

基于PCA-GARCH-LSTM模型的股价预测研究

姜敏, 张楚沂, 孙德山

(辽宁师范大学数学学院, 辽宁大连 116029)

摘要: 股市波动日益成为社会的焦点话题, 如何高效且准确地预测股票价格成为当前热门研究课题。为减少计算量并提高工作效率, 在预测前对股票数据采用降维技术, 同时考虑股票波动情况, 结合主成分分析(PCA)、广义自回归条件异方差(GARCH)和长短期记忆网络(LSTM)3种模型, 构建组合模型进行股价预测。为检验模型预测效果, 以上证指数和中证500指数为例, 对收盘价进行预测。对比实验结果表明, 该PCA-GARCH-LSTM组合模型的RMSE、MAE、MAPE值均小于其他对照模型, 证明了该模型预测的有效性。

关键词: PCA模型; GARCH模型; LSTM模型; 组合模型; 股价预测

DOI: 10.11907/rjtk.241669

开放科学(资源服务)标识码(OSID):

中图分类号: O212.4

文献标识码: A

文章编号: 1672-7800(2025)001-0043-06



Research on Stock Price Prediction Based on PCA-GARCH-LSTM Model

JIANG Min, ZHANG Chuyi, SUN Deshan

(School of Mathematics, Liaoning Normal University, Dalian 116029, China)

Abstract: The fluctuations in the stock market have increasingly become a focal topic in society, making the efficient and accurate prediction of stock prices a popular research area among scholars. To reduce computational load and improve work efficiency, dimensionality reduction techniques are applied to stock data prior to forecasting, while also considering stock volatility. This article combines three models: Principal Component Analysis (PCA), Generalized Autoregressive Conditional Heteroskedasticity (GARCH), and Long Short-Term Memory (LSTM) networks to construct a composite model for stock price prediction. To test the predictive performance of the model, this study takes the Shanghai Composite Index and the CSI 500 Index as examples to predict closing prices. Through comparative experiments, the RMSE, MAE, and MAPE values of the proposed PCA-GARCH-LSTM composite model are all lower than those of other models, indicating the effectiveness of the proposed model in prediction.

Key Words: PCA model; GARCH model; LSTM model; combination model; stock price prediction

0 引言

股票市场作为投资领域的重要组成部分, 具有较高的投资回报率, 但同时也伴随着显著的风险。股票价格受多种市场因素影响, 其涨跌通常呈现出波动性和不规则性。因此, 如何有效预测股票价格并提高预测准确性, 已成为学术界广泛关注的热门课题。近年来, 关于股票价格预测的研究积累了大量文献, 构建了多种预测股票走势与价格的组合模型, 并提供了丰富的理论依据和实验结果。

由于研究指标繁多, 增加了研究的复杂性, 并且数据集中部分指标之间可能存在相关性, 导致信息冗余现象。为此, 引入主成分分析法(PCA)对影响股票价格的多个指标进行筛选, 能够在尽量减少信息损失的前提下, 将多个指标转化为少数几个综合指标。如: 谢心蕊等^[1]提出了一种结合改进PCA的降维方法, 保证了主成分模型的信息容量, 同时减少了噪声干扰。蔡方中等^[2]基于BP神经网络, 结合主成分分析法和改进的果蝇优化算法(Improved Fruit Fly Optimization Algorithm, IFOA), 提出一种PCA-IFOA-BP神经网络的股票价格预测模型。袁文凯等^[3]基于PCA-

收稿日期: 2024-09-19

扫描二维码阅读全文:



基金项目: 辽宁省教育厅基本科研项目(LJKMZ20221424)

作者简介: 姜敏(1999-), 女, 辽宁师范大学数学学院硕士研究生, 研究方向为统计学习及其应用; 张楚沂(2000-), 女, 辽宁师范大学数学学院硕士研究生, 研究方向为统计学习及其应用; 孙德山(1970-), 男, 博士, 辽宁师范大学数学学院副教授、硕士生导师, 研究方向为统计学习及其应用。本文通讯作者: 孙德山。

BP神经网络模型研究了股价波动的影响因素,实验结果表明该模型具有较高的预测准确性。郭尚志等^[4]详细分析了PCA的降维原理,并将其应用于大数据的降维问题,取得了良好效果。

