

文章编号: 2095-2163(2023)08-0100-08

中图分类号: TP391

文献标志码: A

基于BP神经网络和高阶模糊认知图的股票价格预测

王雨涵¹, 张亚萌², 魏国亮¹

(1 上海理工大学 管理学院, 上海 200093; 2 上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 由于金融市场具有的非线性、不确定性、复杂性等特点,其预测问题受到了学术界和相关从业人员的普遍关注。基于模糊认知图的方法广泛应用于金融市场预测,但大部分模型忽略了预测误差对模型精度的影响,针对这一现状本文提出了一种两阶段的预测模型,即基于BP神经网络(BPNN)和高阶模糊认知图(HFCMs)的股票价格预测模型,充分考虑了预测误差对预测精度的影响。模型第一阶段,利用HFCMs模型对历史数据进行预测,并得到与之对应的误差数据集。第二阶段结合了HFCMs模型和BPNN误差预测模型,得到最终的预测结果。其中,HFCMs模型的最佳权重矩阵采用时间变化加速系数粒子群优化(TVAC-PSO)算法得到。最后,在5个金融数据集上对所提模型进行了实验,结果表明本文的模型具有更好的预测效果。

关键词: 高阶模糊认知图; BP神经网络; 金融时间序列; 预测; 误差

Stock price prediction based on BP neural network and high-order fuzzy cognitive map

WANG Yuhan¹, ZHANG Yameng², WEI Guoliang¹

(1 Business School, University of Shanghai for Science and Technology, Shanghai 200093, China; 2 School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

[Abstract] The problem of financial market forecasting has been an important issue of considerable interest to academics and related practitioners. Due to the nonlinearity, uncertainty and complexity of financial markets, fuzzy cognitive maps have been proposed and applied to financial market forecasting. However, most of the models based on fuzzy cognitive maps ignore the influence of historical data prediction errors on model accuracy. The paper proposes a new prediction model for this situation, a stock price prediction model based on back propagation neural network and high-order fuzzy cognitive maps, which fully considers the influence of prediction error on prediction accuracy. First, the HFCMs model is used to forecast historical data and obtain the error data set corresponding to it, which is used as the basis for constructing the BPNN error prediction model. Then, the final prediction results are obtained by combining the HFCMs model and the BPNN error prediction model. Among them, the optimal weight matrix of the model is obtained using the time-varying accelerated coefficient particle swarm optimization (TVAC-PSO) algorithm. Finally, experiments are conducted on the proposed model on five financial datasets, and the results show that the proposed model has higher prediction accuracy.

[Key words] high-order fuzzy cognitive maps; BP neural network; financial time series; forecasting; error

0 引言

作为经济学的一个重要组成部分,金融市场能够反映当前和未来的经济形势,为金融领域从业者提供投资参考。为了更好地掌握未来的经济发展方向,对金融数据进行预测一直是学术研究的重要问题。但由于金融数据呈现出的非线性、非平稳性、不确定性和复杂性,对其进行准确预测存在着不

小的难度。目前,已经有许多方法可以用于对金融数据进行预测,主要可以分为传统模型和现代模型^[1]。

传统模型主要有自回归模型(AR)、自回归综合移动平均模型(ARIMA)、自回归条件异方差模型(ARCH)。文献[2]利用过去的信息建立自回归模型来预测未来的收益。文献[3]利用自回归综合移动平均模型对菲律宾皮索-美元的汇率进行了预

作者简介: 王雨涵(2001-),女,本科生,主要研究方向:人工智能、大数据分析;张亚萌(1992-),女,博士研究生,主要研究方向:人工智能、大数据分析;魏国亮(1973-),男,博士,教授,博士生导师,主要研究方向:数据分析、非线性系统控制、图像处理。

