

时空并蓄，择基而优：ConvLSTM 赋能 FOF 策略的实证新证（附录）

外审评议与作者回复

尊敬的专家：

您好！

衷心感谢评审专家对本研究的专业指导。您提出的宝贵意见不仅帮助我们完善了本文，更显著提升了我们的研究水平。针对您的每一条建议，我们已认真修改并在文中用红色标注。恳请您拨冗审阅修改内容，期待您的进一步的指正！

第一份外审评议与作者回复

【意见 1】

文章选择的基金样本均不能提供月度资产净值，如何按照月度频率计算基金净现金流呢？建议对该衍生指标的计算方法说明清楚。

作者回复：

感谢审稿专家提出的宝贵建议，的确，基金净资产数据是在定期报告中披露的，在 Wind 数据库中，只有季度频率的净资产数据，并没有连续月度的净资产数据。本研究是根据 Wind 数据库中“基金数据浏览器”的连续月度基金总份额数据和月度末基金单位净值相乘计算得到的，文章中已经进行补充说明，以下是修改部分：

在表 1 给出的特征中，除基金资金流入率 $Flows$ 和超额收益 α 需要另外计算的衍生性变量，其他特征可在基金定期报告中获取，其中，基金 i 在 t 月的基金净现金流 $Flow_{i,t}$ 计算方法如下：

$$Flow_{i,t} = \frac{TNA_{i,t} - TNA_{i,t-1}(1 + r_{i,t})}{TNA_{i,t-1}}, \quad (11)$$

其中， $TNA_{i,t}$ 为基金 i 在第 t 月的净资产， $r_{i,t}$ 为基金 i 在第 t 月的月收益率，该指标衡量了基金资金流入的比率。由于公募基金仅在定期报告（季报、半年报、年报）中详细披露净资产和基金总份额，为满足月度频率分析需求，本文对月度基金净资产进行估算，具体方法为：月度基金净资产 = 月度基金总份额 × 当月末基金单位净值，其中月度基金总份额数据来自 Wind 数据库估算值。

【意见 2】

长短期记忆网络类模型对于数据样本数量的依赖度比较高，但经过文中方法筛选后只有 300 余个时间序列，这些样本数量是否足够？如果无法在参考文献上找到依据，不妨缩短样本时间用 2019 年（基金发行高峰）之后的数据做一做敏感性检验（时间长度更短、但序列数量明显增加）；或者纳入灵活配置型基金等样本，也能明显增加样本集（改变测试集长度）。

作者回复：

感谢您提出的关于 LSTM 模型样本数量的疑问，尽管样本数量仅 300 余个，但每个样本的时间跨度长达 9 年，覆盖了多轮市场牛熊转换（如 2018 年熊市、2020 年疫情冲击、2021 年结构性行情、2022 年风格切换等），包含了丰富的市场状态（波动放大、风格轮动、政策冲击等）。对于时序预测模型而言，时间维度的信息丰富性可在一定程度上弥补横截面样本量的不足，同时，序列的时间维度复杂度（如周期长度、噪声水平、非线性模式）直接影响 LSTM 模型训练效果，而非单纯依赖样本数量^[1]，本文预测目标为月度基金单位净值，其动态性低于高频股价或自然语言数据，且 LSTM 模型的样本外 R^2 达到 96.7%，说明模型未出现明显过拟合，对测试集数据的泛化能力尚可，因此，理论和实证表明，当前样本量在控制过拟合后能有效支持实证结论。

本文为减少过拟合风险，已经在模型中通过滑动窗口交叉验证避免数据泄露，确保模型在有限样本下的泛化能力。文章未考虑灵活配置型基金而聚焦普通股票型和偏股混合型基金，是为了保证研究对象的同质性，这两类基金的投资范围、风险特征更一致，而灵活配置型基金的基金经理可根据市场环境（如牛市、熊市）灵活调整股票与债券的配置比例，牛市时可将军票仓位提至 90% 以上，熊市时可降至 10% 以下甚至空仓，仓位灵活性极高。因此本文考虑到若盲目扩大样本而不考虑同质性，可能引入噪声，反而影响模型对核心规律的捕捉。

参考文献：

[1]Greff K,Srivastava R K,KoutnÍK J,et al.LSTM: a search space odyssey[J].IEEE Transactions on Neural Networks and Learning Systems,2017,28(10):2222-2232.

