机器学习算法的核心机制本身进行改进,或提出新的方法论框架,同样是重要的研究方向。近年来,研究者们在这一领域进行了诸多有益的探索,其核心技术方向可被归纳为如图 6 所示的几个方面,包括但不限于融合多源异构数据、构建网络关联特征等。

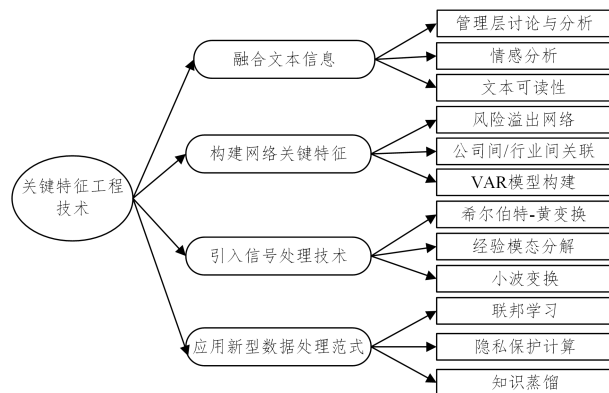


图 6 金融预测中的关键特征工程技术

Fig. 6 Key engineering techniques in financial forecasting

Borup 等^[40]针对随机森林在节点分裂时特征选择的均匀随机性可能导致效率低下的问题,提出了目标性随机森林(Targeted Random Forest, TRF)。TRF 的核心改进在于,它根据每个特征与目标变量的关联度来“目标性”地赋予其不同的抽样概率,关联度越高的特征被选中的概率越大,从而在稀疏或高维数据环境中提升模型的预测精度和稳定性。为了更好地建模金融数据固有的不确定性并提升模型的可解释性,Wang 等^[41]提出了一种可解释的直觉模糊推理模型(IIFD),该方法论的创新之处在于将直觉模糊集理论引入预测模型的构建中。与传统的模糊系统仅考虑“隶属度”不同,直觉模糊集额外引入了“犹豫度”维度,能够更全

面地量化数据中的不确定性。

在高频交易数据分析领域, Mantilla 等^[42]针对限价订单簿(LOB)数据提出了一种新颖的“时间不敏感”特征工程方法,将 LOB 的瞬时状态映射为一个二维矩阵,并通过卷积操作来提取空间特征,为高频数据分析提供了一种新的视角和处理框架。此外,为应对重大外部冲击带来的影响, Ding 等^[43]提出了 XGB-GP 混合框架,用于分析重大外部冲击前后企业财务困境预测因子的时变性。这种结合机器学习进行时变特征重要性分析的方法论,不仅提升了预测模型的适应性,更重要的是为理解宏观冲击如何改变微观风险驱动因素提供了深刻的经济学洞见。

4 基于深度学习的金融数据预测方法

近年来,以深度学习(Deep Learning)为代表的人工智能技术为金融预测带来了革命性的变革。与前述的传统机器学习方法相比,深度学习模型通过其深层次的神经网络结构,能够从海量数据中自动学习和提取高阶抽象特征,从而更有效地捕捉金融市场中普遍存在的高度非线性、非平稳的动态规律。本章将系统性地回顾近三年来深度学习在金融预测领域的应用,重点探讨循环神经网络、混合架构模型、图神经网络、Transformer 架构以及深度强化学习等前沿方法的应用与创新。

4.1 基于循环神经网络的金融时序预测模型

金融数据本质上是时间序列数据,其当前状态受到历史信息序列的深刻影响。循环神经网络及其变体因具有独特的循环结构,能够有效处理序列数据中的依赖关系,已成为金融时序预测领域应用最广泛、最基础的深度学习架构。基于 RNN 的方法框架如图 7 所示。

其中,LSTM 和 GRU 通过引入精巧的门控机制,有效解决了传统 RNN 中的梯度消失和梯度爆炸问题,能够学习到更长期的依赖关系,因此备受研究者青睐。以 LSTM 为例,其核心在于 3 个关键的“门”,即输入门(Input Gate)、遗忘门(Forget Gate)和输出门(Output Gate),它们的计算式如下:

$$\begin{cases} f_t = \sigma(\mathbf{W}_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(\mathbf{W}_i \cdot [h_{t-1}, x_t] + b_i) \\ o_t = \sigma(\mathbf{W}_o \cdot [h_{t-1}, x_t] + b_o) \\ \tilde{C}_t = \tanh(\mathbf{W}_C \cdot [h_{t-1}, x_t] + b_C) \\ C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \\ h_t = o_t \odot \tanh(C_t) \end{cases} \quad (7)$$

其中, f_t, i_t, o_t 分别代表遗忘门、输入门和输出门的激活值; C_t 是细胞状态(cell state); h_t 是隐藏状态(hidden state); x_t 是当前时刻的输入; \mathbf{W} 和 b 是相应权重矩阵和偏置项; σ 是 Sigmoid 激活函数; \odot 代表元素对应相乘。

正是通过这套复杂的门控机制,LSTM 得以有选择地记忆和遗忘信息,从而捕捉长序列中的依赖关系。

近期的研究致力于将 RNN 与其他技术进行融合,以提升模型性能。Saadaoui 等^[44]提出了一个 ARFIMA-LSTM 混合模型。该模型的核心思想是先利用分数阶自回归整合移动

平均模型(ARFIMA)来捕捉和预测金融时间序列中的长记忆性(Long-range Dependence)和线性部分,然后让 LSTM 专门对 ARFIMA 产生的残差序列进行建模,以捕捉原始模型未能解释的非线性模式。该研究的另一项核心创新在于,它打破了传统模型通常假设数据服从高斯分布的局限。该模型能够通过决策循环,从多种非高斯分布中自适应地选择最适合数据的那一种,极大地增强了模型对真实金融数据分布的拟合能力。而在高波动性的加密货币市场,Izadi 等^[45]对 LSTM、GRU 和双向 LSTM 进行了系统性比较,发现在分钟级的高频数据预测中,结构更简洁的 GRU 模型取得了最佳的综合表现。

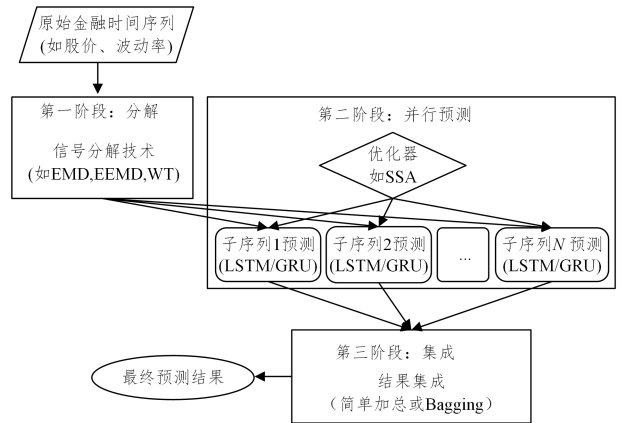


图 7 基于“分解-集成”范式的 RNN 金融预测模型框架
Fig. 7 RNN financial prediction model framework based on the “decomposition integration” paradigm