通讯作者: 张亚萌 Email:15537311987@163.com

收稿日期: 2022-09-02

测。文献[4]利用自回归条件异方差模型对 9 种人民币汇率的波动情况进行了预测。这些模型为金融时间序列预测方法的发展提供了坚实的基础,但仍存在无法准确捕捉市场的高度非线性和复杂性的问题。

近年来,得益于计算机技术的发展,大量的现代预测方法被提出,并用于金融数据的预测之中。而模糊逻辑凭借其处理数据不确定性的优秀能力,吸引了许多人的关注。例如,文献[5]提出了一种将模糊技术与灰色理论相结合的模糊灰色预测方法,来对股票价格进行预测。文献[6]引入了一种新的模糊度量,并建立了一个用于预测股票指数的时间变量模糊时间序列结构。而结合了模糊逻辑和神经网络的模糊认知图(FCMs)在经济领域中得到了广泛的应用。例如,在文献[7]中,提出了一个基于函数权重的 FCMs 模型用于股票价格的预测。在文献[8]中,一种结合了动态时间扭曲和模糊 c -均值技术的 FCMs 模型被用于股票价格时间序列问题的研究。在文献[9]中,将模糊认知图与测度递进策略相结合,从而对股票的日均值进行预测。

尽管现有的 FCMs 模型在金融市场预测中取得了许多成果,但依然存在很多缺陷。如,文献[10]采用小波变换技术提取的特征序列可能存在冗余,而文献[11]中将单变量序列先处理成了多个序列,这些因素都可能影响模型预测的稳健性。而且,目前的 FCMs 预测方法主要通过历史数据进行预测,没有考虑灵活运用历史数据预测过程中产生的误差。

文献[12]在已有预测模型的基础上构造了一个相应的误差预测模型来提高预测的准确性。基于该思想,本文通过把历史预测误差列为影响模型预测能力的一个因素,提出了一种结合 BP 神经网络和 HFCMs 模型的方法来对金融市场进行预测。该模型以金融数据集中的原始股票价格作为输入,以预测股票价格作为输出。首先,对金融数据集进行预处理,使之达到规范化标准。然后,建立 HFCMs 模型对金融数据集进行预测,并利用 BP 神经网络构造相应的误差预测模型。最后,将 2 个模型相结合,构造 BPNN-HFCMs 模型来预测股票价格。其中,最佳权重矩阵由时间变化加速系数粒子群优化(TVAC-PSO)算法得到。

本文的结构如下。第 1 节介绍了模型的结构和方法论,第 2 节介绍了利用上述模型对一系列金融数据集进行实验的结果,第 3 节用于总结模型的优

点和不足。

1 基于 BP 神经网络和高阶模糊认知图的股票价格预测方法

本节将详细介绍利用高阶模糊认知图(High-order Fuzzy Cognitive Maps)模型对股票价格进行预测的方法论,以及如何利用 BP 神经网络(Back Propagation Neural Network)对模型误差进行进一步优化。首先,用 TVAC-PSO 算法来寻找 HFCMs 模型的最优参数,得到对股票价格的初步预测值。然后,利用 BP 神经网络建立误差预测模型,预测 HFCMs 模型的预测误差,从而提高模型的预测精度。

1.1 高阶模糊认知图(HFCMs)

模糊认知图最早由 Kosko 等学者于 1986 年提出,是对于认知图的一种延伸。将认知图中概念之间的三值逻辑关系 $\{-1, 0, 1\}$ 扩展为 $[-1, 1]$ 区间上的模糊关系,便构成了模糊认知图的底层逻辑。

一般来说,FCM 是由 N 个概念节点或实体以及一系列加权边构成的有向图,节点与节点之间用加权边相互连接,从而体现出各个概念之间的因果关系。而节点 C_i 和 C_j 之间的因果关系可以由模糊成员关系 w_{ij} 来表示,因此可以用一个 $n \times n$ 阶矩阵 $\mathbf{W} = (w_{ij})_{n \times n}$ 来唯一确定一个具有 n 个概念节点的模糊认知图, w_{ij} 的取值范围即为 $[-1, 1]$,一般来说, w_{ij} 需要遵循以下规则:

- (1) $w_{ij} > 0$, 表示节点 C_i 对节点 C_j 有正的影响。即,如果 C_i 变化, C_j 会发生同向的变化,变化程度即为 w_{ij} 。
- (2) $w_{ij} < 0$, 表示节点 C_i 对节点 C_j 有负的影响。即,如果 C_i 变化, C_j 会发生反向的变化,变化程度即为 w_{ij} 。
- (3) $w_{ij} = 0$, 表示节点 C_i 对节点 C_j 无影响。




图 1 FCMs 模型结构示意图

Fig. 1 Schematic diagram of the structure of FCMs model

为了使概念描述更直观,图1中描述了一个具有5个节点的简单FCMs模型。节点 C_i 在 $(t+1)$ 时刻的状态值由式(1)得到:

$$A_j(t+1) = \Phi\left(\sum_{i=1}^N w_{ij}A_i(t)\right) \quad j=1,2,\dots,N \quad (1)$$

其中, $A_i(t)$ 表示节点 C_i 在时间 t 时的状态值; $A_j(t+1)$ 表示节点 C_j 在时间 $t+1$ 时的状态值; N 为概念节点的数量; w_{ij} 为概念节点 C_i 到 C_j 的连接权重; $\Phi(\cdot)$ 为非线性激活函数,可以将数据转换到一定的范围之内,如 $[0,1]$ 。常用的激活函数主要有sigmoid函数和双曲切线函数两种,分别见式(2)、式(3):

$$\Phi(x) = \frac{1}{1 + e^{-\eta_1 x}} \quad (2)$$

$$\Phi(x) = \tanh(\eta_2 x) = \frac{e^{\eta_2 x} - e^{-\eta_2 x}}{e^{\eta_2 x} + e^{-\eta_2 x}} \quad (3)$$

其中, η_1 和 η_2 是2个激活函数中的正数,sigmoid函数和双曲切线函数可以将输入映射到 $[0,1]$ 和 $[-1,1]$ 上。

在式(1)基础上利用历史信息,Stach提出了HFCMs模型,从而减少了长期滞后性对模型预测结果的影响。HFCMs模型和FCMs模型的区别主要体现在状态值的定义公式上,而HFCMs模型的数学表达如式(4)所示:

$$A_j(t+1) = \Phi\left(\sum_{i=1}^N (w_{ij}^{(1)}A_i(t) + w_{ij}^{(2)}A_i(t-1) + \dots + w_{ij}^{(m)}A_i(t-m+1)) + b_j\right) \quad j=1,2,\dots,N \quad (4)$$

其中, $w_{ij}^{(m)}$ 表示在 m 时刻概念节点 C_i 到 C_j 的连接权重; b_j 表示偏置项;其他符号的含义与式(1)中相同。对比式(1)和式(2)不难看出,当 $m=1$ 时,HFCMs模型与FCMs模型相同。

对于模型中的权重矩阵 w_{ij} ,本文通过时间变化加速系数粒子群优化(TVAC-PSO)算法来寻优。TVAC-PSO是一种基于种群的自适应学习算法,其中每个个体称作粒子,并且能够保存种群中所有粒子最优位置和速度的记忆。通过多次迭代,粒子不断改变其状态,直到达到最优或平衡状态。粒子 i 在 d 维搜索空间中的速度 v_{id} 和位置 x_{id} 的定义公式具体如下:

$$v_{id} = w \times v_{id} + c_1 \times rand \times (pb_{id} - x_{id}) + c_2 \times rand \times (gb - x_{id}) \quad (5)$$

$$x_{id} = x_{id} + v_{id} \quad (6)$$

其中, $rand$ 表示 $[0,1]$ 内均匀分布的随机数;