【意见 3】

文章没有对组合配置中的换手率给出测算，场外基金的赎回费都是不太低的，建议按照赎回费 0.5% 来估算（申购费可以免去计算）不同模型、不同换手率带来的影响，否则现在回测的组合净值是过度乐观的。

作者回复：

非常感谢您的宝贵建议，您提出的关于交易成本（尤其是赎回费）对回测结果的影响非常重要。本文重点是基于 ConvLSTM 模型对基金的收益率预测能否有效提升基金组合配置效率，重点在于对比不同策略（MV、RP、EW）下 FOF 的理想收益差异，忽略了月度调仓的高换手率带来的交易成本。经过计算。本文 FOF 的子基金月度换手率高于 90%，因此本文在 FOF 配置部分（4.4 小节）加入了 0.5% 赎回费率的调仓成本，增加后，各策略 FOF 配置结果均有所变化，整体平均月收益率和年化收益率有所降低，样本外 FOF 累计净值较不考虑赎回费率有所降低，由“在调仓月度 2023 年 7 月至 2025 年 4 月，MV 策略多头实现累计净值 1.231，RP 策略多头实现累计净值 1.128，EW 策略多头实现累计净值 1.087”调整为“在调仓月度 2023 年 7 月至 2025 年 4 月，MV 策略多头实现累计净值 1.183，RP 策略多头实现累计净值 1.097，EW 策略多头实现累计净值 1.50，”以下是具体修改部分。

4.4 FOF 资产配置

通过 ConvLSTM 模型预测收益率结果进行基金组合资产配置，每期选择预测收益最高的前 10 只基金构建策略多头 FOF，以 MV 策略、RP 策略和 EW 策略计算调仓期整体收益。对于基金月度调仓成本方面，若某月度 FOF 中某子基金被赎回，则扣除其对应权重 0.5% 的赎回费率，在实际投资中大额申购费率通常可忽略不计，因此本文未考虑申购费用。由于样本基金为普通股票型基金与偏股混合型基金，因此本文选择 Wind 普通股票基金指数（885000.WI）和 Wind 偏股混合基金指数（885001.WI）作为基金组合收益的比较基准。测

试集内策略多头 FOF 同比较基准的收益表现如表 6 所示。

表 6 ConvLSTM 模型的 MV 策略 FOF、RP 策略 FOF 和 EW 策略 FOF 配置结果

	RP 策略 FOF	EW 策略 FOF	MV 策略 FOF	885000.WI	885001.WI
平均月收益率	0.51%	0.16%	0.94%	-0.39%	-0.43%
年化收益率	6.30%	1.11%	11.88%	-6.71%	-7.00%
夏普比率	0.32	0.02	0.63	-0.27	-0.31
最大回撤	12.20%	15.00%	7.40%	23.00%	23.00%
卡玛比率	0.52	0.07	1.61	-0.29	-0.30
月胜率 1	63.64%	54.55%	68.18%	—	45.45%
月胜率 2	72.73%	59.09%	72.73%	54.55%	—

根据表 6 可知，基于 ConvLSTM 模型优选子基金构建的 FOF 组合策略表现均显著优于基准基金指数（885000.WI 和 885001.WI），其中 MV 策略表现最优，组合年化收益率达到 **11.88%**，最大回撤率为 **7.40%**，其相较于基准指数 885000.WI 和 885001.WI 月胜率分别为 **68.18%**和 **72.73%**，年化超额收益约为 **18%**。RP 和 EW 两种策略的 FOF 在各收益评价指标表现也均优于基准基金指数，EW 策略 FOF 表现整体稍弱于其他两种策略。

实证结果显示，基于 RNN 和 LSTM 模型预测结果构建的 FOF 组合同样展现出显著的投资价值。如表 7 和表 8 所示，通过收益率排序优选前十基金形成的子基金池，在 MV 策略、RP 策略和 EW 策略配置下，其收益表现均稳定超越基准指数，这一发现验证了量化选基方法的可行性。值得注意的是，LSTM 模型构建的 FOF 组合在关键绩效指标上普遍优于 RNN 模型，其中 MV 策略表现尤为突出，夏普比率持续保持在 0.1 以上，这一结果与最小方差投资理论^[33]的预期相符，表明在基金配置中控制组合波动能够有效提升风险调整后收益。相比之下，EW 策略的年化收益率均低于 1%，反映出简单分散化策略在主动管理型基金配置中的局限性。更值得关注的是，本研究提出的基于 ConvLSTM 模型所构建的 FOF 组合策略展现出更优异的综合表现，其各项绩效指标均显著优于时间序列模型，进一步凸显了时空特征建模在基金选择中的优势。