为了进一步提升模型性能,研究者们从多个维度对 RNN 模型进行了改进。在模型架构层面,Mukherjee 等^[10]采用了堆叠式 LSTM 并结合 Dropout 技术来预测印度股票市场,通过增加网络深度来学习更抽象的特征,同时防止过拟合。在应用层面,Yıldırım 等^[46]模仿人类交易员结合技术面和基本面进行分析的思路,提出了一个新颖的混合模型。该框架构建了两个独立的、专门化的 LSTM 模型:一个仅使用宏观经济指标作为输入(模拟基本面分析),另一个仅使用技术指标作为输入(模拟技术面分析)。最终的交易决策并非由一个大而全的模型做出,而是通过一个基于规则的决策层来融合两个专家模型的输出,在深度学习框架下实现了“基本面”与“技术面”的结合。

在模型优化层面,为解决传统网格搜索耗时巨大的问题,Zhao 等^[47]提出了一种基于加权误差函数的网格搜索方法,该方法通过赋予近期验证数据更高的权重,显著提升了 LSTM 等模型超参数的优化效率。

此外,一个重要的研究方向是将 RNN 与其他技术进行融合。在数据处理层面,“分解-集成”策略被广泛应用。该策略首先利用信号处理技术将复杂的原始序列分解为多个相对简单的子序列,然后对每个子序列分别使用 RNN 模型进行预测,最后将所有子序列的预测结果进行聚合。Song 等^[13]的多项研究表明,无论是采用多重分解技术为 GRU/LSTM 提供更丰富的输入特征,还是结合非参数回归来分离和预测

高频数据中的价格跳跃成分,这种范式都能显著提升模型的预测精度。在训练范式层面,为解决实时金融预测中常见的模型自适应和误差累积问题,Gajamannage 等^[48]提出了一个双 LSTM 并行训练的全新框架。该框架在每次预测迭代时,使用第一个 LSTM(LSTM₁)来探索并找出当前数据窗口下的最优训练轮数,而第二个 LSTM(LSTM₂)则直接使用这个最优轮数进行训练并做出最终预测。这种“一个探索、一个执行”的分工机制,使得模型在每个时间点都能自适应地找到最佳训练强度,极大地提升了实时预测的稳定性和准确性。

4.2 基于混合架构与多模态数据的预测模型

随着研究的深入,研究者们开始构建更为复杂的混合模型,通过融合不同类型的深度学习架构或不同来源的数据,捕捉金融市场中更多维度的信息。基于混合架构与多模态数据的方法框架如图 8 所示。

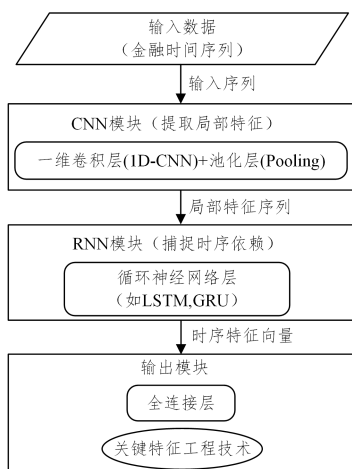


图 8 典型的 CNN-RNN 混合金融预测模型架构

Fig. 8 Typical CNN-RNN hybrid financial prediction model architecture

CNN-RNN 混合模型是其中一种经典且高效的策略。CNN 擅长提取局部模式和空间特征,而 RNN 则精于处理序列依赖关系。将两者结合,能够使模型既捕捉到金融时间序列中的“形态”特征,又学习到其“时序”规律,是金融预测中的一种经典且高效的混合策略。当应用于金融时间序列这类一维数据时,其核心的一维卷积操作可以表示为:

$$(y * w)(n) = \sum_{m=-\infty}^{\infty} x(m)w(n-m) \quad (8)$$

其中, y 是卷积操作的结果, x 是输入信号, w 是卷积核, n 表示当前计算的位置, m 作为求和变量。通过滑动不同的卷积核,CNN 能够自动地从原始序列中提取出如“上升形态”“盘整形态”等多种局部模式特征。在此基础上,Dong 等提出了一个基于 CEEMDAN-SE 和 ARIMA-CNN-LSTM^[49] 的黄金期货价格预测模型。该模型首先采用自适应噪声完备集合经验模态分解,将原始复杂序列分解为多个本征模态函数。其核心创新在于,它进一步利用样本熵(Sample Entropy,SE)来度量每个 IMF 的复杂度,并据此将它们重构为一个低复杂度的平稳高频分量和一个高复杂度的低频分量。随后,模型针对性地使用计算成本较低的 ARIMA 模型来预测高频部分,使用 CNN-LSTM 混合模型来预测包含更多趋势信息的低频

部分。这种“分解-重构-分别预测-集成”的精细化处理流程,在提升预测精度的同时,有效降低了计算开销。

融合自编码器(Autoencoder,AE)与其他网络是另一主流方向。AE 及其变体因具有强大的无监督特征学习和数据降维/降噪能力,常常被用作混合模型中的关键预处理模块。Zhao 等^[50]提出的 SA-DLSTM 集成框架便是典型代表,它利用情感增强 CNN 从网络文本评论中提取情感指数,同时使用去噪自编码器(DAE)对高噪声的金融交易数据进行特征提取和降噪,最后将两种特征共同输入 LSTM 中进行最终的股价趋势预测,有效融合了文本情感和量化数据两种信息。针对公司财务困境预测中常见的多源数据不完整问题,Huang 等^[51]则提出了一个基于变分自编码器(VAE)的 MV-VDE 模型。该模型为不同的数据视角设计了独立的编码器-解码器,并通过乘积专家模型来融合来自不同数据视角的潜在表示,在数据不完整的情况下依然能够稳健地预测财务困境。

4.3 基于图神经网络的金融预测模型

金融市场本质上是一个由众多实体,如公司、行业等及其复杂关系构成的网络。风险和正是这个网络中进行传导和溢出。图神经网络的出现为直接对这种网络结构数据进行建模提供了强大的工具,它能够同时学习每个实体的自身特征和实体间的关联信息,在系统性风险、市场波动性等涉及网络效应的预测任务中展现出独特优势。

传统 GNN 应用的一个核心挑战是,它们通常依赖一个预先定义的、静态的图结构,难以捕捉金融市场中瞬息万变的关系。针对此痛点,Zhou 等^[24]提出了一个名为演化多尺度图神经网络(Evolving Multiscale Graph Neural Network,EMGNN)的全新框架,并将其应用于加密货币波动率的预测任务。该模型的核心创新在于其“演化”和“多尺度”两大特性。该研究不仅显著提升了波动率的预测精度,还通过可视化学习到的图结构,为理解加密货币与传统金融市场的复杂互动提供了可解释的视角。

将 GNN 与多模态数据(尤其是社交媒体信息)结合,是另一个前沿方向。Zhang 等^[52]提出了一种基于 GNN 的社交媒体情绪分析框架。传统情绪分析平等对待所有信息源,而该研究的核心创新在于,利用 GCN 来学习和量化每个 Twitter 账户的“影响力指数”。GNN 通过分析社交网络的图结构,为高影响力账户发布的情绪信息赋予更大的权重。这个经过 GNN 加权的情绪指数随后被输入到 LSTM 等时序模型中进行预测,显著提升了模型的性能。

同时,GNN 与其他模型的混合应用也成为重要趋势。Lazcano 等^[53]提出的 RNN-GCN 混合模型,并行使用 GCN 学习股票间的相关性,同时利用 GRU 捕捉每支股票自身的价格时间序列规律,实现了对时空依赖的共同建模。在此基础上,Huang 等^[11]进一步提出了 AGGSNN 模型,其核心创新在于引入了一个注意力机制来动态地学习和融合 GCN 提取的空间信息和 GRU 提取的时间信息,使得模型能够更灵活、更智能地整合时空特征,从而做出更优的交易决策。基于时空图神经网络的方法框架如图 9 所示。

