

采用门控循环单元与深度进化策略的股票指数量化模型

任晓萍^{1,2}, 陈志平¹

(1. 西安交通大学数学与统计学院, 710049, 西安;

2. 东北石油大学数学与统计学院, 163318, 黑龙江大庆)

摘要: 为了提高股票价格指数预测的准确性、增强统计建模性能优化与股票指数特征相依的交易策略效果,提出一种将指数预测与量化交易策略有效结合的门控循环单元深度进化量化模型(GRU-DES)。首先,建立循环神经网络(RNN)、长短期记忆神经网络(LSTM)和门控循环单元网络(GRU)预测模型,分别对上海证券交易所(上证)超大盘股票指数、上证中盘股票指数和上证小盘股票指数进行预测;接着采用所提出的深度进化量化模型(DES)对三大股票指数的预测值与真实值进行回测研究,通过比较预测结果与真实结果在同一策略下的各项回测指标和交易细节等特性确定最优网络结构和策略参数,进而优化深度进化策略;最后根据优化后的策略提出了GRU-DES模型,并再次对三大股票指数进行样本外数据回测来验证模型有效性。实证回测结果表明:所提出的GRU-DES模型在各量化回测指标上较LSTM-DES模型与RNN-DES模型的预测精度均高出14%以上,有效解决了统计预测指标的随机性和过拟合的问题;根据2016年至2024年7年间数据回测,所提出的GRU-DES模型比强化学习模型在各回测指标中均展现了稳定性和有效性。

关键词: 股票指数;量化模型;长短期记忆神经网络;门控循环单元;收益率

中图分类号: TP181 **文献标志码:** A

DOI: 10.7652/xjtuxb202502015 **文章编号:** 0253-987X(2025)02-0146-10

Quantitative Model for Stock Indexes Based on Gated Recurrent Unit and Deep Evolution Strategy

REN Xiaoping^{1,2}, CHEN Zhiping¹

(1. School of Mathematics and Statistics, Xi'an Jiaotong University, Xi'an, 710049, China;

2. School of Mathematics and Statistics, Northeast Petroleum University, Daqing, Heilongjiang 163318, China)

Abstract: To improve the prediction accuracy of stock price indexes and enhance the performance of statistical modeling and the design of quantitative trading strategy based on the characteristics of indexes, a quantitative model was proposed, which was based on gated recurrent unit and deep evolution strategy (GRU-DES) and effectively integrated index prediction with quantitative trading strategies. Firstly, RNN, LSTM, and GRU neural network predictive models were established to forecast the SSE mega cap, SSE mid cap and SSE small cap indexes, respectively. Next, the proposed DES model was employed to backtest the predicted values and true values of the three indexes. By comprehensively comparing the backtesting metrics and trading details of

收稿日期: 2024-05-23。 作者简介: 任晓萍(1988—),女,博士生;陈志平(通信作者),男,教授,博士生导师。

基金

项目: 国家重点研发计划资助项目(2022YFA1004001);国家自然科学基金资助项目(11991023)。

网络出版时间: 2024-10-24

网络出版地址: <https://link.cnki.net/urlid/61.1069.T.20241023.1419.009>

the predicted results with the true results under the same strategy, after determining the network structure and strategy parameters, the DES was optimized. Finally, the GRU-DES model was developed on basis of the optimized strategy, and the model effectiveness was verified through out-of-sample backtesting of these indexes again. The results show that the proposed GRU-DES model was 14% higher than the LSTM-DES model and RNN-DES model in backtesting metrics, effectively avoiding the randomness and overfitting problems of statistical prediction indexes. According to the backtesting results over 7 years from 2016 to 2024, the proposed GRU-DES model sufficiently demonstrates the stability and effectiveness in all backtesting metrics compared to reinforcement learning model.

Keywords: stock index; quantitative model; long short term memory; gated recurrent unit; returns

近年来,研究人员不断从量化策略和算法交易方面对量化投资进行优化,在资本市场风险增加、股票指数波动剧烈的背景下,急需将机器学习算法与深度学习算法应用到量化投资体系中。用混合方法生成交易信号也是近两年投资机构与量化学者研究的重点,如 Ayala 等^[1]结合机器学习算法与传统技术指标,分别测试了线性模型(LM)、人工神经网络(ANN)、随机森林(RF)和支持向量机回归算法(SVR)的性能,但交易策略上缺乏创新性。

近年来,不少学者结合机器学习和深度学习算法对个股价格进行预测,Wang 等^[2]构建了多元线性回归模型、最小绝对收缩和选择算子、SVR 算法、ANN 网络、循环神经网络(RNN)、长短时记忆神经网络(long short term memory, LSTM)、门控循环单元网络(gated recurrent unit, GRU)和双向门控循环单元网络(bidirectional GRU, Bi GRU) 8 个单项模型,虽然实验数据充足,但模型性能评价标准仍是传统统计计算标准。Peng 等^[3]采用 LSTM 网络和 Transformer 模型对中国 A 股市场的银行股价进行预测,使用集成经验模态分解方法对股票指数降噪后进行预测,降噪与预测相结合的研究方法可能会造成预测信息的缺失。Lind 等^[4]基于股票交易策略,对比分析了 LSTM 网络和 GRU 网络的优劣性。Sang 等^[5]结合了传统技术指标、简单移动平均指标(SMA)、相对强弱指标(RSI)与 LSTM 网络,通过实证表明技术指标相结合比单独使用可得到更好的预测效果。Kanwal 等^[6]提出了一种基于混合深度学习(DL)的预测模型,该模型结合了双向 Cuda 深度神经网络长短期记忆(Bi-Cu DNN-LSTM)和一维卷积神经网络(CNN),用于及时有效地预测股价,但模型没有经过样本外数据验证。Lv 等^[7]将股票指数分解为一系列从高频到低频排列的本征模态函数(IMF),将其输入深度自动编码器(DAE)去除冗余数据并提取深层特征,最后将高