表 7 RNN 模型的 MV 策略 FOF、RP 策略 FOF 和 EW 策略 FOF 配置结果

	RP 策略 FOF	EW 策略 FOF	MV 策略 FOF	885000.WI	885001.WI
平均月收益率	0.14%	0.00%	0.27%	-0.39%	-0.43%
年化收益率	1.82%	0.00%	3.30%	-6.71%	-7.00%
夏普比率	0.02	-0.08	0.10	-0.27	-0.31
最大回撤	12.00%	15.00%	8.20%	23.00%	23.00%
卡玛比率	0.15	0.00	0.40	-0.29	-0.30
月胜率 1	54.55%	40.91%	54.55%	—	45.45%
月胜率 2	54.55%	45.45%	59.09%	54.55%	—

表 8 LSTM 模型的 MV 策略 FOF、RP 策略 FOF 和 EW 策略 FOF 配置结果

	RP 策略 FOF	EW 策略 FOF	MV 策略 FOF	885000.WI	885001.WI
--	-----------	-----------	-----------	-----------	-----------

平均月收益率	0.15%	0.05%	0.31%	-0.39%	-0.43%
年化收益率	1.83%	0.61%	3.76%	-6.71%	-7.00%
夏普比率	0.03	-0.04	0.12	-0.27	-0.31
最大回撤	12.00%	15.00%	12.00%	23.00%	23.00%
卡玛比率	0.15	0.04	0.31	-0.29	-0.30
月胜率 1	59.09%	40.91%	59.09%	--	45.45%
月胜率 2	59.09%	45.45%	59.09%	54.55%	--




图 15 ConvLSTM 模型优选基金构建的 FOF 累计净值曲线

图 15 展示了 ConvLSTM 模型构建的 FOF 在样本外的累计净值曲线，累计净值根据公式 (19) 计算，在调仓月度 2023 年 7 月至 2025 年 4 月，MV 策略多头实现累计净值 **1.183**，RP 策略多头实现累计净值 **1.097**，EW 策略多头实现累计净值 **1.50**，显著优于普通股票型基金指数 (0.88)、偏股混合型基金指数 (0.875)。同时，普通股票型基金指数的绩效表现优于偏股混合型基金指数，这是符合实际的，普通股票型基金中股票资产占基金资产的比例不低于 80%，因其股票仓位更高，能更充分地分享权益资产的上涨收益。

【意见 4】

基金经理能力是影响文章样本（主动选股基金）业绩的核心因素，同一基金经理管理的不同基金业绩一致性相对较高，但本文在模型训练和稳健性检验时均未对这一显而易见的群聚效应做出一些解释或者说明。从文章价值的角度，在稳健性检验部分可以尝试在组合中剔除同一基金经理的多只基金，检验组合业绩是否存在显著变化。

作者回复：

感谢您的提问，根据您的建议，我们对 326 只基金样本进行统计分析，结果得到这 326 个基金的基金经理最多管理着 4 只不同的产品，但是因为研究中仅选取了 10 只表现最优的基金作为 FOF 的子基金，即多数基金因预测收益未达标而未入选组合，根据模型结果，调仓月度的 10 只基金的基金经理完全不同，表明模型自然筛选出了不同经理管理的高潜力基金，间接规避了同一经理的群聚效应，因此无法“在组合中剔除同一基金经理的多只基金”。综上，尽管无法通过“剔除同一经理的多只基金”进行检验，基金经理群聚效应在本研究的组合层面未形成显著影响。感谢您的建议，对于后续研究中可能出现的更多的样本量，我们会考虑到基金经理能力在不同基金业绩上的一致性或者群聚效应表现。

第二份外审评议与作者回复

【意见 1】

论文强调 ConvLSTM 方法能够构建“时空维度”的多基金净值预测框架，通过卷积层捕获基金之间的“空间关联”，建议在本文基金净值预测的框架下，把 ConvLSTM 方法中的“空间”说得更直白一些。如果理解得正确的话，“空间关联”指的是，多个基金之间横截面层面的相关性（同期或跨期相关性都有），直接这样表述更易于理解。