波动率作为反映市场波动的重要指标,能够为股价变动提供量化描述。因此,采用GARCH模型计算股票的波动率,已成为股票价格预测中的重要因素。万睿^[5]通过GARCH模型对沪深300指数的市场波动性进行了预测,结果表明,GARCH模型有助于提高股票市场预测准确性。李妍^[6]在研究非对称模型时发现,GARCH-M模型并不适合模拟中国上海证券市场的股价波动情况,而GARCH(1,1)模型的预测效果最佳。刘祺等^[7]使用ARIMA-GARCH模型进行建模,提取每日收益率的波动率,并将其纳入原有数据集中,构建组合模型进行预测。李姜悦等^[8]基于美国股市两类指数的日收盘价数据,运用GARCH类模型进行实证分析发现,APARCH(1,1)模型拟合的条件异方差能够更好地反映波动率变化。

神经网络因其能够从大量原始数据中提取高层次抽象特征,且无需依赖先验知识,而广泛应用于图像、语音及金融等领域。金融时间序列通常具有长期依赖性,因而具有记忆功能的循环神经网络(RNN)成为更合适的选择^[9]。为了解决RNN模型的不足,引入自循环的概念,长短期记忆网络(Long Short-Term Memory, LSTM)得以提出。曹超凡等^[10]在LSTM基础上结合CNN提取并输入数据特征,再将特征矩阵输入LSTM模型进行关联预测。邓德军等^[11]提出基于E-V-ALSTM混合深度模型的股票价格预测方法。李梦等^[12]针对股价数据的高噪声、非线性和非平稳性,提出LSTM-Wavelet模型用于股价预测,显著提高了预测精度。王文姣等^[13]以沪深300指数收盘价为预测对象,采用误差倒数变权组合预测法,对传统机器学习模型和LSTM模型进行加权组合,从而实现了更为精准的预测。

基于上述研究,本文构建了PCA-GARCH-LSTM组合预测模型,旨在降低计算量的同时提高股价预测精度,解决单一预测模型存在的部分局限性。该组合模型将被应用于上证指数和中证500指数的收盘价预测,以验证其预测效果。

1 研究方法

1.1 主成分分析模型(PCA)

主成分分析(Principal Component Analysis, PCA)是机器学习中的一种无监督的变量降维方法,主要用于对数据、图像的降维,加快对原始数据中价值信息的处理速度,降低数据复杂性,使得后续分析、可视化和模型构建更加便捷。

主成分分析模型基本步骤如下:①获取 m 条原始数据,其中每条数据均有 n 个评价指标,构造一个 $m \times n$ 的

原始数据矩阵,记为 X ;②标准化处理;③计算协方差矩阵,对标准化后的数据求其协方差矩阵,记为 R ,则: $R = \frac{X^T X}{m}$;④计算协方差矩阵的特征值和特征向量;⑤确定主成分个数。

1.2 广义自回归条件异方差模型(GARCH)

自回归条件异方差模型(Autoregressive Conditional Heteroskedasticity, ARCH)于20世纪末期被提出,广义自回归条件异方差模型(Generalized Autoregressive Conditional Heteroskedasticity, GARCH)是ARCH模型的扩展^[14]。GARCH模型的优点是能够预测股票未来波动性,提供对风险和不确定性的量化度量,以及捕捉金融时间序列数据中的非线性特征。GARCH模型的参数估计通常通过极大似然估计方法完成,通过选择适合的模型对数据的异方差性进行规范和评估。

若平稳序列满足如式(1):

$$\begin{cases} \varepsilon_t = \sqrt{h_t} \cdot v_t \\ h_t = \alpha_0 + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j} \\ v_t \sim iidN(0, 1) \end{cases} \quad (1)$$

其中, $\alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0, \sum_{i=1}^{\max(p,q)} (\alpha_i + \beta_j) < 1$, 则称该平稳序列服从GARCH(p, q)模型。

1.3 长短期记忆模型(LSTM)