层抽象特征输入 LSTM 网络,以预测下一个交易日的股票回报率。于孝建等^[8]使用 LSTM 网络对股票历史数据进行建模,同时从社交媒体、个股评论等文本数据中提取情感特征共同搭建股票预测模型;该模型可以对金融市场发生风险给出预警,但没有提出金融风险的应对策略。Liu 等^[9]提出了一个用于日内股市预测的包含 CEEMDAN、Entropy 和带历史注意力的门循环单元网络(GRU-HA)的四阶段混合(CEGH)模型。文献[3,7,9]将股票交易数据去噪后进行预测,而预测准确度的提升主要是依靠因去噪而平滑的交易数据,并没有在预测算法上进行创新。以上研究只依靠统计指标评估股票价格预测的精度,没有从量化交易的角度来验证预测的准确性。

另外,也有很多研究人员致力于利用新型神经网络进行金融资产定价。周章元等^[10]结合主成分分析法和注意力机制优化 LSTM 网络,对消费行业板块指数进行预测,文中只阐明了策略的有效性,并没有探讨模型预测效果的优劣。Bińkowski 等^[11]提出显著性偏移卷积神经网络(significance-offset convolutional neural network, SOCNN)和 RNN 网络的混合应用,Luo 等^[12]提出一种基于多循环 CNN-GRU 网络和注意力机制的甲醇价格预测方法;在模型构建中,设计了一种并行混合网络架构,模型框架上有一定的创新,但预测精度没有明显提升。Nourbakhsh 等^[13]将 CNN 网络和 LSTM 网络结合,并利用市盈率、盈利能力和公司交易次数等基本数据,提升股价趋势预测性能,但多网络结合在股票价格的预测上只有框架结构的创新,对不同时期的交易数据预测效果缺乏鲁棒性。

针对现有文献方法的不足,本文提出新的应对方案:① 简化对股票指数预测的过程,选用预测较好的算法分别进行预测对比;② 交易策略不选用传统的交易策略,而是采用加入具有网络结构的实时交易策略,即本文使用的深度进化策略(deep

evolution strategy, DES);③从交易的角度来验证预测的有效性,为预测与量化投资有效结合提供新的研究视角与框架。

1 GRU 网络

从现有研究中可知,循环神经网络存在梯度消失问题,无法解决输入数据的长期依赖关系。LSTM 作为一种特殊的循环神经网络,在处理长期依赖关系时消除了梯度消失问题;该网络通过维持一个能存储较长时序的状态来解决长期依赖关系,下一个状态由前一个状态计算得到。LSTM 网络结构包含:一个遗忘门,决定 t 时刻获得新数据后,存储在长期记忆中的信息的重要性;输入门,表示长期记忆更新方式;输出门,计算最近输入的短期记忆,同时记录更新后的长期记忆^[13]。

GRU 网络是简化版的 LSTM 网络,两者的主要区别在于 GRU 网络将 LSTM 网络中的遗忘门和输入门集成在一个更新门中,从而减少了参数,简化了计算过程,从而达到网络结构简化的目的。GRU 网络结合了时间序列单元的可见状态和隐藏状态,目前实证结果表明 GRU 网络在一定程度上加快了网络计算速度。

根据文献[12-14]中的金融预测方法的实证结果,为便于对照 LSTM 网络与 GRU 网络预测结果的准确度,本文激活函数全部选取 tanh 函数。GRU 网络的具体模型方程如下

$$\begin{cases} z_t = \varphi(\omega_z[x_t, y_{t-1}]) \\ g_t = \varphi(\omega_r[x_t, y_{t-1}]) \\ z'_t = \varphi(\omega'[x_t, g_t y_{t-1}]) \\ y_t = (1 - z_t)y_{t-1} + z_t z'_t \end{cases} \quad (1)$$

式中: z_t 为 t 时刻更新门状态; φ 为激活函数; ω_z 为更新门输入状态的权重; x_t 为 t 时刻输入序列; g_t 为 t 时刻重置门状态; ω_r 为重置门输入状态的权重; z'_t 为 t 时刻更新记忆状态; ω' 为更新记忆输入状态的权重; y_t 为 t 时刻最终状态。