作者回复：

感谢审稿专家提出的宝贵建议。我们已经在 1.2 节 ConvLSTM 的模型介绍最后一部分加入了在基金净值预测任务中的时间维度特征和空间维度特征的具体理解，将“空间”特征从横截面层面的同期或跨期相关性进行解释，便于读者理解。以下是修改部分。

在基金净值预测任务中，RNN 和 LSTM 模型存在独立建模与参数共享两种方式，独立建模需要为每只基金单独训练模型，虽然保留了基金异质性，但计算复杂度较高，产生严重参数冗余，而参数共享处理所有基金无法捕捉基金间的差异化特征。正如前文所述，这两种方法均无法建模基金间的空间相关性。为此，本研究采用 ConvLSTM 模型，通过卷积核捕捉基金间的空间依赖关系，同时利用 LSTM 建模时间维度特征，该方法通过三维张量输入实现时空联合建模，在保证预测精度的同时显著提升计算效率。

在基金净值预测任务中具体可以理解为，时间维度特征是基金净值在不同时点的动态变化规律，反映了基金业绩的历史延续性。而空间维度特征刻画的是基金间横截面上的相互影响和依赖关系，这种关联可能源于多方面：①同期相关性，即不同基金在同一时刻净值波动的联动性，源于基金对共同风险因子（如市场波动、行业冲击）的暴露，或羊群效应引发的集体交易行为；②跨期相关性：一只基金当前或历史的净值变动，可能影响持有相似资产、同一经理公司或同一风格的基金未来的净值变化，反映了风险或信息在基金网络中的传导与扩散机制。

ConvLSTM 能够有效识别并量化这种复杂的横截面依赖结构，从而将原本孤立的单基金时间序列预测，提升为更符合金融市场联动本质的多基金协同预测框架。

【意见 2】

论文的核心结论为基于 ConvLSTM 方法可综合考虑多个基金横截面和时间序列层面的信息，进而能够更加准确地预测基金净值。为支持以上结论，除了提供统计结果外，还需要在实证讨论部分或者结论部分，从理论角度阐释解释为什么有必要考虑多个基金横截面层面的关联，比如行业相关性、基金羊群效应、Mkt-RF t-stat 体现的系统性风险等，以提供该结论的经济直觉。

作者回复：

感谢审稿专家提出的宝贵建议，ConvLSTM 模型确实考虑到多个基金的横截面层面信息，这是模型的优势所在。我们已在 4.1 节和 6 节结论部分补充横截面关联的理论解释，以下是修改部分。

ConvLSTM 考虑时间序列信息之外的横截面信息，不仅能提升预测精度，从经济逻辑

看也具有意义。首先，基金净值波动并非孤立存在，不同基金可能因行业相关性或基金经理的趋同交易行为呈现羊群效应，抑或共同暴露于如 Mkt-RF 所反映的市场系统性风险，这些横截面关联会导致基金净值呈现联动特征。ConvLSTM 通过同时捕捉时序列上的动态趋势与横截面层面的相互影响，既能识别单只基金的个体波动规律，又能纳入多基金关联效应对净值的驱动作用，从而在预测中更贴近实际市场运行逻辑。

.....

6 结束语

通过人工智能算法的深度应用，FOF 能够更精准地进行资产配置与投资决策。这不仅优化了投资管理流程，显著提升了运作效率，还进一步增强了其应对金融市场复杂性与不确定性的能力。在金融高质量发展的新时代背景下，FOF 将借助金融科技，为投资者创造更为稳健和长期的价值回报，也为整个金融服务体系的完善与创新贡献了积极力量。

传统的时间序列预测模型 RNN 和 LSTM 在独立建模时会造成计算冗余，而共享参数会忽略基金异质性，难以满足多基金联合预测需求。本文将时空序列预测 ConvLSTM 模型引入该领域，以 326 只普通股票型和偏股混合型基金为研究样本，构建时空维度的多基金净值预测框架，通过卷积层捕获基金间空间关联，通过 LSTM 层捕捉时序规律。考虑空间特征不仅优化了预测效率问题，也具有其经济意义，即 ConvLSTM 的时空建模既能识别单只基金的时序波动规律，又能纳入多基金关联效应对净值的驱动作用。