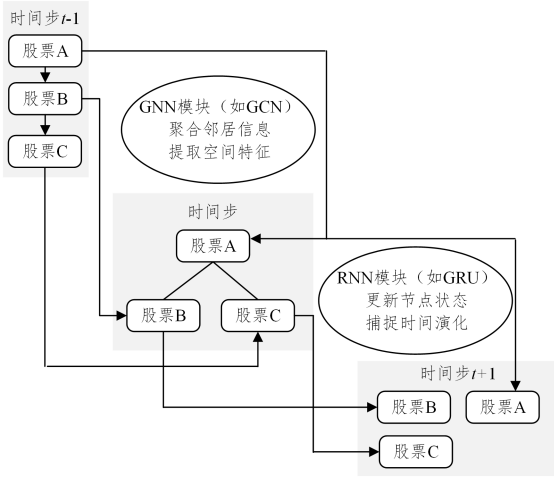


图9 时空图神经网络模型概念示意图

Fig. 9 Conceptual diagram of spatio-temporal GNN model

此外, GNN 的方法论改进与综述也至关重要。传统 GNN 应用的一个核心挑战是它们通常依赖一个静态的图结构。针对此痛点, Huang 等^[54]提出了名为图重学习网络(Graph Relearn Network, GRN)的全新框架。GRN 的核心创新在于其“重学习”机制,它不再依赖固定的图结构,而是在训练过程中迭代地优化和调整图的邻接关系,旨在找到一个与下游预测任务最匹配的图结构。

另一大研究方向是如何构建信息含量更丰富的图结构,并将其他理论融入 GNN 框架。Lee 等^[55]在其股票波动率预测研究中,提出了一个名为 H-ETE-GNN 的新颖模型。该模型的第一个创新点在于,它没有使用传统的皮尔逊相关性来构建图,而是采用了源于信息论的有效传递熵(Effective Transfer Entropy, ETE)。ETE 能更好地捕捉金融时间序列中非线性、非对称的因果关系,从而构建出更真实的跨市场信息流动网络。其第二个核心创新在于,利用分形市场假说中的 Hurst 指数来动态检测市场状态的转变。模型只有在检测到市场从一个状态(如趋势市)切换到另一个状态(如震荡市)时,才会触发对图结构和模型参数的再训练。这种事件驱动的自适应机制极大地提高了模型的效率和对市场结构性变化的响应能力。

4.4 基于 Transformer 架构的金融预测模型

尽管基于 RNN 的架构应用广泛,但其固有的循环结构限制了模型的并行计算能力,并在捕捉超长期依赖关系时面临挑战。Transformer 模型通过其核心的自注意力机制(Self-Attention Mechanism),能够直接计算序列中任意两个位置之间的依赖关系,而不受距离的限制,这使其在捕捉长期依赖方面具有天然优势,同时也具备高度的可并行化能力。其核心计算单元——缩放点积注意力的计算式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (9)$$

其中, \mathbf{Q} (Query), \mathbf{K} (Key) 和 \mathbf{V} (Value) 是由输入序列嵌入向量经过线性变换后得到的 3 个矩阵。模型通过计算 Query 和所有 Key 的点积来得到注意力分数,经过缩放,除以 $\sqrt{d_k}$ 以防止梯度过小,再经 softmax 归一化后,将得到的权重应用于 Value 向量,从而得到加权后的序列表示。这种机制使得序

列中的每个元素都能“关注”到所有其他元素,并根据相关性提取信息。

近年来,Transformer 及其变体正迅速被应用于金融时间序列预测领域。早期的研究主要致力于验证标准 Transformer 架构的有效性。Wang 等^[14]将标准的 Transformer 模型直接应用于股票市场指数的预测,实验表明其预测性能优于传统的 LSTM 等 RNN 模型。Ma 等^[17]则将 Transformer 的应用从单纯的价格预测拓展到了更复杂的资产配置领域,他们提出了 TAA(Transformer for Asset Allocation)模型,并借助可解释性工具 SHAP 量化了不同技术指标在决策中的重要性,在一定程度上打开了 Transformer 的“黑箱”。

与此同时,对 Transformer 架构本身进行方法论层面的改进也是一个重要的研究方向。Li 等^[19]提出了一个名为 DifFormer 的通用时间序列分析 Transformer 架构。该模型的核心创新在于其神经差分注意力(Neural Differencing Attention)机制,这是一种新颖的“有符号”注意力,不仅能像传统注意力那样进行加权求和,还能进行“减法”操作。这种机制使得模型能够像统计学中的差分一样,在网络内部自动地去除趋势、凸显变化、保留季节性并高亮异常值。此外, DifFormer 还引入了动态范围划分策略,能够自适应地将时间序列划分成多个最优的局部范围进行注意力计算,从而灵活捕捉不同长度的周期模式。这些根本性的改进使得 DifFormer 在分类、回归和预测等多种任务上均表现出卓越的性能,具备成为金融时间序列分析通用骨干网络的潜力。Tao 等^[56]则提出了一种序列分解 Transformer 模型,该模型对标准的 Transformer 架构进行了两点关键改进:一是集成了序列分解模块,能够自动将输入序列分解为趋势项和季节项;二是引入了自相关机制来替代传统的自注意力机制,能更有效地捕捉时间序列中基于周期的依赖关系。

4.5 基于深度强化学习的金融决策模型

前文所述的深度学习模型主要解决“预测”问题。然而,在真实的金融市场中,“预测”仅仅是第一步,更核心的任务是基于预测进行“决策”。深度强化学习将深度学习强大的状态感知能力与强化学习的序列决策能力相结合,为构建能够直接与市场环境交互、自主学习并执行最优交易或投资策略的智能体(Agent)提供了可能。DRL 的目标是在一个动态变化的环境中,通过不断试错来最大化长期的累积回报,这与金融投资的本质高度契合。基于 DRL 的方法框架如图 10 所示。

近年来,构建能够直接输出投资组合权重的端到端模型是 DRL 在金融领域应用的一大趋势。例如, Yang 等^[57]提出的一个用于投资组合管理的 DRL 框架,直接将包含多种加密货币的市场历史价格张量输入到一个基于 CNN-RNN 的策略网络中,实现了从市场观察到资产配置的端到端决策。该研究还创新性地引入了投资组合向量内存(PVM)机制,用于记录历史的资产配置状态,为智能体决策提供了更丰富的上下文信息。

为了使 DRL 智能体的决策更符合金融经济学理论,一些研究开始将经典的金融理论融入 DRL 的框架设计中。Jang 等^[20]在他们的股票投资组合优化研究中,将现代投资组合理论(MPT)与深度确定性策略梯度(DDPG)算法进行了结合,

提出了 MPT-DDPG 模型。该研究的核心创新在于,它没有使用简单的利润作为奖励函数,而是将 MPT 理论中的夏普比率直接作为智能体的奖励信号,引导智能体在学习过程中去寻找一个风险与回报相平衡的最优策略。

随着研究的深入,多智能体强化学习(Multi-Agent Reinforcement Learning, MARL)和结合复杂图信息的 DRL 模型也开始出现。Huang 等^[58]提出了一个名为 MADDQN 的 MARL 框架,通过设置具有不同目标偏好的多个子智能体,来模拟更复杂的市场协作与博弈。Li 等^[59]则构建了基于多层图关系和强化学习的交易策略模型,先利用 GNN 从复杂关系图中进行趋势预测,再将预测结果输入 RL 框架中进行策略训练。这些研究共同表明,深度强化学习正从简单的单资产交易,向复杂的多资产投资组合管理、多智能体协作以及多源信息融合等更高级、更贴近真实金融场景的方向发展。