2 深度进化策略

进化策略(evolution strategy, ES)算法被广泛应用于解决工程和统计研究问题,如车间调度问题^[15]、车辆自动泊车视域规划问题^[16]和高维数据特征识别^[17]问题等。目前,未见将进化策略应用于金融交易中。本文提出的深度进化策略(DES)是一种在 ES 算法上加入了无损失函数网络结构,可合理优化开仓、平仓的一种高频交易策略。DES 模型包含两个模块:①DES 模型训练过程,训练模型包

含输入层、隐藏层和输出层;②DES 模型决策交易过程。DES 模型包含 5 个初始参数,分别为:权重(ω)、奖励函数(r)、参与扰动种群大小(M_{pop})、权重更新参数(σ)和学习率(l_r)。

DES 模型的训练模块包括 3 个参数:窗口期、输入量和输出量,其训练过程通过不断执行指定迭代次数的循环完成训练。首先,初始化变量,在每个循环训练 epoch 中,随机生成种群后计算个体变异扰动值和个体更新权重,进行变异操作;接收新进入的数据序列后进行模型训练,计算交易策略权重。DES 模型的决策交易模块包含 3 个初始参数:初始价值(V_{ini})、每次迭代跳过的序列数(G)和状态空间(S_t)。决策过程如下:首先根据新进入数据的排序位置确定波动趋势状态,获取当前价格趋势状态后,按照窗口期设置的值提取价格序列中相应序列数的历史数据,进入第一个模块进行训练完成模型优化;然后根据优化后的模型计算出决策值(D), D 大于新进入的价格值将执行买入操作, D 小于新进入的价格值将进行卖出操作;最后,计算每次交易的收益率,并将其标准化,进行下一代模型的训练。决策过程连续接收优化训练后更新的交易策略权重,根据模型预测的动作执行决策操作;DES 模型通过逐渐优化神经网络的个体权重,从而提高模型的性能。由于 DES 模型属于高频策略范畴,因此本文只包含买入和卖出两种交易行动。

本文提出的 DES 模型训练和决策交易参数的更新分步计算过程如下。

步骤 1 模型个体权重的更新过程。根据种群中每一个个体 i 和预先设置的扰动强度 θ 参数进行扰动操作,计算最新一期的变异扰动值和更新增加扰动项后的权重

$$J_i = \theta i_i \quad (2)$$

$$\omega_i = \omega_{i-1} + J_i \quad (3)$$

式中: i_i 为种群中 t 时刻个体 i 的值; J_i 为 t 时刻最新一期变异指数扰动值; ω_i 为 t 时刻最新一期更新后的权重。

步骤 2 确定模型训练中 t 时刻交易策略使用的权重值

$$\omega_{\text{tr},t} = \omega_t + \frac{l_r}{M_{\text{pop}}\sigma} \sum_{i=1}^{M_{\text{pop}}} J_{i,t} P_i \quad (4)$$

式中: M_{pop} 为参与扰动的样本数; σ 为权重更新参数; l_r 为学习率可控制更新步长; $J_{i,t}$ 为第 i 个样本 t 时刻扰动值; P_i 为第 i 个样本奖励值。

步骤 3 将收盘价格作为输入,计算策略连续状态空间的状态值

$$S_t = v_{\text{in}} \omega_{\text{tr},t} + \omega_{\text{tr},t-1} S_{t-1} \quad (5)$$

式中: v_{in} 为收盘价输入值。

步骤4 根据连续状态空间值,确定连续决策值

$$D = S_t \omega_{tr,t+1} \quad (6)$$

步骤5 DES奖励函数定义为给定权重下进行交易后的收益率

$$r = \frac{V_{dec} - V_{ini}}{V_{ini}} \times 100\% \quad (7)$$

式中: V_{ini} 为执行决策后账户的价值; V_{dec} 为执行决策后账户的价值。

与传统梯度下降等优化方法相比,DES模型无需手动设计损失函数,没有梯度下降过程,这使得DES模型更加简约、高效。DES模型的工作流程如图1所示。




图1 DES模型工作流程图

Fig. 1 DES working flowchart

3 GRU-DES精度检验

3.1 模型预测检验指标

采用传统的统计预测精度指标均方根误差(root mean squared error, E_{RMSE})和平均绝对百分比误差(mean absolute percentage error, E_{MAPE})来评价模型精确度,在模型拟合效果上选择多输出的决策系数 R_{vw}^2 , 3个评价模型指标表示为

$$E_{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \quad (8)$$

$$E_{MAPE} = \frac{1}{m} \sum_{i=1}^m \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\% \quad (9)$$

$$R_{vw}^2 = \frac{\sum_{j=1}^m \text{var}(y_j) R_j^2}{\sum_{j=1}^m \text{var}(y_j)} \quad (10)$$

式中: m 为变量的数量; n 为样本的个数; y_i 为第 i 个输出; $\hat{y}_i$ 为第 i 个输出估计值; R_j^2 为第 j 个输出的 R^2 值; $\text{var}(y_j)$ 为第 j 个输出的数学方差。

3.2 量化策略回测指标

文献[18-19]中使用投资组合中各股票收益率的

线性加权作为投资策略优劣的标准。文献[20]使用年化收益率、阿尔法、夏普比值、波动率、胜率、最大回撤比率、信息比率等回测指标对预测建模方法进行评估。在现有文献启发下,本文从量化投资角度出发,通过结合投资策略的回测结果衡量模型的预测精准度,投资策略回测结果的评估包含以下几个指标。