【意见 3】

论文公式或图表有一些细节没有解释清楚，建议补充。比如，公式（2）至（6）后面段落的变量说明应当提前，因为在图 3、图 4 中已有相应变量。比如，公式（7）最小方差策略是不是在给定收益率的基础上，再最小化组合方差？公式（9）的组合方差 sigma 是否缺少脚标？比如，公式（17）分母中 ybar 没有具体解释，样本外 R2 高达 90% 应该和 ybar 的选取有很大关系。比如，图 5 左侧底部“基金单位净值序列”和右侧底部“基金月度收益率序列”之间的关系是什么，需要解释清楚。比如，图 9 把基金平均分为 5 组，没有说明分组的依据。

作者回复：

感谢审稿专家提出的宝贵建议。我们已经将图 3 和图 4 中出现的模型结构变量在图像介绍部分进行说明，以下是修改部分。

ConvLSTM 引入了空间上的卷积操作和时间上的循环操作，保留了 LSTM 中的记忆单元和门控机制，能够考虑到时序数据的长期依赖性和空间结构的局部相关性。图 3 展示了 ConvLSTM 模型中 ConvLSTM 单元的信息传递机制，空间特征随着每层的卷积结构被逐步编码纵向传递，时间维度信息沿着时间顺序横向传递。其中， $H_t \in \mathbb{R}^{M \times d}$ 表示 t 时刻的隐藏状态， $C_t \in \mathbb{R}^{M \times d}$ 表示 t 时刻的记忆细胞状态， d 是隐藏层维度， X_t 是 t 时刻的模型输入， $\hat{X}_t$ 是 t 时刻的模型输出。




图3 ConvLSTM 模型时空信息传递图

最小方差策略我们并未给定收益率，直接通过最小化投资组合的方差实现优化，已经在文章中添加说明。

2 资产配置策略

2.1 最小化方差策略

MV 策略在市场大幅波动的时候往往能够提供避险效果，因此受到投资者的关注，但实践中容易出现极端组合权重，导致风险过度集中，违背了风险分散化的理念。本研究采用无预设收益率目标的 MV 策略，即该策略不预设目标收益率，而是直接通过最小化投资组合的方差 σ_p 实现优化，核心逻辑是在所有可能的资产组合中，寻找总风险（方差）最低的组合，公式表示如下：

$$\min_w \frac{1}{2} w^T \Sigma w. \quad (7)$$

其中， w 为基金组合中各基金的权重向量， Σ 为基金收益率的协方差矩阵。

感谢您的指正！我们在公式（9）添加了 sigma 的脚标。

其中，RP 策略要求所有单个资产的 TRC 相等，即满足以下条件：

$$w_i \frac{\partial \sigma_p}{\partial w_i} = w_j \frac{\partial \sigma_p}{\partial w_j}, \forall i, j. \quad (9)$$

图 5 左侧底部“基金单位净值序列”到右侧底部“基金月度收益率序列”是通过公式计算得到的，即模型预测的单位净值序列得到月度收益率序列，是根据新增的公式（13）进行计算的，这一部分计算方法已经添加。

具体而言，本研究采用滑动窗口法进行模型的滚动训练与预测，并将样本划分为训练集和测试集，其中训练集占样本总时长的 90%，测试集占 10%，以此保障模型训练与评估的有效性。具体实施过程如下（如图 5(a)所示）：设定训练集时间跨度为 τ 个月，测试集预测时间跨度为 h 个月，模型输入采用时间步长为 J 个月的历史数据，输出为未来 K 个月的全样本基金净值预测值。根据研究设计，本文取 $\tau = 84$ ， $h = 23$ ， $J = 3$ ， $K = 1$ ，即每次预测

测试集未来 1 个月的基金净值，预测时使用前 3 个月的历史数据作为输入（如图 6(b)所示）。通过 23 次连续的窗口滑动，最终获得测试集连续 23 个月的完整预测结果 $[\hat{y}_1, \dots, \hat{y}_h]$ ，其中 $\hat{y}_i \in \mathbb{R}^{M \times 1}$ ，涵盖全部 $M = 326$ 只样本基金。基于净值预测结果，可以进一步计算收益率预测序列，具体而言，第 t 月 M 只基金的收益率 $\hat{r}_t$ 计算公式为：

$$\hat{r}_t = \frac{\hat{y}_t - \hat{y}_{t-1}}{\hat{y}_{t-1}} \times 100\%, \quad (13)$$

其中， $t=2, 3, \dots, h$ 。由此，从 23 个月的净值预测序列中可衍生出长度为 $l=22$ 的收益率预测序列 $[\hat{r}_1, \hat{r}_2, \dots, \hat{r}_l]$ ，用于后续的基金组合构建与绩效评估。