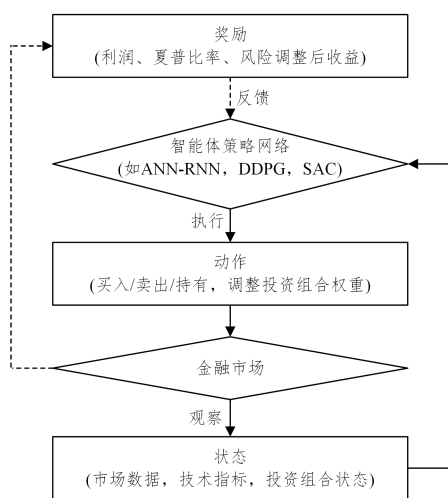


图 10 深度强化学习在金融决策中的通用框架

Fig. 10 General framework for DRL in financial decision making

5 金融数据预测中的数据处理方法

在基于人工智能的金融预测领域的应用中,模型的性能不仅取决于算法本身的先进性,还在很大程度上依赖于输入数据的质量和特征的有效性。高质量的特征工程与数据处理能够从原始数据中提取出更具信息量的预测因子,处理金融数据特有的噪声、非平稳性和复杂关联性。本章将探讨那些核心贡献在于提出新颖的辅助技术并对某一领域进行系统性回顾的研究,这些工作从不同维度提升了金融预测流程的整体效能与深度。

特征工程是机器学习流程的基石,其重要性在金融预测中尤为凸显。近年来,研究者在融合多源异构数据、构建网络关联特征、引入先进信号处理技术以及应用新型数据处理范式等方面取得了显著进展。

将 Transformer 与其他模型进行混合,以发挥各自优势,是另一个富有成效的研究方向。Mishra 等^[60]构建了一系列深度混合模型,例如在 TL-GARCH 模型中,首先通过 GARCH 模型对数据进行处理,再将输出输入 LSTM 层,之后送入 Transformer 层进行最终的特征提取和预测。这种多阶段、多架构的串联融合,旨在让不同模型发挥各自的优势

(GARCH 捕捉波动聚集、LSTM 处理短期时序、Transformer 捕捉长期依赖)。

构建网络关联特征是捕捉金融系统复杂性的另一关键技术。金融市场中的实体并非孤立存在,而是通过各种渠道相互关联,形成复杂的风险传导网络。Wang 等^[1]针对系统性风险预测问题,创新性地提出并验证了“网络关联性”特征的有效性。他们通过向量自回归模型构建了金融机构间的动态风险传导网络,并将从中提取的关联性指标作为新特征,显著增强了标准机器学习模型对系统性风险事件的预测能力。

Haq 等^[61]针对股票趋势预测,提出了一个将复杂特征选择与深度生成模型相结合的混合方法。其核心创新在于一个名为多过滤器特征选择 (Multi-Filter Feature Selection, MFFS) 的流程。该流程通过集成 3 种具有不同模型假设 (L1 正则化逻辑回归、SVM 和随机森林) 的特征排序结果,并结合聚类来消除冗余,最终生成了一个更加鲁棒和高效的特征子集。随后,这个经过精心筛选的特征子集被输入到一个基于变分自编码器 (VAE) 和注意力机制的深度生成模型中进行预测,其性能显著优于使用全部特征或单一方法筛选特征的模型。

引入先进的信号处理技术是处理高噪声、非平稳金融时间序列的有效途径。Dezhkam 等^[22]将信号处理领域的希尔伯特-黄变换 (HHT) 创造性地应用于股票市场预测。HHT 能够将非线性的股价序列自适应地分解为一系列本征模函数,从中可以提取出瞬时频率、振幅等传统技术指标无法捕捉的深层特征,显著提升了预测效果和投资回报。

联邦学习 (Federated Learning, FL) 作为一种新兴的数据处理和建模范式,为解决金融领域普遍存在的数据孤岛和隐私保护问题提供了新的解决方案。联邦学习在金融领域的应用如图 11 所示。Kong 等^[62]首次将联邦学习框架应用于供应链金融中订单级别的风险预测,允许各参与方在不暴露原始数据的情况下,协同训练一个共享的机器学习模型,有效解决了数据割裂问题。为解决联邦学习中数据异构性导致的性能下降问题,Wang 等^[41]进一步提出了名为 FedKT 的新型联邦学习算法,通过知识蒸馏技术,将全局模型的“知识”迁移给数据量较少的本地模型,显著提升了模型的整体表现。

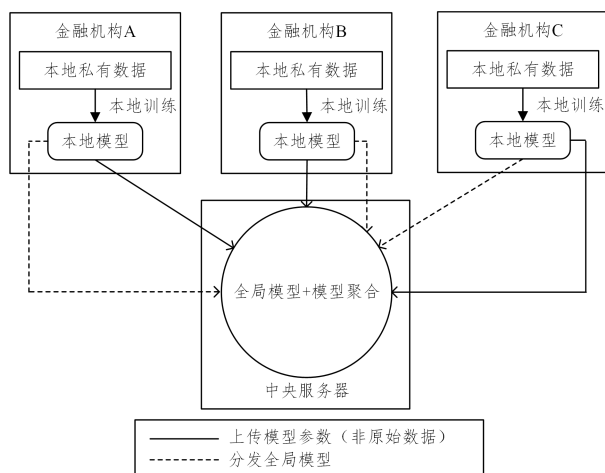


图 11 联邦学习在金融风险预测中的应用范式

Fig. 11 Application paradigm of federated learning in financial risk prediction

在本领域内,相关学者发表了多篇有影响力的综述性文章,它们对于系统性地梳理现有成果、总结技术趋势和指明未来方向至关重要。

Htun 等^[27]对应用于股票市场预测的特征选择与提取技术进行了详尽的综述,为该领域的特征工程提供了清晰、全面的分类框架。针对特定市场,Ayitey 等^[63]对外汇市场的机器学习应用进行了系统性文献回顾和元分析,指出神经网络和 SVM 是应用最广泛的算法,并强调混合模型是未来的重要发展方向。Olorunnimbe 等^[7]则对深度学习在股票市场的应用实践和回测方法进行了全面综述,在肯定 CNN-RNN 混合架构和深度强化学习等主流趋势的同时,也强调了其在模型可解释性和回测的严谨性方面仍有待加强。

从更宏观的视角出发,Masini 等^[6]评述了近年来机器学习在时间序列预测领域的进展,强调了现代机器学习方法在处理高维数据和非线性关系上的优势,并讨论了如前向验证等严谨的评估方法。此外,聚焦于特定模型框架的综述也为研究提供了深度指引,例如 Zhang 等^[64]对 TSK 模糊系统的融合方法进行了系统性回顾,将其归纳为分层、宽度和堆叠 3 种融合范式。

6 金融预测的结构化神经网络建模范式

6.1 从模型应用到结构化建模的视角转变

前述章节系统性地回顾了各类机器学习与深度学习模型在金融预测领域的应用。这些研究虽取得了显著成果,但大多仍遵循“数据-模型-预测”的应用范式,即将现有的人工智能模型(如 RNN, GNN, Transformer 等)作为功能强大的“黑箱”或“灰箱”工具,直接应用于金融数据处理。这种方法的核心在于利用算法强大的拟合能力来挖掘数据中的统计规律,而较少从金融产品本身的内在结构出发来指导神经网络的拓扑设计。