(1)日收益率表示为

$$r_a = \frac{V_{a,t}}{V_{a,t-1}} - 1 \quad (11)$$

式中: $V_{a,t}$ 为第 t 日投资账户价值。

(2)年化收益率表示为

$$r_{an} = \left(\frac{V_{fin}}{V_{ini}} \right)^{\frac{252}{n}} - 1 \quad (12)$$

式中: V_{fin} 为最终账户价值。

(3)最大回撤比率(M_{DD}),反映了投资期间最大下跌幅度表示为

$$M_{DD} = \max \left(\frac{V_{roll} - V_{a,t}}{V_{roll}} \right) \quad (13)$$

式中: V_{roll} 为账户价值的累积最大值。

(4)夏普比值(R_{sh}),衡量投资者承受一单位的风险获得的超额回报表示为

$$R_{sh} = \frac{E(r_a - r_f)}{\sqrt{\text{var}(r_a - r_f)}} \quad (14)$$

式中: $E(r_a - r_f)$ 为超额收益率数学期望; r_a 为日收益率; r_f 为无风险收益率; $\text{var}(r_a - r_f)$ 为超额收益率数学方差。

(5)欧米茄比值(R_{om}),衡量投资组合收益分布情况表示为

$$R_{om} = \frac{\sum (r_a > r_{tar})}{\sum (r_a \leq r_{tar})} \quad (15)$$

式中: r_{tar} 为目标收益率。

(6)卡玛比值(R_{cal}),衡量投资组合风险调整后收益表示为

$$R_{cal} = \frac{r_{an}}{M_{DD}} \quad (16)$$

式中: r_{an} 为年化收益率; M_{DD} 为最大回撤比率。

(7)索提诺比值(R_{sor}),衡量投资者承受一单位的下行风险获得的超额回报表示为

$$R_{sor} = \frac{E(r_a)}{\sqrt{\text{var}(r_{neg})}} \quad (17)$$

式中: r_{neg} 为负日收益率。

4 实证分析

4.1 实证数据

上市公司流通市值大小和交易活跃度展现出不

同的指数变动特征。本文旨在对流通市值和交易活跃度综合指数进行对比研究。分别选取了上海证券交易所(以下简称上证)超大盘股票指数和上证中盘股票指数 2006 年 1 月 1 日至 2024 年 6 月 30 日的收盘价数据,上证小盘股票指数由于其上市日期限制,只能获取 2010 年 1 月 1 日至 2024 年 6 月 30 日的数据。最后,对于上证三大股票指数,本文采用 2016 年 1 月 1 日至 2024 年 6 月 30 日的日交易数据进行 DES-GRU 模型交易回测分析。本文所使用的数据来源于国泰安 CSMAR 数据库。

实证分为 3 个部分:①采用 RNN、LSTM 和 GRU 3 个网络预测模型分别对 2006 年 1 月 1 日至 2015 年 12 月 31 日的上证超大盘股票指数、上证中盘股票指数的日收盘价数据和 2010 年 1 月 1 日至 2022 年 12 月 31 日的上证小盘股票指数的日收盘价数据进行训练及预测;②将第一部分预测出的收盘价和相同指数同一时期的真实收盘价分别进行 DES 模型回测,对比研究预测价格和真实价格回测结果及交易细节的差别,确定最优网络结构和策略参数;③根据优化出的 GRU-DES 模型对样本外数据 2016 年 1 月 1 日至 2024 年 6 月 30 日 7 年间上证大盘指数、上证中盘股票指数和上证小盘股票指数进行模型验证,以进一步彰显本文所提出模型的优势。

4.2 预测模型对比

基于文献[20-25]中对相关预测网络模型的对比研究结果,本文选用预测效果较好的 3 个网络模型 RNN、LSTM 和 GRU 进行对比研究,为了确定适合它们的最优层次网络结构,每个模型分别对层数为 1、2、3、4 的隐藏层(记为 GRU-1 层~GRU-4 层)进行网络训练。具体地,将 3 个模型分别用于上证超大盘股票指数。上证中盘股票指数和上证小盘股票指数的预测。本文所选的数据以 2016 年初证券市场熔断政策出现为分界点,上证大盘指数和上证中盘股票指数使用 2006 年 1 月 1 日至 2015 年 12 月 31 日,共 2 427 条交易数据,其中 1 492 条训练数据和 485 条测试数据个交易日数据,上证小盘股票指数编制日期较短,所以使用 2010 年 1 月 1 日至 2022 年 12 月 31 日,共 3 153 个交易日的数据,其中 2 502 条训练数据和 630 条测试数据。表 1 所示为各个模型预测结果的均方根误差,表 2 所示各个模型预测结果的平均绝对百分比误差,表 3 所示各个模型的决策系数,依据均方根误差值、平均绝对百分比误差最小和决策系数最接近 1 的原则,选择各模型的最优层次网络结构。由于 3 个模型训练结果图类似,限于篇幅本文只展示 GRU 模型对上证超大盘股票指数的最优预测结果,效果图如图 2 所示。