公式（18）即原公式（17）的 $\bar{y}_t$ 表示测试集中基金复权单位净值真实值的均值，已经添加具体解释。

其中， y_t 和 $\hat{y}_t$ 分别表示第 t 时刻基金复权单位净值的真实值和预测值， $\bar{y}_t$ 表示测试集中基金复权单位净值真实值的均值， h 表示样本数量，在本文中， $h=23$ 。

图 9 将基金平均分为 5 组，是根据每个月度预测收益率进行划分的，以下是修改内容。

对历史数据进行滚动预测，可以逐期得到基金的收益率，为了考察 ConvLSTM 对优质基金的筛选能力，本文对样本外基金月度收益率预测结果进行分组检验，每期均按照该期基金收益率预测值从高到低排序，将全部基金平均分为 5 组，其中组 1 为预测收益率最高的基金组合，组 5 为预测收益率最低的基金组合，逐期计算组内累计净值收益表现。如图 9 所示，五组累计净值曲线呈现出显著的单调性且没有交错现象，表明 ConvLSTM 有良好的子基金筛选效果。

【意见 4】

论文在构建投资组合时是否有考虑交易成本。一般来说，基金交易成本本身不低，FOF 由于双重收费问题成本更高。如果有，可以适当考虑，进而修改投资组合结果；如果没有，也可以在文中说明不考虑交易成本的原因。

作者回复：

感谢您的提问！本文的考虑是，FOF 的“双重收费”一般是指投资者在投资 FOF 产品时，可能同时承担两层费用：即投资者投资 FOF 时的一层申购费、赎回费，以及 FOF 买卖子基金时可能产生的二层申赎费等，因为本文研究只是“买卖子基金”，不涉及申购和赎回其他 FOF 产品，也不考虑 FOF 产品运作阶段的管理费和托管费的叠加，因此不存在双重收费。同时，构建基金组合的确需要考虑交易成本，本问题已经在第一份外审评议的【意见 3】中有所解答。

参考文献

- [1] 柏凤山,迟国泰,温武军.基于 LSTM 和多头注意力机制的企业违约预测模型[J].管理工程学报,2024,38(3):213-226.
- [2] 陈晓红,肖粲然,刘咏梅.基于可解释深度学习的碳交易价格驱动因素研究[J/OL].系统工程理论与实践,1-17[2025-08-11].<https://link.cnki.net/urlid/11.2267.N.20250515.2028.090>.