本章旨在跳出具体的模型应用,从一个更具本源性的视角,探讨一种旨在反映金融产品内在结构的神经网络建模范式。我们将尝试回答一个核心问题:能否构建一种神经网络,其架构本身就是针对金融实体,尤其是如共同基金这类复杂的投资组合,是内在构成关系的一种模拟和表达。这种从金融逻辑出发、自下而上构建网络结构的思路,或将为提升模型的预测性能和可解释性提供一条新的路径。

6.2 金融实体作为“根源组合”的拓扑结构

金融市场中的许多投资工具,尤其是金融基金,其本质是一个由多种基础资产构成的复杂系统。我们可以将这些基础资产,如股票、债券、货币、商品等,定义为影响基金净值的“基金源”。因此,一只基金的整体表现可以被看作其所有“基金源”在不同权重和相互作用下的综合体现。这种构成关系天然地形成了一种数学拓扑结构:底层资产(基金源)是基础节点,它们通过特定的投资策略和市场机制相互关联、相互影响,最终汇聚成基金这一顶层实体。

这种拓扑视角为我们提供了构建金融预测神经网络的全新思路。它要求我们设计的网络架构不应是随意的,而应与所预测的金融产品的内在结构相匹配。具体而言,神经网络的输入层可以被设计为与“基金源”一一对应,每个输入神经


元代表一种特定的底层资产或其关键影响因素,如某支股票的收益率、某种债券的久期等。这样,输入层便不再是无差别的数据输入端口,而是对金融实体构成的一种结构化模拟,为整个网络的学习过程赋予了明确的经济学和金融学意义。

6.3 隐藏层:从特征工程到“关联变量”的内在建模

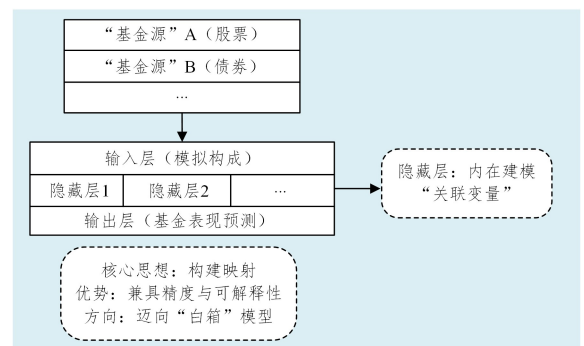
在上述结构化建模范式中,隐藏层(Hidden Layer)扮演了至关重要的角色。如果说输入层模拟了金融产品的“构成”,那么隐藏层则负责建模这些构成元素之间的复杂关系。本文将这些由输入变量之间相互作用而产生的、需要模型学习和表达的中间关系,抽象地称为“关联变量”。

在金融实践中,不同“基金源”,如股票和债券之间并非相互独立,它们之间可能存在复杂的线性和非线性关系。例如,股债的负相关性、不同行业股票的轮动效应、宏观经济冲击下的共同反应等。传统方法通常需要研究者依赖专业知识,通过大量的人工特征工程来尝试捕捉这些关系。而在此范式下,隐藏层的作用被重新定义为对这些“关联变量”的内在化建模。通过其复杂的连接权重和非线性激活函数,隐藏层能够自主地从数据中学习和发现这些关联。例如,第一隐藏层可能学习到不同资产间的简单相关性;而更深的隐藏层则可能在此基础上,结合货币政策等其他因素,学习到更复杂的宏观经济周期下的资产轮动模式。

因此,隐藏层的设计包括层数、每层的神经元数量以及连接方式,应以有效捕捉和表达关键“关联变量”为目标。这为神经网络的架构设计提供了理论依据,即网络深度和宽度的选择应服务于对金融产品内在逻辑关系的模拟,而非盲目堆叠。这种方法论,有望将部分过去依赖于人工的特征工程任务转化为一个可由网络自主学习的内在建模过程。主流的“黑箱”与结构化的神经网络对比如图 12 所示。



(a) 主流“黑箱”应用范式



(b) 结构化神经网络建模范式

图 12 从“黑箱”应用到结构化建模的范式演进

Fig. 12 Paradigm evolution from “black box” application to structured modeling

6.4 正向/反向传播:实现结构化学习的机制

在构建了与金融实体拓扑结构相匹配的神经网络之后,

模型的学习过程通过经典的正向传播(Forward Propagation)和反向传播(Back Propagation)这两个相互依赖的机制来实现。

在正向传播阶段,输入层的“基金源”数据,如各类资产的收益率,沿着网络逐层向前传递。在每一隐藏层,神经元都会对来自前一层的信息进行加权求和与非线性变换,从而逐步形成对各“关联变量”的量化表达,最终在输出层生成对基金净值等目标的初步预测。

而在反向传播阶段,模型将输出层的预测结果与真实值进行比较,计算出预测误差。这个误差会从输出层开始,沿着网络逐层向后传递。在传递过程中,优化算法(如梯度下降法)会根据误差对每一层网络的连接权重和偏置进行微调。这一过程的本质可以理解为模型在不断地修正其对“关联变量”的理解和建模方式。通过成千上万次的“预测—反馈—修正”循环,神经网络最终能够学习到一套最优的权重参数,使其内部的“关联变量”模型能够最精准地反映真实的金融市场规律。

综上所述,这种基于金融实体拓扑结构的神经网络建模范式,为人工智能在金融预测领域的应用提供了一种具有深刻内在逻辑的框架。它强调了模型架构设计应与金融产品的内在构成相呼应,将输入层视为对基础资产的模拟,将隐藏层视为对资产间复杂关系的建模。

该范式的核心优势在于,它不仅追求预测的准确性,更追求模型内部逻辑与金融现实的一致性。通过这种结构化的设计,神经网络的每一部分都具有了潜在的经济学或金融学含义,这为我们打开“黑箱”、理解模型决策过程提供了可能。这有望推动金融 AI 从高度依赖数据拟合的“黑箱”模型,向更具可解释性和稳健性的“白箱”或“灰箱”模型发展。这一思路不仅为未来的模型研究和算法创新提供了理论基础,也与本文后续章节将要探讨的“模型可解释性”等挑战与未来方向完美呼应。

7 总结

7.1 数据层面的挑战

数据是所有人工智能模型的基石,其质量和特性直接决定了模型性能的上限。在金融领域,数据层面的挑战尤为突出。

1)数据质量、异构性与稀缺性。金融数据以其高噪声、非平稳的特性而著称,这要求模型必须具备强大的去噪和动态适应能力^[70]。同时,金融预测日益依赖于多源异构数据的融合,如何有效整合结构化的交易数据、非结构化的新闻文本,甚至是描述实体间关系的图数据,是提升模型性能的关键,也是当前研究的一大难点^[71]。此外,对于“黑天鹅”事件,如金融危机^[72]、重大政策冲击^[44],以及如信用违约^[73]、财务舞弊等风险事件^[74],高质量的标注样本往往非常稀缺,这给模型的训练和泛化带来了巨大挑战。

2)数据隐私与“数据孤岛”。金融数据具有高度的敏感性,严格的隐私保护和监管要求使得不同机构间的“数据孤岛”问题尤为严重。这极大地限制了构建全局、高性能模型所需的数据规模和多样性^[35]。近年来,以联邦学习(Federated