pb_{id} 表示粒子 i 在 d 维搜索空间中局部最佳位置; gb 表示全局最佳位置。而研究推出的 w 、 c_1 、 c_2 的定义公式为:

$$w = (w_{\max} - w_{\min}) \times \frac{iter_m - iter}{iter_m} + w_{\min} \quad (7)$$

$$c_1 = (c_{1f} - c_{1i}) \times \frac{i}{MAX} + c_{1i} \quad (8)$$

$$c_2 = (c_{2f} - c_{2i}) \times \frac{i}{MAX} + c_{2i} \quad (9)$$

其中, $iter_m$ 和 $iter$ 分别表示最大迭代数和当前迭代数; c_{1f} 、 c_{1i} 、 c_{2f} 、 c_{2i} 为常数; i 表示当前迭代数; MAX 为总迭代数。

TVAC-PSO通过最小化以下损失函数来得到最佳的权重矩阵:

$$J_1 = \frac{1}{T} \sum_{t=1}^T \sum_{i=1}^N (A_i(t) - \hat{A}_i(t))^2 + \frac{\lambda}{2} \times \sqrt{\sum_{j=1}^N w_{ij}^2} \quad (10)$$

s.t. $-1 < w_{ij} < 1, i, j=1,2,\dots,N$

其中, λ 是正则化参数,范围为 $[0,1]$ 。

通过TVAC-PSO模型,可以帮助HFCMs模型获得更高的预测精度。

1.2 反向传播神经网络(BPNN)

由于HFCMs模型存在一定的预测误差,因此本文通过对误差进行二次预测,从而进一步提高模型准确率。在此,选择了反向传播神经网络(BPNN)来建立该误差预测模型。

神经网络模仿了人类神经元的激活、传递过程。BP神经网络采用输出结果前向传播,误差反向传播的方式来对输入进行处理,是一种基础神经网络。BP神经网络包含输入层、隐层、输出层三层结构。每一层神经元都与上一层神经元相连接,收集其传递来的信息并通过仿射变换 z 将其变为一个标量,再由激活函数(见式(2)、式(3))处理之后把仿射变换后的数据传递给下一层。仿射变换 z 可以用式(11)进行简单表述:

$$z_i = W_i \times a_{i-1} + b_i \quad (11)$$

其中, a_{i-1} 为该层神经元的输入; W_i 为第 i 层的权重矩阵; b_i 为偏置向量。可以看出,各层神经网络的权重矩阵 W_i 以及对应的偏置向量 b_i 即为神经网络中的待训练参数。为了便于理解,一个3层的BP神经网络结构如图2所示。

为了得到模型的最佳参数,在训练过程中,首先对权重矩阵和偏置向量进行初始化,再使用梯度下降法反向传递误差,从而逐渐减小模型输出值与实际值之间的差距,使权重矩阵 W_i 以及对应的偏置向

量 b_i 能够接近最佳值。




图 2 BPNN 结构图示

Fig. 2 Schematic diagram of the structure of BPNN

1.3 BPNN-HFCMs

利用如上 BP 神经网络来构造对于 HFCMs 的误差预测模型, 再与 HFCMs 模型相结合, 得到 BPNN-HFCMs 模型对金融数据集进行预测。为了便于理解, 图 3 描述了该模型的流程图。