表 1 RNN、LSTM 和 GRU 网络模型预测结果的均方根误差对比

Table 1 RMSE prediction outcomes of RNN、LSTM and GRU

模型	均方根误差		
	超大盘	中盘	小盘
GRU-1 层	0.001 17	0.047 93	0.002 10
GRU-2 层	0.000 93	0.009 53	0.006 61
GRU-3 层	0.000 38	0.010 41	0.003 61
GRU-4 层	0.000 70	0.007 05	0.001 54
LSTM-1 层	0.004 96	0.013 56	0.002 57
LSTM-2 层	0.001 62	0.010 76	0.002 86
LSTM-3 层	0.000 53	0.013 99	0.002 68
LSTM-4 层	0.000 77	0.021 16	0.004 23
RNN-1 层	0.006 09	0.016 25	0.001 90
RNN-2 层	0.002 32	0.006 24	0.002 90
RNN-3 层	0.014 19	0.022 93	0.010 18
RNN-4 层	0.057 45	0.007 76	0.011 80

表 2 RNN、LSTM 和 GRU 网络模型预测结果的平均绝对百分比误差对比

Table 2 MAPE prediction outcomes of RNN、LSTM and GRU

模型	平均绝对百分比误差/%		
	超大盘	中盘	小盘
GRU-1 层	0.051 91	0.152 99	0.021 93
GRU-2 层	0.041 48	0.043 02	0.035 35
GRU-3 层	0.033 36	0.040 22	0.034 86
GRU-4 层	0.046 09	0.034 66	0.003 61
LSTM-1 层	0.091 08	0.059 64	0.032 05
LSTM-2 层	0.064 77	0.050 29	0.031 38
LSTM-3 层	0.074 92	0.059 82	0.035 95
LSTM-4 层	0.075 94	0.077 70	0.039 44
RNN-1 层	0.067 42	0.053 13	0.026 25
RNN-2 层	0.058 34	0.044 25	0.027 41
RNN-3 层	0.107 62	0.055 38	0.045 40
RNN-4 层	0.279 26	0.063 60	0.036 43

表 3 RNN、LSTM 和 GRU 网络模型的决策系数对比

Table 3 R^2 fitting effect of RNN, LSTM and GRU

模型	决策系数		
	超大盘	中盘	小盘
GRU-1 层	0.98	0.72	0.95
GRU-2 层	0.98	0.98	0.92
GRU-3 层	0.96	0.96	0.90
GRU-4 层	0.97	0.96	0.90
LSTM-1 层	0.96	0.94	0.93
LSTM-2 层	0.96	0.95	0.89
LSTM-3 层	0.94	0.93	0.86
LSTM-4 层	0.94	0.89	0.85
RNN-1 层	0.97	0.95	0.92
RNN-2 层	0.97	0.96	0.93
RNN-3 层	0.95	0.95	0.82
RNN-4 层	0.67	0.94	0.88

由表 1、表 2 和表 3 可以观察到:① GRU 模型的 4 个层次预测结果较稳定,均方根误差和平均绝对百分比误差都是最小,对三大股票的预测精度最高,并且模型的拟合效果都较好;② LSTM

模型的整体预测能力较弱,预测精度与模型拟合效果基本一致;③ RNN 模型也展示出较好的预测准确性,但预测结果的稳定性和模型拟合效果较弱。




图 2 基于 GRU 模型的上证超大股票指数预测结果

Fig. 2 Shanghai stock exchange (SSE) mega cap stock index forecast results based on GRU model

4.3 GRU-DES 精度分析

本文用 DES 模型对 4.2 节中 RNN、LSTM 和 GRU 这 3 个模型预测的三大股票收盘价和同一时期真实收盘价格进行量化策略回测。这里上证超大股票指数和上证中盘股票指数预测了 484 期,对应交易日期为 2013 年 10 月 16 日至 2015 年 12 月 30 日;上证小盘股票指数预测了 630 期,对应交易日期为 2020 年 6 月 1 日至 2022 年 12 月 31 日。GRU 模型的简化特点与高频策略 DES 模型的高效思想一致,DES 模型的参数根据收益最大化进行多次调整,选中扰动强度为为 0.1,学习率为 0.03;策略执行环境设置为:初始资金为 10 000 元,手续费比率为 0.000 1,数据频率为日数据,订单类型为市价单,无杠杆,不存在做空机制,回测期间无风险收益率与目标收益率均设置为 0。

GRU-DES 模型、LSTM-DES 模型、RNN-DES 模型与 DES 模型真实值回测的对比结果展示在表 4

中,显而易见:① GRU-DES 模型在年化收益率、最大回撤比率、卡玛比值和索提诺比值与真实回撤指标上保持高度一致,均比 RNN-DES 模型和 LSTM-DES 模型的预测精度高出 14% 以上;② LSTM-DES 模型回测效果与真实值差别最大,LSTM 模型在统计指标上预测效果也不佳,其中最大回撤比率、欧米茄比值、卡玛比值和索提诺比值变动区间较大,说明 LSTM-DES 模型明显没有识别出行情的波动,LSTM 模型预测存在随机性问题;③ RNN-DES 模型在小盘股票指数回测出高于真实值的年化收益率和较大回撤,说明预测的结果波动性大,导致在小盘股票指数计算与波动率相关的回撤指标中夏普比值、欧米茄比值、卡玛比值和索提诺比值更为接近真实回测值的现象,4.2 节中 RNN 模型从统计指标角度展现出优势,但 RNN-DES 模型明显与真实值回测结果相差较大,说明了 RNN 模型预测存在过拟合问题。