长短期记忆网络(Long Short-Term Memory, LSTM)是一种特殊的循环神经网络,它引入了细胞状态的概念,采用门控机制,通过输出门、输入门和遗忘门3个门机构控制细胞状态,在处理复杂的时间序列尤其是拟合非线性部分数据时具有较大优势^[15-18]。LSTM的链式结构由记忆区块构成,如图1所示。

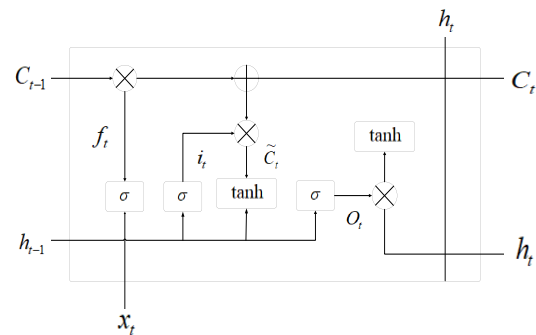


Fig. 1 Structure of LSTM memory unit

图1 LSTM记忆单元结构

其中: f_t 是遗忘门,用来控制“记忆细胞”历史状态的保留; σ 是Sigmoid函数,可以将所有激活值映射至0~1区间; i_t 是输入门,用来控制信息到细胞单元中的输入状态; o_t 是输出门,用来控制信息从细胞单元中的输出状态。

LSTM模型主要计算步骤如下^[19]:①在 t 时刻,通过查看 x_t 和 h_{t-1} 信息输出一个0~1区间的向量,计算遗忘门 f_t ;

②利用 x_t 和 h_{t-1} 计算输入门 i_t 决定更新部分信息;③利用 x_t 和 h_{t-1} 通过一个 \tanh 层得到新的待选细胞信息 \tilde{C}_t ;④更新旧的细胞信息 C_{t-1} 变为新的细胞信息 C_t ;⑤计算输出门 o_t ;⑥传入输出层,再经过计算后得到 LSTM 模型在 t 时刻的预测值 y_t 。

1.4 PCA-GARCH-LSTM 组合模型

1.4.1 组合模型基本步骤

PCA-GARCH-LSTM 组合模型^[20]基本步骤如下:①对原始数据进行预处理以保证数据的完整性和准确性;②利用主成分分析方法筛选得到综合指标;③通过 GARCH 模型处理原始数据得到股票波动率;④将主成分分析模型筛选出来的综合指标与由 GARCH 模型得到的股票波动率分成训练集和测试集,先将训练集输入 LSTM 模型进行训练,再对测试集进行预测;⑤比较预测效果。

PCA-GARCH-LSTM 组合模型具体步骤如图 2 所示。

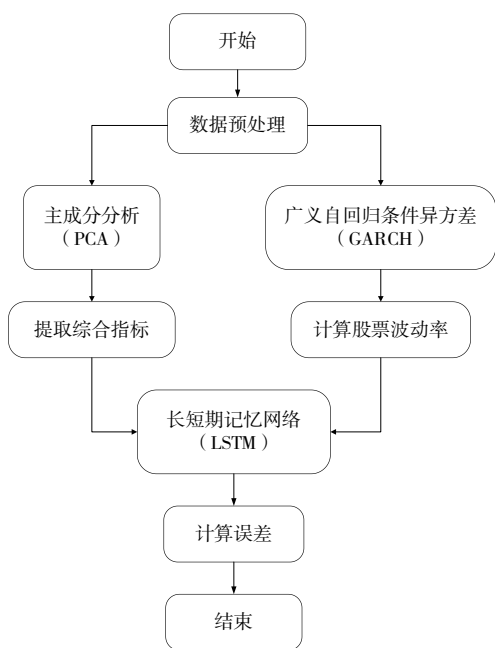


Fig. 2 Flow of the PCA-GARCH-LSTM combination model

图 2 PCA-GARCH-LSTM 组合模型流程

1.4.2 组合模型优势

股价预测的 PCA-GARCH-LSTM 组合模型相较于传统预测模型,具有以下显著优势:

(1)实现多角度信息融合。组合模型能够去除部分噪声和冗余信息,使模型专注于对股价影响最大的变量,同时还避免了处理高维数据带来的复杂性。通过结合波动率信息,组合模型可以更好地理解市场动荡状况,尤其是在市场剧烈波动时提供更精确的预测能力,捕捉股价的复杂变化模式,从而提高预测准确性。