Learning, FL)为代表的隐私计算技术提供了此类问题的解决方案。通过在不共享原始数据的前提下进行协同建模,联邦学习有望打破数据壁垒,在保护数据隐私的同时提升模型性能。然而,如何有效处理联邦学习中的数据异构性(Non-IID)问题,仍是未来需要持续研究的方向。

7.2 模型层面的挑战

在模型层面,虽然更深、更复杂的网络结构不断涌现,但其在金融领域的应用仍需面临泛化能力、可解释性和计算效率等核心挑战。

1)模型的鲁棒性与泛化能力。金融市场是一个典型的开放、动态系统,模型的过拟合问题尤为严重。一个在历史回测中表现优异的模型,在真实市场中可能迅速失效。因此,如何提升模型的鲁棒性和泛化能力是所有预测模型的核心议题。这不仅需要更先进的正则化技术^[75]和更严谨的回测框架^[76],还需要模型能够动态适应变化的市场环境。例如, Ding 等^[43]便强调了模型适应时变特征的重要性。

2)模型可解释性与可信赖 AI(XAI)。深度学习模型常被诟病为“黑箱”,其决策过程缺乏透明度,这在需要高度负责和严格监管的金融领域是难以接受的。因此,发展可解释性人工智能已成为该领域最迫切的需求之一。当前的研究正从多个方向寻求突破:一是采用内在可解释的模型,如 Wang 等^[41]提出的基于直觉模糊逻辑的推理模型;二是利用事后解释工具如 LIME 和 SHAP 等来分析“黑箱”模型的决策依据,如 Çelik 等^[5]将其用于评估预测的“可靠性”,Ma 等^[17]则用其分析 Transformer 模型中技术指标的重要性。构建既准确又可信赖的金融预测模型,将是未来研究的核心。

3)计算资源与效率。随着模型尤其是 STGNN^[77]和 DRL 模型复杂度的提升,其训练所需的计算资源和时间成本急剧增加,这不仅限制了大规模模型在中小机构中的应用,也对模型的实时预测和迭代优化提出了挑战。因此,研究更高效的模型架构,如线性 Transformer 和优化算法,对于推动 AI 在金融领域的普适性应用至关重要。

7.3 未来研究方向展望

面对上述挑战,结合当前的技术前沿,我们认为未来人工智能在金融预测领域的研究将在以下几个方向取得重要突破,如图 13 所示。

1)深度多模态融合与知识图谱。未来的预测模型将不再满足于简单地拼接不同来源的数据,而是会发展出更精巧的深度多模态融合机制^[78-79],如基于注意力机制的跨模态信息交互。此外,将金融领域的专业知识构建为知识图谱,并将其与深度学习模型,特别是 GNN 相结合,有望让模型在数据驱动的基础上,融入更多的先验知识和逻辑约束,从而做出更稳健、更合理的预测。

2)因果推断与 AI 的结合。当前的金融预测模型绝大多数是基于相关关系,而非因果关系,这使得模型在面临市场结构变化时表现脆弱。将因果推断理论与机器学习相结合,旨在从数据中挖掘“是什么导致了价格变动”,而不仅仅是“什么与价格变动相关”。这有望从根本上提升模型的鲁棒性和泛化能力,是推动金融 AI 从“预测”走向“理解”的关键一步。

3)金融大语言模型^[80]的深化应用。以 BloombergGPT

为代表的金融领域垂直大模型的出现,预示着一个新时代的到来。未来,LLM 不仅能提供更精准的文本情感分析,更有潜力成为集信息检索、数据分析、逻辑推理、策略生成于一体的“金融分析师”或“交易员”。如何构建更强大的金融 LLM,并探索其在量化交易、风险管理和智能投顾等领域的深度应用,将是极具价值的研究方向。

4) 更自主、更适应的决策智能。以深度强化学习为代表的决策智能将继续发展。未来的研究将聚焦于构建更接近真实市场的模拟环境、设计更合理的奖励函数(如结合金融理论的夏普比率),以及发展能够处理复杂市场博弈的多智能体强化学习系统。

5) 新兴计算范式的探索。虽然尚处早期,但量子计算因在处理优化问题和模拟复杂系统方面具有巨大潜力,被认为可能为金融建模(如投资组合优化等)带来颠覆性的变革。探索量子机器学习算法在金融领域的应用,将是一个极具前瞻性的研究方向。

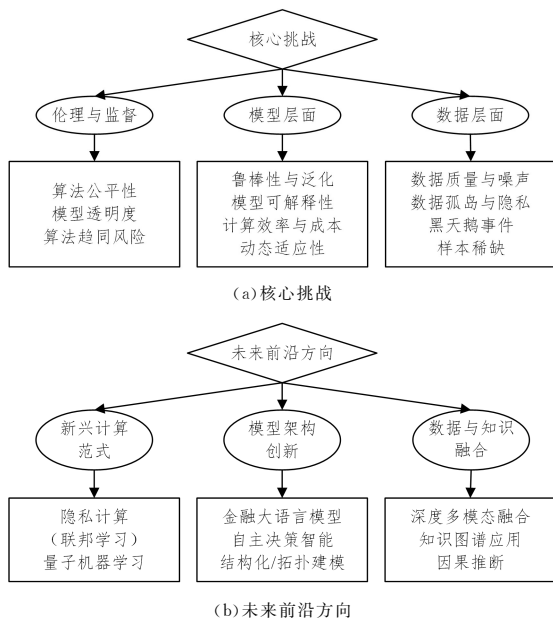


图 13 AI 在金融预测领域的挑战与未来方向

Fig. 13 Challenges and future directions of artificial intelligence in financial forecasting

最后,随着 AI 在金融领域应用的日益深化,算法的公平性、透明度以及由算法趋同性可能引发的新型系统性风险等伦理与监管问题也亟待学术界、业界和监管机构的共同关注与研究,以确保人工智能技术能够安全、可靠、负责任地推动金融行业的健康发展。

参考文献

[1] WANG G J, CHEN Y, ZHU Y, et al. Systemic risk prediction using machine learning: Does network connectedness help prediction? [J]. *International Review of Financial Analysis*, 2024, 93: 103147.

[2] CHANG V, HAHM N, XU Q A, et al. Towards data and analytics driven B2B-banking for green finance: A cross-selling use case study [J]. *Technological Forecasting and Social Change*, 2024, 206: 123542.

[3] WANG S, CHI G. Cost-sensitive stacking ensemble learning for

company financial distress prediction [J]. *Expert Systems with Applications*, 2024, 255: 124525.

[4] CHOU J S, CHEN K E. Optimizing investment portfolios with a sequential ensemble of decision tree-based models and the FBI algorithm for efficient financial analysis [J]. *Applied Soft Computing*, 2024, 158: 111550.

[5] ÇELİK T B, İCAN Ö, BULUT E. Extending machine learning prediction capabilities by explainable AI in financial time series prediction [J]. *Applied Soft Computing*, 2023, 132: 109876.

[6] KUO R J, CHIU T H. Hybrid of jellyfish and particle swarm optimization algorithm-based support vector machine for stock market trend prediction [J]. *Applied Soft Computing*, 2024, 154: 111394.

[7] OLORUNNIMBE K, VIKTOR H. Deep learning in the stock market—a systematic survey of practice, backtesting, and applications [J]. *Artificial Intelligence Review*, 2023, 56 (3): 2057-2109.