表 4 RNN-DES、LSTM-DES 和 GRU-DES 模型回测结果对比

Table 4 Back test outcomes comparison of RNN-DES、LSTM-DES and GRU-DES models

对比模型	规模	回测指标					
		年化 收益率/%	最大回撤 比率/%	夏普 比值	欧米茄 比值	卡玛 比值	索提诺 比值
GRU-DES	超大盘	54.55	1.46	3.96	12.80	37.26	24.73
	中盘	68.58	2.48	3.79	25.92	27.56	18.06
	小盘	24.51	2.74	3.47	5.71	8.95	9.64
LSTM-DES	超大盘	59.81	1.32	3.69	48.69	44.17	38.57
	中盘	74.29	0.67	2.82	63.08	110.56	39.43
	小盘	41.30	0.22	3.56	81.90	187.20	72.04
RNN-DES	超大盘	68.26	3.36	4.67	8.07	20.35	15.59
	中盘	70.97	3.44	3.95	7.31	20.31	12.34
	小盘	37.57	4.28	3.92	4.65	9.24	8.42
DES	超大盘	56.97	1.70	4.23	17.05	33.89	29.70
	中盘	67.93	2.95	2.83	11.03	22.99	17.41
	小盘	28.14	2.37	4.15	4.91	11.89	7.4

图 3 展示了各模型账户价值变动过程:①图中显示 GRU-DES 模型与真实值回测账户价值变动最




图 3 预测值与真实值回测的账户价值变动对比
Fig. 3 Back test account value comparison of predicted and actual values




图 4 2016 年 1 月 1 日至 2024 年 6 月 30 日上证三大股票指数 GRU-DES 模型回测账户价值
Fig. 4 GRU-DES model backtest account values of SSE three stock indexes from January 1, 2016 to June 30, 2024

为接近;②LSTM-DES 模型虽然在超大盘回测中账户价值与真实回测结果较为相近,但另外两个指数回测上表现出不稳定性;③策略回测期间上证中盘股票指数波动趋势明显,策略容易识别交易信号,导致 3 个模型从账户价值曲线中展现出相似的回测的效果。

4.4 GRU-DES 模型样本外验证

为了更准确验证本文优化后策略的盈利稳定性,这里从交易策略的样本外表现来进一步验证 GRU-DES 模型的优势。将 GRU-DES 模型应用于 2016 年 1 月 1 日至 2024 年 6 月 30 日上证三大股票收盘点位进行测试,同时测试了 3 个双强化学习模型 Double-Duel Q learning、Duel Q learning 和 Double Q learning^[26-27]的交易结果,回测环境与上文训练期间相同,回测结果如表 5 所示,其中三大股票以“买入并持有策略”为基准。不难看出:本文提出的 GRU-DES 高频交易量化策略远优于 3 个强化学习算法策略和基准;虽然 Double-Duel Q learning 模型和 Double Q learning 模型有较高的欧米茄比率,说明这两个量化模型的胜率较高,盈亏比率较低产生较大回撤,但 GRU-DES 模型各回测指标在三大股票上展现出稳定性。另外,样本外数据验证期间指数行情一直处于低位震荡中下行趋势,而模型训练期间指数处于趋势明显上行区间故样本外数据策略效果远低于训练期间回测效果,同时也说明 GRU-DES 模型在捕捉趋势中有一定优势和稳定性。GRU-DES 模型回测账户价值曲线和交易细节如图 4 和图 5 所示,从账户价值逐步上涨中可以观察到 GRU-DES 模型一直表现出稳定的收益。

最后,将 GRU-DES 量化模型应用于 2023 年 10 月 9 日至 2024 年 9 月 30 日上证三大股票指数收盘点位进行测试,回测结果如表 6 所示,可见 GRU-DES 模型所有回测指标都优于基准模型。

表 5 强化学习策略与 GRU-DES 模型回测结果对比

Table 5 Back test outcomes comparison of reinforcement learning strategies and GRU-DES model

对比模型	规模	回测指标					
		年化 收益率/%	最大回撤 比率/%	夏普 比值	欧米茄 比值	卡玛 比值	索提诺 比值
GRU-DES	超大盘	10.85	4.92	2.60	2.40	2.20	4.10
	中盘	12.92	6.89	2.29	2.40	1.87	3.44
	小盘	14.53	9.67	1.81	2.09	1.50	2.02
Dule Q learning	超大盘	1.70	16.50	0.22	1.19	1.03	0.35
	中盘	0.86	8.89	0.02	1.13	0.10	0.13
	小盘	0.49	25.54	0.03	1.05	0.02	0.06
Double-Duel Q learning	超大盘	−0.14	30.83	−1.76	22.07	0.00	1.85
	中盘	0.24	19.73	1.14	9.36	0.01	0.33
	小盘	3.50	21.98	1.36	31.67	0.16	3.60
Double QL	超大盘	3.37	23.70	1.75	10.26	0.14	1.24
	中盘	3.48	19.98	1.97	16.52	0.17	2.15
	小盘	4.76	32.67	1.15	2.16	0.15	0.07
基准	超大盘	0.01	45.73	0.04	1.00	0.02	0.06
	中盘	0.01	33.42	0.07	1.01	0.04	0.09
	小盘	−0.01	41.33	−0.03	0.99	−0.02	−0.04