(2)提高预测精度。组合模型能够获取多维度的市场信息,提供更全面的股价走势预测。理论上,相比于传统预测模型的输入变量,组合模型更能提升预测精度。同时,长短期记忆网络擅长捕捉复杂的非线性动态关系,将

综合指标与波动率输入模型后,能够学习到更为细致的模式。

(3)减少过拟合风险。传统预测模型由于输入数据过于复杂或包含噪声,往往会导致过拟合。组合模型能够有效过滤不相关的噪声变量,降低过拟合风险,同时提高泛化能力。波动率的引入有助于模型考虑到市场风险和波动情况,避免仅依赖开盘价等单一信息进行预测,从而增强模型稳健性。

(4)增强模型鲁棒性和适应性。组合模型结合不同数据来源,能够更好地适应市场的不同条件,特别是在波动较大的市场环境下,能够动态捕捉市场情绪变化,进一步增强预测的鲁棒性和适应性。与传统预测模型相比,组合模型在应对市场变化时更具灵活性和有效性。

综合来看,组合模型通过降维减少维度和噪声,结合波动率的市场波动信息,再将这些特征与综合指标一起输入长短期记忆网络进行训练,从多个角度捕捉股市的复杂动态。因此,它在股价预测中比传统预测模型具有更高的预测准确性、稳健性和适应性。

1.5 模型评价指标

为了评估 PCA-GARCH-LSTM 组合模型的预测效果,分别采用均方根误差 (RMSE)、平均绝对误差 (MAE) 和平均绝对百分比误差 (MAPE) 作为衡量模型预测效果的指标。指标计算公式如式 (2)~式 (4) 所示。

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

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{\hat{y}_i} \right| \times 100\% \quad (4)$$

2 实验与结果分析

2.1 数据选取与说明

本文选取了上证指数与中证 500 指数两类指数,所用数据集选取两类指数 2008 年 1 月 4 日至 2023 年 1 月 9 日共 3 650 个交易日数据,其中涉及的指标共 10 个,包括开盘价、收盘价、最高价、最低价、成交量、成交额、振幅、涨跌幅、涨跌额和换手率,分别称为指标 1—指标 10。最后 365 天数据作为检验预测效果的测试集,其余数据均为训练集。同时,实验设置对照组以检验组合模型预测效果,其中对照组选取了 PCA-LSTM 模型、LSTM 单一模型、ARIMA 模型、随机森林回归和 CNN 模型。

为防止量纲产生的影响,在实验前需要对 PCA 模型筛选得到的综合指标进行最大最小值归一化处理,计算公式如式 (5) 所示。

$$X_{std} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (5)$$

其中, X_{\min} 为数据集的最小值, X_{\max} 为数据集的最

大值。

2.2 模型环境与参数设定

本文实验基于Python3.7.6、TensorFlow1.14.0版本语言环境。在LSTM模型构建中,模型结构选择2层,分别为输入层和全连接层。优化器选择Adam,迭代次数为1000次,同时全连接层作为输出,选用默认激活函数,输出第二天的收盘价。

2.3 实证结果分析

2.3.1 上证指数数据集预测分析

对上证指数数据集进行归一化处理,并利用PCA模型得到各指标特征值,如图3所示。可以得出,在筛选的10个指标中,指标1、指标2和指标3所对应的特征值均大于1,指标4所对应的特征值接近于1。

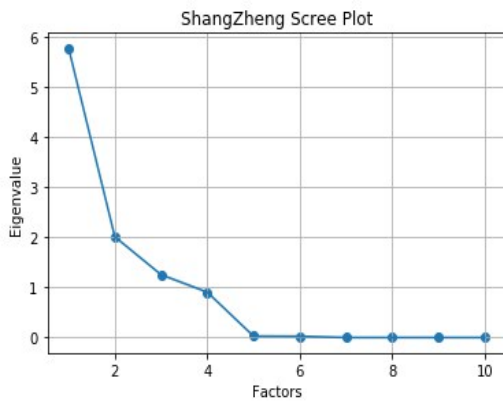


Fig. 3 Eigenvalues of the Shanghai composite index dataset

图3 上证指数数据集指标特征值图

查看10个指标所对应特征值的贡献度,如表1所示。可以得出,前4个指标所对应特征值的累计贡献度达到了0.99。因此,根据特征根法和累计贡献度,筛选出4个综合指标。

Table 1 Contribution degree of corresponding eigenvalues of indicators in the Shanghai composite index dataset