[8] MASINI R P, MEDEIROS M C, MENDES E F. Machine learning advances for time series forecasting [J]. *Journal of economic surveys*, 2023, 37(1): 76-111.

[9] BALA R, SINGH R P. A dual-stage advanced deep learning algorithm for long-term and long-sequence prediction for multivariate financial time series [J]. *Applied Soft Computing*, 2022, 126: 109317.

[10] MUKHERJEE S, SADHUKHAN B, SARKAR N, et al. Stock market prediction using deep learning algorithms [J]. *CAAI Transactions on Intelligence Technology*, 2023, 8(1): 82-94.

[11] HUANG W C, CHEN C T, LEE C, et al. Attentive gated graph sequence neural network-based time-series information fusion for financial trading [J]. *Information Fusion*, 2023, 91: 261-276.

[12] LUO Q, BU J, XU W, et al. Stock market volatility prediction: Evidence from a new bagging model [J]. *International Review of Economics & Finance*, 2023, 87: 445-456.

[13] SONG Y, HUANG J, XU Y, et al. Multi-decomposition in deep learning models for futures price prediction [J]. *Expert Systems with Applications*, 2024, 246: 123171.

[14] WANG C, CHEN Y, ZHANG S, et al. Stock market index prediction using deep Transformer model [J]. *Expert Systems with Applications*, 2022, 208: 118128.

[15] CHENG D, YANG F, XIANG S, et al. Financial time series forecasting with multi-modality graph neural network [J]. *Pattern Recognition*, 2022, 121: 108218.

[16] JIN M, KOH H Y, WEN Q, et al. A survey on graph neural networks for time series: forecasting, classification, imputation, and anomaly detection [J]. *arXiv:2307.03759*, 2023.

[17] MA T, WANG W, CHEN Y. Attention is all you need: An interpretable transformer-based asset allocation approach [J]. *International Review of Financial Analysis*, 2023, 90: 102876.

[18] FISCHER T, STERLING M, LESSMANN S. Fx-spot predictions with state-of-the-art transformer and time embeddings [J]. *Expert Systems with Applications*, 2024, 249: 123538.

[19] LI B, CUI W, ZHANG L, et al. Difformer: Multi-resolutional differencing transformer with dynamic ranging for time series analysis [J]. *IEEE transactions on pattern analysis and machine*

- intelligence,2023,45(11):13586-13598.
- [20] JANG J,SEONG N Y. Deep reinforcement learning for stock portfolio optimization by connecting with modern portfolio theory[J]. *Expert Systems with Applications*,2023,218:119556.
- [21] DU J. Mean-variance portfolio optimization with deep learning based-forecasts for cointegrated stocks[J]. *Expert Systems with Applications*,2022,201:117005.
- [22] DEZHAKAM A,MANZURI M T. Forecasting stock market for an efficient portfolio by combining XGBoost and Hilbert-Huang transform [J]. *Engineering Applications of Artificial Intelligence*,2023,118:105626.
- [23] HENRIQUE B M,SOBREIRO V A,KIMURA H. Practical machine learning: Forecasting daily financial markets directions [J]. *Expert Systems with Applications*,2023,233:120840.
- [24] ZHOU Y,XIE C,WANG G J,et al. Forecasting cryptocurrency volatility:a novel framework based on the evolving multiscale graph neural network [J]. *Financial Innovation*,2025,11(1):1-52.
- [25] ASHTIANI M N,RAAHEMI B. News-based intelligent prediction of financial markets using text mining and machine learning:A systematic literature review[J]. *Expert Systems with Applications*,2023,217:119509.
- [26] ALI A A,KHEDR A M,EL-BANNANY M,et al. A powerful predicting model for financial statement fraud based on optimized XGBoost ensemble learning technique[J]. *Applied Sciences*,2023,13(4):2272.
- [27] HTUN H H,BIEHL M,PETKOV N. Survey of feature selection and extraction techniques for stock market prediction[J]. *Financial Innovation*,2023,9(1):26.
- [28] ABDOLI M,AKBARI M,SHAHRABI J. Bagging supervised autoencoder classifier for credit scoring[J]. *Expert Systems with Applications*,2023,213:118991.
- [29] SEBASTIAO H,GODINHO P. Forecasting and trading cryptocurrencies with machine learning under changing market conditions[J]. *Financial Innovation*,2021,7(1):3.
- [30] CHI G,WANG S. Default risk prediction model of Chinese Listed Companies Based on xgboost [J]. *Journal of Systems Management*,2024,33(3):735-754.
- [31] YIN L,LI B,LI P,et al. Research on stock trend prediction method based on optimized random forest[J]. *CAAI Transactions on Intelligence Technology*,2023,8(1):274-284.
- [32] CHENG J,TIWARI S,KHALED D,et al. Forecasting Bitcoin prices using artificial intelligence: Combination of ML, SARI-MA, and Facebook Prophet models[J]. *Technological Forecasting and Social Change*,2024,198:122938.
- [33] DAG A,DAG A Z,ASILKALKAN A,et al. A Tree Augmented Naïve Bayes-based methodology for classifying cryptocurrency trends[J]. *Journal of Business Research*,2023,156:113522.
- [34] SUN Z L,TANG J Y,FENG S,et al. Adaptive stock trading strategy based on deep reinforcement learning [J]. *Journal of Zhejiang University of technology*,2024,52(2):188-195.
- [35] PARK H J,KIM Y,KIM H Y. Stock market forecasting using a multi-task approach integrating long short-term memory and the random forest framework[J]. *Applied Soft Computing*,2022,114:108106.
- [36] EMMANUEL I,SUN Y,WANG Z. A machine learning-based credit risk prediction engine system using a stacked classifier and a filter-based feature selection method[J]. *Journal of Big Data*,2024,11(1):23.
- [37] ZHOU Y,SHEN L,BALLESTER L. A two-stage credit scoring model based on random forest: Evidence from Chinese small firms[J]. *International Review of Financial Analysis*,2023,89:102755.
- [38] DEL FAVA S,GUPTA R,PIERDZIOCH C,et al. Forecasting international financial stress:The role of climate risks[J]. *Journal of International Financial Markets, Institutions and Money*,2024,92:101975.
- [39] LYU X M,ZHANG R,et al. Personal credit risk assessment of online micro loan business—Based on DNN smoteenn extratrees combination model [J]. *Practice and Understanding of Mathematics*,2023,53(7):14-21.
- [40] BORUP D,CHRISTENSEN B J,MÜHLBACH N S,et al. Targeting predictors in random forest regression[J]. *International Journal of Forecasting*,2023,39(2):841-868.
- [41] WANG W,LIN W,WEN Y,et al. An interpretable intuitionistic fuzzy inference model for stock prediction[J]. *Expert Systems with Applications*,2023,213:118908.
- [42] MANTILLA P,DORMIDO-CANTO S. A novel feature engineering approach for high-frequency financial data[J]. *Engineering Applications of Artificial Intelligence*,2023,125:106705.
- [43] DING S,CUI T,BELLOTTI A G,et al. The role of feature importance in predicting corporate financial distress in pre and post COVID periods:Evidence from China[J]. *International Review of Financial Analysis*,2023,90:102851.
- [44] SAÂDAOUI F,RABBOUCH H. Financial forecasting improvement with LSTM-ARFIMA hybrid models and non-Gaussian distributions[J]. *Technological Forecasting and Social Change*,2024,206:123539.
- [45] IZADI M A,HAJIZADEH E. Time Series Prediction for Cryptocurrency Markets with Transformer and Parallel Convolutional Neural Networks[J]. *Applied Soft Computing*,2025,113(3):113229.
- [46] YiLDiRiM D C,TOROSLU I H,FIORÉ U. Forecasting directional movement of Forex data using LSTM with technical and macroeconomic indicators[J]. *Financial innovation*,2021,7(1):1.
- [47] ZHAO Y,ZHANG W,LIU X. Grid search with a weighted error function:Hyper-parameter optimization for financial time series forecasting[J]. *Applied Soft Computing*,2024,154:111362.
- [48] GAJAMANNAGE K,PARK Y,JAYATHILAKE D I. Real-time forecasting of time series in financial markets using sequentially trained dual-LSTMs[J]. *Expert Systems with Applications*,2023,223:119879.
- [49] DONG Z,ZHOU Y. A novel hybrid model for financial forecasting based on CEEMDAN-SE and ARIMA-CNN-LSTM [J]. *Mathematics*,2024,12(16):2434.
- [50] ZHAO Y,YANG G. Deep Learning-based Integrated Framework for stock price movement prediction [J]. *Applied Soft Computing*,2023,133:109921.
- [51] HUANG Y,WANG Z,JIANG C. Diagnosis with incomplete multi-view data:A variational deep financial distress prediction method[J]. *Technological Forecasting and Social Change*,2024,201:123269.