图 5 2016 年 1 月 1 日至 2024 年 6 月 30 日上证三大股票指数 GRU-DES 模型交易细节

Fig. 5 GRU-DES model trading details of SSE three stock indexes from January 1, 2016 to June 30, 2024

表 6 GRU-DES 模型 2023 年 10 月 9 日至 2024 年 9 月 30 日上证三大股票指数的回测结果
Table 6 GRU-DES backtest outcomes of SSE three stock Indexes from October 9, 2023 to September 30, 2024

对比模型	规模	回测指标					
		年化 收益率/%	最大回撤 比率/%	夏普 比值	欧米茄 比值	卡玛 比值	索提诺 比值
GRU-DES	超大盘	18.70	2.73	3.97	4.62	7.22	7.88
	中盘	23.48	0.47	3.22	6.97	50.12	16.62
	小盘	36.37	0.92	3.66	9.66	41.97	19.37
基准	超大盘	11.52	13.68	0.66	1.13	0.84	1.51
	中盘	11.35	13.61	0.62	1.12	0.84	1.38
	小盘	4.83	19.50	0.22	1.04	0.25	0.44

5 结 论

本文同时考虑 RNN,LSTM 和 GRU 3 种神经网络模型,选取上证超大盘股票指数、上证中盘股票指数和上证小盘股票指数进行训练与回测,由此提出了 GRU-DES 模型并进行样本外数据验证,得出以下结论。

(1) 根据 3 个模型预测统计指标的对比结果,GRU 网络模型显示出一定的稳定性和精确性;LSTM 网络模型在预测统计指标上显示出预测效果较弱,模型预测精度与模型拟合效果一致;RNN 网络模型预测结果的稳定性和模型拟合效果较弱。

(2) 根据 GRU-DES、LSTM-DES 和 RNN-DES 量化模型回测结果的对比,GRU-DES 模型在各回测指标上,均比 RNN-DES 模型和 LSTM-DES 模型的预测精度高出 14%以上,说明神经网络与交易策略的结合可以有效解决统计指标的随机性和过拟合问题。

(3) 本文提出的 GRU-DES 模型与 Double Duel Q learning、Duel Q learning、Double Q learning 强化学习模型对比,在各回测指标中都表现出明显的优势。GRU-DES 模型将预测结果与动态交易策略有效结合,在预测过程中动态同步改进交易策略,同时交易策略又反过来印证预测结果。

参考文献:

[1] AYALA J, GARCÍA-TORRES M, NOGUERA J L V, et al. Technical analysis strategy optimization using a machine learning approach in stock market indices [J]. Knowledge-Based Systems, 2021, 225: 107119.

[2] WANG Jia, WANG Xinyi, WANG Xu. International oil shocks and the volatility forecasting of Chinese stock market based on machine learning combination models [J]. The North American Journal of Econom-

ics and Finance, 2024, 70: 102065.

[3] PENG Zongyu, GUO Peichang. A data organization method for LSTM and transformer when predicting Chinese banking stock prices [J]. Discrete Dynamics in Nature and Society, 2022, 2022(1): 7119678.

[4] LIN Zili, TIAN Fangyuan, ZHANG Weiqian. Evaluation and analysis of an LSTM and GRU based stock investment strategy [C]//Proceedings of the 2022 International Conference on Economics, Smart Finance and Contemporary Trade (ESFCT 2022). Dordrecht, The Netherlands: Atlantis Press, 2022: 1615-1626.

[5] SANG Chenjie, DI PIERRO M. Improving trading technical analysis with TensorFlow long short-term memory (LSTM) neural network [J]. The Journal of Finance and Data Science, 2019, 5(1): 1-11.

[6] KANWAL A, LAU M F, NG S P H, et al. BiCuD-NNLSTM-1dCNN: a hybrid deep learning-based predictive model for stock price prediction [J]. Expert Systems with Applications, 2022, 202: 117123.

[7] LV Pin, SHU Yating, XU Jia, et al. Modal decomposition-based hybrid model for stock index prediction [J]. Expert Systems with Applications, 2022, 202: 117252.

[8] 于孝建, 刘国鹏, 刘建林, 等. 基于 LSTM 网络 and 文本情感分析的股票指数预测 [J]. 中国管理科学, 2024, 32(8): 25-35.

YU Xiaojian, LIU Guopeng, LIU Jianlin, et al. Stock index prediction based on LSTM network and text sentiment analysis [J]. Chinese Journal of Management Science, 2024, 32(8): 25-35.

[9] LIU Yijiao, LIU Xinghua, ZHANG Yuxin, et al. CEGH: a hybrid model using CEEMD, Entropy, GRU, and history attention for intraday stock market forecasting [J]. Entropy, 2023, 25(1): 71.