表1 上证指数数据集指标对应特征值贡献度

指标	贡献度	累计贡献度
1	0.577 44	0.577 44
2	0.201 06	0.778 50
3	0.125 46	0.903 96
4	0.090 54	0.994 50
5	0.002 54	0.997 36
6	0.000 06	0.999 90
7	0.000 02	0.999 96
8	0.000 01	0.999 98
9	0.000 01	0.999 99
10	0.000 01	1.000 00

根据上证指数中当日收盘价减去前一日收盘价可以得到每日回报,计算可得真实日收益率。同时,利用日收益率建立股票波动率的GARCH(1,1)模型,得到波动率方程并对波动率进行预测,得到预测波动率。将真实日收益率与预测波动率叠加绘图,如图4所示。可以得出,在预测波动率与真实日收益率基本已知的情况下,预测的股票

波动率高的地方,日收益率也高,两支曲线反映的趋势大致相同。




Fig. 4 Daily return and stock volatility of the Shanghai composite index dataset

图4 上证指数数据集日收益率与股票波动率

分别用PCA-GARCH-LSTM模型和对照组模型对测试集进行预测,计算不同模型的RMSE、MAE、MAPE值,结果如表2所示。可以得出,PCA-GARCH-LSTM组合模型的预测效果较好。

Table 2 Prediction error values of different models and intervals in the Shanghai composite index test set

表2 上证指数测试集不同模型不同区间预测误差值

模型	RMSE	MAE	MAPE
PCA-GARCH-LSTM模型	11.10	7.10	0.24
PCA-LSTM模型	16.60	10.98	0.35
LSTM模型	10.68	10.31	0.38
ARIMA模型	33.75	25.16	0.76
随机森林回归	27.23	22.59	0.68
CNN模型	8.86	8.76	0.26

为了更为直观地展示PCA-GARCH-LSTM的预测效果,对数据进行可视化,如图5所示。

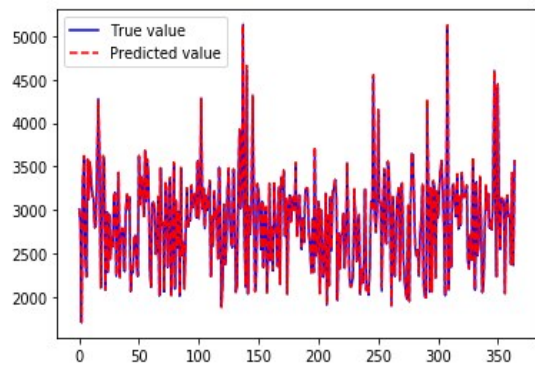


Fig. 5 Comparison between the true and predicted values of the Shanghai composite index test set

图5 上证指数测试集真实值与预测值对比图

2.3.2 中证500指数数据集预测分析

对中证500指数数据集进行归一化处理,并利用PCA模型得到各指标特征值,如图6所示。可以看出,在筛选的10个指标中,指标1、指标2和指标3所对应的特征值均大于1,指标4对应的特征值也接近于1。

查看10个指标所对应的特征值的贡献度,如表3所示。可以看出,前4个指标所对应特征值的累计贡献度达到了0.98。因此,根据特征根法和累计贡献度,筛选出4个综合指标。




Fig. 6 Eigenvalues of CSI 500 index dataset

图 6 中证 500 指数数据集指标特征值

Table 3 Contribution degree of corresponding eigenvalues of CSI 500 index dataset indicators

表 3 中证 500 指数数据集指标对应特征值贡献度

指标	贡献度	累计贡献度
1	0.613 59	0.613 59
2	0.200 58	0.814 17
3	0.108 40	0.922 57
4	0.065 69	0.988 26
5	0.006 90	0.995 16
6	0.004 77	0.999 93
7	0.000 03	0.999 96
8	0.000 02	0.999 98
9	0.000 01	0.999 99
10	0.000 01	1.000 00