- [52] ZHANG P, HARRIS R D F, ZHENG J. GNN-based social media sentiment analysis for stock market forecasting and trading[J]. *Expert Systems with Applications*, 2025; 128425.
- [53] LAZCANO A, HERRERA P J, MONGE M. A combined model based on recurrent neural networks and graph convolutional networks for financial time series forecasting[J]. *Mathematics*, 2023, 11(1): 224.
- [54] HUANG Z, LI K, JIANG Y, et al. Graph Relearn Network: Reducing performance variance and improving prediction accuracy of graph neural networks[J]. *Knowledge-Based Systems*, 2024, 301: 112311.
- [55] LEE S, CHO P. Graph-Based Stock Volatility Forecasting with Effective Transfer Entropy and Hurst-Based Regime Adaptation[J]. *Fractal and Fractional*, 2025, 9(6): 339.
- [56] TAO Z, WU W, WANG J. Series decomposition Transformer with period-correlation for stock market index prediction[J]. *Expert Systems with Applications*, 2024, 237: 121424.
- [57] YANG S. Deep reinforcement learning for portfolio management[J]. *Knowledge-Based Systems*, 2023, 278: 110905.
- [58] HUANG Y, ZHOU C, CUI K, et al. A multi-agent reinforcement learning framework for optimizing financial trading strategies based on TimesNet[J]. *Expert Systems with Applications*, 2024, 237: 121502.
- [59] LI S Y, ZHONG X Y, LI K Y, et al. Research on strategy teaching based on multi-layer graph relationship and reinforcement learning[J]. *Computer Engineering*, 2025, 51(3): 122-130.
- [60] MISHRA A K, RENGANATHAN J, GUPTA A. Volatility forecasting and assessing risk of financial markets using multi-transformer neural network based architecture[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108223.
- [61] HAQ A U, ZEB A, LEI Z, et al. Forecasting daily stock trend using multi-filter feature selection and deep learning[J]. *Expert Systems with Applications*, 2021, 168: 114444.
- [62] KONG L, ZHENG G, BRINTRUP A. A federated machine learning approach for order-level risk prediction in supply chain financing[J]. *International Journal of Production Economics*, 2024, 268: 109095.
- [63] AYITEY J M, APPIAHENE P, APPIAH O, et al. Forex market forecasting using machine learning: Systematic Literature Review and meta-analysis[J]. *Journal of Big Data*, 2023, 10(1): 9.
- [64] ZHANG Y, WANG G, ZHOU T, et al. Takagi-Sugeno-Kang fuzzy system fusion: A survey at hierarchical, wide and stacked levels[J]. *Information fusion*, 2024, 101: 101977.
- [65] YANG M, LIM M K, QU Y, et al. Deep neural networks with L1 and L2 regularization for high dimensional corporate credit risk prediction[J]. *Expert Systems with Applications*, 2023, 213: 118873.
- [66] OYEDELE A A, AJAYI A O, OYEDELE L O, et al. Performance evaluation of deep learning and boosted trees for cryptocurrency closing price prediction[J]. *Expert Systems with Applications*, 2023, 213: 119233.
- [67] LONG W, GAO J, BAI K, et al. A hybrid model for stock price prediction based on multi-view heterogeneous data[J]. *Financial Innovation*, 2024, 10(1): 48.
- [68] SONG Y, CAI C, MA D, et al. Modelling and forecasting high-frequency data with jumps based on a hybrid nonparametric regression and LSTM model[J]. *Expert Systems with Applications*, 2024, 237: 121527.
- [69] ZHANG Q, QIN C, ZHANG Y, et al. Transformer-based attention network for stock movement prediction[J]. *Expert Systems with Applications*, 2022, 202: 117239.
- [70] EDALATPANAH S A, HASSANI F S, SMARANDACHE F, et al. A hybrid time series forecasting method based on neutrosophic logic with applications in financial issues[J]. *Engineering Applications of Artificial Intelligence*, 2024, 129: 107531.
- [71] ROOSTAEE M R, ABIN A A. Forecasting financial signal for automated trading: An interpretable approach[J]. *Expert Systems with Applications*, 2023, 211: 118570.
- [72] RAZA S A, KHAN K A, BENKRAIEM R, et al. The importance of climate policy uncertainty in forecasting the green, clean and sustainable financial markets volatility[J]. *International Review of Financial Analysis*, 2024, 91: 102984.
- [73] YU B, LI C, MIRZA N, et al. Forecasting credit ratings of decarbonized firms: Comparative assessment of machine learning models[J]. *Technological Forecasting and Social Change*, 2022, 174: 121255.
- [74] SUN Z Q, LIU X L. Research on risk taking, trend of net interest margin and stable development of banks—experimental evidence based on panel data of commercial banks from 2009 to 2019[J]. *Financial Theory and Practice*, 2023, 44(3): 18-26.
- [75] CHAUDHARI K, THAKKAR A. Neural network systems with an integrated coefficient of variation-based feature selection for stock price and trend prediction[J]. *Expert Systems with Applications*, 2023, 219: 119527.
- [76] LU M, XU X. TRNN: An efficient time-series recurrent neural network for stock price prediction[J]. *Information Sciences*, 2024, 657: 119951.
- [77] HU M, TAN Z, LIU B, et al. Graph Portfolio: High-Frequency Factor Predictors via Heterogeneous Continual GNNs[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2025, 37(7): 4104-4116.
- [78] WANG Y, ANDREEVA G, Martin-Barragan B. Machine learning approaches to forecasting cryptocurrency volatility: Considering internal and external determinants[J]. *International Review of Financial Analysis*, 2023, 90: 102914.
- [79] MD A Q, KAPOOR S, AV C J, et al. Novel optimization approach for stock price forecasting using multi-layered sequential LSTM[J]. *Applied Soft Computing*, 2023, 134: 109830.
- [80] SHAO Z, YAO X, CHEN F, et al. Revisiting time-varying dynamics in stock market forecasting: A multi-source sentiment analysis approach with large language model[J]. *Decision Support Systems*, 2025, 190: 114362.



CHEN Xiayi, born in 1999, master. Her main research interest is financial data analysis.