[10] 周章元, 何小灵. 基于优化 LSTM 模型的股价预测方法 [J]. 统计与决策, 2023, 39(6): 143-148.

ZHOU Zhangyuan, HE Xiaoling. Stock price prediction method based on optimized LSTM model [J]. Sta-

tistics & Decision, 2023, 39(6): 143-148.

[11] BINKOWSKI M, MARTI G, DONNAT P. Autoregressive convolutional neural networks for asynchronous time series [C]//Proceedings of the 35th International Conference on Machine Learning. Chia Laguna Resort, Sardinia, Italy: PMLR, 2018: 580-589.

[12] LUO Shuang, NI Zhiwei, ZHU Xuhui, et al. A novel methanol futures price prediction method based on multicycle CNN-GRU and attention mechanism [J]. Arabian Journal for Science and Engineering, 2023, 48(2): 1487-1501.

[13] NOURBAKHS Z, HABIBI N. Combining LSTM and CNN methods and fundamental analysis for stock price trend prediction [J]. Multimedia Tools and Applications, 2023, 82(12): 17769-17799.

[14] LI Chengyu, QIAN Guoqi. Stock price prediction using a frequency decomposition based GRU transformer neural network [J]. Applied Sciences, 2023, 13(1): 222.

[15] KHURSHID B, MAQSOOD S. A hybrid evolution strategies-simulated annealing algorithm for job shop scheduling problems [J]. Engineering Applications of Artificial Intelligence, 2024, 133, Part A: 108016.

[16] ABOYEJI E T, AJANI O S, MALLIPEDDI R. Covariance matrix adaptation evolution strategy based on ensemble of mutations for parking navigation and maneuver of autonomous vehicles [J]. Expert Systems with Applications, 2024, 249, Part A: 123565.

[17] NEMATZADEH H, GARCÍA-NIETOJ, ALDANA-MONTES J F, et al. Pattern recognition frequency-based feature selection with multi-objective discrete evolution strategy for high-dimensional medical datasets [J]. Expert Systems with Applications, 2024, 249, Part A: 123521.

[18] LO A W, SINGH M. Deep-learning models for forecasting financial risk premia and their interpretations [J]. Quantitative Finance, 2023, 23(6): 917-929.

[19] 刘伟龙, 张永, 杨兴雨. 基于 LSTM 预测信息的在线融资融券组合交易策略 [J]. 系统工程理论与实践, 2024, 44(8): 2493-2508.

LIU Weilong, ZHANG Yong, YANG Xingyu. Online margin trading strategy based on LSTM prediction information [J]. Systems Engineering-Theory & Practice, 2024, 44(8): 2493-2508.

[20] 贺毅岳, 高妮, 韩进博, 等. 基于长短记忆网络的指数量化择时研究 [J]. 统计与决策, 2020, 36(23): 128-133.

HE Yiyue, GAO Ni, HAN Jinbo, et al. Research on the exponential quantitative timing based on long short term memory [J]. Statistics & Decision, 2020, 36(23): 128-133.

[21] 柴昱白, 陈伟, 赵舒欣, 等. 采用机器学习与二维伽马函数的股票指数量化交易策略 [J]. 西安交通大学学报, 2023, 57(5): 204-212.

CHAI Yubai, CHEN Wei, ZHAO Shuxin, et al. Quantitative trading strategy for stock index based on machining learning and 2D gamma function [J]. Journal of Xi'an Jiaotong University, 2023, 57(5): 204-212.

[22] 贺毅岳, 刘磊, 高妮. 基于 M-LSTM 的股票指数日内交易量分布预测研究 [J]. 运筹与管理, 2022, 31(10): 196-203.

HE Yiyue, LIU Lei, GAO Ni. Research on forecasting intraday trading volume of stock index based on M-LSTM [J]. Operations Research and Management Science, 2022, 31(10): 196-203.

[23] GUPTA U, BHATTACHARJEE V, BISHNU P S. StockNet-GRU based stock index prediction [J]. Expert Systems with Applications, 2022, 207: 117986.

[24] 蔡超, 何馨怡, 李丽. 大规模数据的分布式神经网络回归模型研究 [J]. 统计与决策, 2023, 39(17): 34-39.

CAI Chao, HE Xinyi, LI Li. Research on distributed neural network regression model for large-scale data [J]. Statistics & Decision, 2023, 39(17): 34-39.

[25] KU C S, XIONG Jiale, CHEN Y L, et al. Improving stock market predictions: an equity forecasting scanner using long short-term memory method with dynamic indicators for Malaysia stock market [J]. Mathematics, 2023, 11(11): 2470.

[26] NING B, LIN F H T, JAIMUNGAL S. Double deep Q-learning for optimal execution [J]. Applied Mathematical Finance, 2021, 28(4): 361-380.

[27] XU Hongfeng, CHAI Lei, LUO Zhiming, et al. Stock movement prediction via gated recurrent unit network based on reinforcement learning with incorporated attention mechanisms [J]. Neurocomputing, 2022, 467: 214-228.

(编辑 刘杨 陶晴)