利用日收益率建立股票波动率的 GARCH(1, 1)模型,得到波动率方程并对波动率进行预测,得到预测波动率。将真实日收益率与预测波动率叠加绘图,如图 7 所示。




Fig. 7 Daily return and stock volatility of the CSI 500 index dataset

图 7 中证 500 指数数据集日收益率与股票波动率

分别用 PCA-GARCH-LSTM 模型和对照组模型对不同预测区间的测试集分别进行预测,计算不同模型的 MAE、RMSE、MAPE 值,结果如表 4 所示。可以看出,PCA-GARCH-LSTM 组合模型的预测效果较好。

为了更为直观地展示 PCA-GARCH-LSTM 的预测效果,对数据进行可视化,如图 8 所示。

3 结语

本文对股票价格预测问题进行了探究,采用主成分分

Table 4 Prediction error values of different models and intervals in the CSI 500 index test set

表 4 中证 500 指数测试集不同模型不同区间预测误差值

模型	RMSE	MAE	MAPE
PCA-GARCH-LSTM 模型	29.57	20.42	0.40
PCA-LSTM 模型	34.81	23.20	0.49
LSTM 模型	32.06	27.88	0.52
ARIMA 模型	80.00	60.14	0.94
随机森林回归	154.46	130.39	1.96
CNN 模型	31.42	31.26	0.48




Fig. 8 Comparison between the true and predicted value of the CSI 500 index test set

图 8 中证 500 指数测试集真实值与预测值对比

析法提取综合指标,并将其与 GARCH 模型得到的股票波动率相结合,输入长短期记忆网络模型进行股价预测,取得了较好的预测效果。PCA-GARCH-LSTM 组合模型在金融时间序列预测中展现出了优异的泛化能力和学习能力,未来有望拓展应用至更多领域。同时,该组合模型也存在一些不足,例如模型结构较为复杂等,后续将继续对其进行改进和完善。

参考文献:

- [1] XIE X R, LEI X R, ZHAO Y. Application of MI and improved PCA dimensionality reduction algorithm in stock price prediction[J]. Computer Engineering and Applications, 2020, 56(21): 139-144.
谢心蕊,雷秀仁,赵岩. MI和改进PCA的降维算法在股价预测中的应用[J]. 计算机工程与应用, 2020, 56(21): 139-144.
- [2] QI F Z, LIN S Q, YU T T. Stock price prediction model based on PCA and IFOA-BP neural network[J]. Computer Applications and Software, 2020, 37(1): 116-121, 156.
慕方中,林少倩,俞婷婷. 基于PCA和IFOA-BP神经网络的股价预测模型[J]. 计算机应用与软件, 2020, 37(1): 116-121, 156.
- [3] YUAN W K, ZHOU Z T. Research on factors influencing stock price volatility based on PCA-BP neural network[J]. Business Exhibition Economy, 2023(10): 99-101.
袁文凯,周作涛. 基于PCA-BP神经网络的股价波动影响因素研究[J]. 商展经济, 2023(10): 99-101.
- [4] GUO S Z, LIAO X F, LI G, et al. PCA based big data dimensionality reduction application[J]. Computer Simulation, 2024, 41(5): 483-486.
郭尚志,廖晓峰,李刚,等. 基于PCA的大数据降维应用[J]. 计算机仿真, 2024, 41(5): 483-486.
- [5] WAN R. Prediction of stock price volatility based on GARCH model[J]. Technology News, 2022, 20(6): 129-132.