- [3] 陈晓非.基于深度学习的智能投顾基金组合配置研究[D].北京:北京交通大学,2022.
- [4] 迟国泰,王珊珊.基于 XGBoost 的中国上市公司违约风险预测模型[J].系统管理学报,2024,33(3):735-754.
- [5] 高鹤,李旻文,高峰.基金经理风险偏好、投资风格与基金业绩——基于性别个人特征的视角[J].投资研究,2014,33(5):82-96.
- [6] 李仁宇,叶子谦.基于机器学习的基金收益预测[J].统计与决策,2023,39(11):156-161.
- [7] 李星毅,李仲飞,李其谦,等.基于机器学习的资产收益率预测研究综述[J].中国管理科学,2025,33(1):311-322.
- [8] 李仲飞,周骐.一个基于 BL 模型和复杂网络的行业配置模型[J].中国管理科学,2024,32(4):1-13.
- [9] 刘博,王明烁,李永,等.深度学习在时空序列预测中的应用综述[J].北京工业大学学报,2021,47(8):925-941.
- [10] 沈红波,洪康隆,王锴.基金经理语调、基金收益与投资者行为——基于 BERT 人工智能模型的检验[J].现代金融研究,2025,30(4):20-38.
- [11] 史代敏.我国证券投资基金投资业绩的实证分析[J].管理现代化,2000(6):52-55.
- [12] 宋正阳,周忠宝,余乐安,等.基于混合集成预测算法和 Black-Litterman 模型的投资组合优化策略研究[J/OL].中国管理科学,1-12[2025-08-11].<https://doi.org/10.16381/j.cnki.issn1003-207x.2023.1895>.
- [13] 杨炘,王小征.中国证券投资基金业绩评价因素模型实证研究[J].系统工程理论与实践,2003(10):30-35.
- [14] 赵琪,徐维军,季昱丞,等.基于卷积神经网络的财务困境预测:公司财报的图像化[J].管理工程学报,2025,39(1):46-62.
- [15] 张学勇,张琳.大类资产配置理论研究评述[J].经济学动态,2017(2):137-147.
- [16] 周仁才.融合机器学习算法的期权定价[J].系统管理学报,2022,31(3):476-485.
- [17] 周志华,李沐.机器学习[M].北京:清华大学出版社,2016.
- [18] Banz R W.The relationship between return and market value of common stocks[J].Journal of Financial Economics,1981,9(1):3-18.
- [19] Barberis N,Greenwood R,Jin L,et al.X-CAPM: an extrapolative capital asset pricing model[J].Journal of Financial Economics,2015,115(1):1-24.
- [20] Bao W,Yue J,Rao Y.A deep learning framework for financial time series using stacked autoencoders and long-short term memory[J].PLoS ONE,2017,12(7):e0180944.
- [21] Chen X,Zhang Y,Wang L,et al.Deep learning for cross-market asset pricing: a comparative study of LSTM and attention mechanisms[J].Journal of Financial Economics,2022,145(3):789-815.
- [22] Clarke R,De Silva H,Thorley S.Minimum-variance portfolio composition[J].Financial Analysts Journal,2013,69(2):49-66.
- [23] Dalio R,Prince E,Jensen G.Risk parity in the era of monetary policy uncertainty[J].Journal of Portfolio Management,2021,47(4):7-21.
- [24] DeMiguel V,Garlappi L,Uppal R.Optimal versus naive diversification: how inefficient is the 1/N portfolio strategy?[J].Review of Financial Studies,2009,22(5):1915-1953.
- [25] DeMiguel V,Gil-Bazo J,Nogales F J,et al.Machine learning and fund characteristics help to select mutual funds with positive alpha[J].Journal of Financial Economics,2023,150(3):103737.
- [26] DeMiguel V,Gil-Bazo J,Nogales F J,et al.The predictive power of characteristic-sorted factors in mutual fund returns[J].Review of Financial Studies,2021,34(5):2439-2483.
- [27] DeMiguel V,Gil-Bazo J,Nogales F J,et al.A transaction-cost perspective on the predictability of mutual fund returns[J].Journal of Financial Economics,2021,142(2):735-756.

- [28] Ding X,Zhang Y,Liu W.LSTM-based forecasting for the CSI 300 index: a comparative study with traditional time series models[J].Pacific-Basin Finance Journal,2021,68:101591.
- [29] Fama E F,French K R.A five-factor asset pricing model[J].Journal of Financial Economics,2015,116(1):1-22.
- [30] Kaniel R,Lin Z,Pelger M,et al.Machine-learning the skill of mutual fund managers[J].Journal of Financial Economics,2023,150(1):94-138.
- [31] Li X,Wang Y,Chen Z.Integrated gradients meets attention: a novel interpretation framework for stock price prediction[J].Journal of Financial Econometrics,2023,21(2):345-367.
- [32] Shi X,Chen Z,Wang H,et al.Convolutional LSTM network: a machine learning approach for precipitation nowcasting[C]//Advances in Neural Information Processing Systems 28 (NIPS 2015),2015:802-810.
- [33] Zhang R,Liu H,Patel M.Beyond linear factor models: interpretable AI for fund performance attribution[J].Review of Asset Pricing Studies,2024,14(1):178-215.
- [34] Zhu Q M,Chen J F,Zhu L,et al.Wind speed prediction with spatio-temporal correlation: a deep learning approach[J].Energies,2018,11(4):705.




图 1 RNN、LSTM 与 ConvLSTM 模型预测机制的比较




图 2 时间序列预测与时空序列预测的比较




图 3 ConvLSTM 模型时空信息传递图




图4 ConvLSTM 模型卷积操作与内部结构图




图5 本文的FOF配置流程




图6 滑动窗口预测示意图




图 7 ConvLSTM 模型训练误差变化图像




图 8 三种模型误差评价指标时间演变图




图 9 分组检验累计净值曲线




图 10 ConvLSTM 样本外累计 IC 与月度 IC 图




图 11 ConvLSTM 样本外累计 RankIC 与月度 RankIC 图




图 12 ConvLSTM 模型特征重要性评估




图 13 预测特征在不同时间步上的贡献度演变




图 14 RNN (a) 与 LSTM (b) 的模型特征重要性评估




图 15 ConvLSTM 模型优选基金构建的 FOF 累计净值曲线