- 万睿. 基于GARCH模型的股价波动预测[J]. 科技资讯, 2022, 20(6): 129-132.
- [6] LI Y. Empirical study on the volatility of the Shanghai composite index based on GARCH family models [J]. Modern Business, 2014 (14) : 124-125.
李妍. 基于GARCH族模型的上证指数波动性实证研究[J]. 现代商业, 2014(14):124-125.
- [7] LIU Q, SHI S Z, LOU L, et al. Stock price prediction and decision-making based on ARIAM-GARCH deep learning [J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2024, 47 (1): 119-130.
刘祺, 施三支, 娄磊, 等. 基于ARIAM-GARCH深度学习的股价预测与决策[J]. 长春理工大学学报(自然科学版), 2024, 47(1):119-130.
- [8] LI J Y, SHEN C C, WANG W J. Comparative analysis of volatility in the US stock market based on GARCH models[J]. Business Development Economics, 2024(5):111-116.
李姜悦, 沈慈慈, 王伟杰. 基于GARCH类模型对美国股市波动性的对比分析[J]. 商展经济, 2024(5):111-116.
- [9] XIA J J, JIANG T. Research on financial risk warning based on RNN recurrent neural network: a case study of Anhui province [J]. Journal of Hubei University of Arts and Sciences, 2021(11):26-32.
夏佳佳, 姜涛. 基于RNN循环神经网络的金融风险预警研究——以安徽省为例[J]. 湖北文理学院学报, 2021(11):26-32.
- [10] CAO C F, LUO Z N, XIE J X. Research on stock price prediction of MDT-CNN-LSTM model [J]. Computer Engineering and Applications, 2022, 58(5): 280-286.
曹超凡, 罗泽南, 谢佳鑫. MDT-CNN-LSTM模型的股价预测研究[J]. 计算机工程与应用, 2022, 58(5):280-286.
- [11] DENG D J, XU H Z, WEI S Y. Stock price prediction of E-V-ALSTM model [J]. Computer Engineering and Applications, 2023, 59 (6) : 101-112.
邓德军, 徐洪珍, 韦诗玥. E-V-ALSTM模型的股价预测[J]. 计算机工程与应用, 2023, 59(6):101-112.
- [12] LI M, HUANG Z J, XU J H. Stock price prediction using LSTM-Wavelet model based on deep learning and wavelet analysis[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2023, 40(2): 99-105.
李梦, 黄章杰, 徐健晖. 基于深度学习和小波分析的LSTM-Wavelet模型股价预测[J]. 重庆工商大学学报(自然科学版), 2023, 40(2): 99-105.
- [13] WANG W J, ZHANG N. Stock price prediction based on LSTM variable weight combination model[J]. Trade Show Economy, 2023(7): 95-97.
王文姣, 张娜. 基于LSTM变权组合模型的股价预测[J]. 商展经济, 2023(7):95-97.
- [14] SHI J Q. Research and application of financial time series based on GARCH and neural network models [D]. Hangzhou: Zhejiang University of Technology, 2020.
施佳琴. 基于GARCH和神经网络模型的金融时间序列研究与应用 [D]. 杭州: 浙江工业大学, 2020.
- [15] SOMENATH M, BIKASH S, NAIRITA S, et al. Stock market prediction using deep learning algorithms [J]. CAAI Transactions on Intelligence Technology, 2023, 8(1):82-94.
- [16] SUN R Q. Research on the prediction model of US stock index price trends based on LSTM neural network [D]. Beijing: Capital University of Economics and Business, 2016.
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.
- [17] HU Y W. Stock prediction based on optimized LSTM model [J]. Computer Science, 2021, 48 (S1): 151-157.
胡聿文. 基于优化LSTM模型的股票预测[J]. 计算机科学, 2021, 48 (S1):151-157.
- [18] QIU D Y, DING L. Price prediction of Shanghai and Shenzhen 300 stock index futures based on multidimensional high-frequency data and LSTM model [J]. Journal of Chongqing University of Technology (Social Sciences), 2022 (3): 55-69.
邱冬阳, 丁玲. 基于多维高频数据和LSTM模型的沪深300股指期货价格预测[J]. 重庆理工大学学报(社会科学), 2022(3):55-69.
- [19] CI B C, ZHANG P Y. Financial time series prediction based on ARIMA-LSTM model [J]. Statistics and Decision Making, 2022, 38 (11) : 145-149.
次必聪, 张品一. 基于ARIMA-LSTM模型的金融时间序列预测[J]. 统计与决策, 2022, 38 (11):145-149.
- [20] ZHANG Y A, YAN B B. A deep learning composite prediction model for the stock market [J]. Computer Science, 2020, 47(11): 255-267.
张永安, 颜斌斌. 一种股票市场的深度学习复合预测模型[J]. 计算机科学, 2020, 47(11):255-267.

(责任编辑: 孙娟)