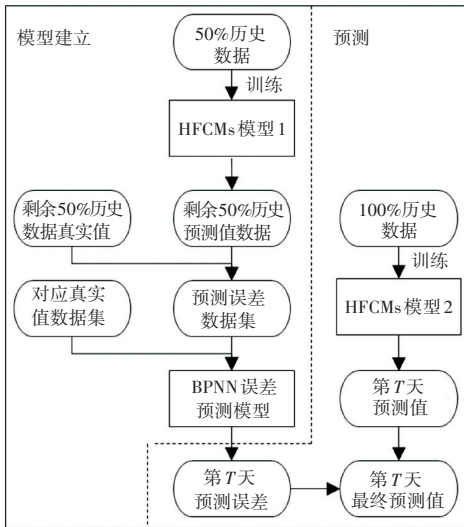


图 3 模型结构流程图

Fig. 3 Flowchart of model structure

BPNN-HFCMs 模型分为模型建立部分和预测部分。在模型建立部分, 以原始股票价格以及最大迭代次数 NG 作为模型输入, 首先用 50% 的历史数据利用 TVAC-PSO 算法训练 HFCMs 模型 1, 然后用训练好的 HFCMs 模型 1 来预测剩余的 50% 历史数据。通过比较剩余 50% 历史数据的真实值和预测值之间的差得到预测误差集, 再用 BPNN 算法用预测误差集构造误差预测模型。模型的输出即为预测价格。

在预测部分, 同样以原始股票价格作为模型输入, 首先, 用 100% 的历史数据训练 HFCMs 模型 2, 得到第 T 天的预测值; 然后用构造好的 BPNN 模型以 $T - 1$ 天的数据为输入, 输出第 T 天的预测误差。结合第 T 天的预测误差和第 T 天的预测值, 则可以

得到第 T 天的最终预测值。模型的输出即为最终预测价格。

1.4 算法

在本节中, 提出一个算法来详细展示上文所提出的预测系统, 即 HFCMs 预测模型和 BPNN-HFCMs 模型。为简洁起见, 模型的伪代码详见算法 1 及算法 2。

算法 1 HFCMs 模型

输入 原始股票价格, 最大迭代次数: NG

输出 预测价格

- 1: 获取历史数据, 并将股票价格初始化为 $[-1, 1]$ 的范围内
- 2: 随机初始化 TVAC-PSO 算法中所有粒子的速度 v_{id} 和位置 x_{id}
- 3: for $g = 1$ to NG do
- 4: 用方程(5)和方程(6)更新所有粒子的速度和位置

5: 计算损失函数 J_1 的值

6: 检查是否满足结束条件

7: end for

8: 得到 HFCMs 模型框架

9: 通过 HFCMs 模型框架预测未来价格

算法 2 BPNN-HFCMs 模型

输入 原始股票价格

输出 最终预测价格

- 1: 获取历史数据
- 2: 以 50% 的历史数据作为输入, 根据算法 1 构造 HFCMs 模型 1

3: 根据算法 1, 使用 HFCMs 模型 1 预测剩余 50% 的历史数据

4: 用预测误差和实际值作为输入, 训练 BPNN 误差预测模型

5: 使用 HFCMs 模型预测股票价格, BPNN 误差预测模型预测对应时间点的预测误差

6: 结合步骤 5 中的预测数据和预测误差, 得到对应时间点的最终预测值

2 实验

为了验证 BPNN-HFCMs 模型对金融时间序列预测的有效性并评价其预测效果, 本节中选取了 5 个金融数据集对模型进行了实验。其中, 2.1 节介绍了实验的设置和评价指标, 2.2 节则是对实验结果的展示。

2.1 实验设置和评价指标

本文的实验均是在一台 2.38 GHz CPU、16 GB 内存、使用 Python3.10 版本的 Windows 10 操作系统的笔记本电脑上进行的。对这里的研究内容可给出阐释论述如下。

(1) 数据集。本文选取了 5 个从雅虎金融上下载的金融时间序列数据集: SP500、RUT、N225、HSI、DJI, 来对预测模型的有效性进行验证。其中, 每个数据集分别包括从 2010 年 1 月 4 日到 2020 年 10 月 22 日的每日开盘价、最高价、最低价以及收盘价。由于整个模型主要分为 2 个部分: 根据 HFCMs 的预

表 1 各股票收盘价格的统计描述

Tab. 1 The statistical description of the close price of each stock

数据集	数量	最大值	最小值	均值	标准差
SP500	2 721	3 580.840	1 022.580	2 050.590	659.476
RUT	2 721	1 740.750	580.490	1 158.981 8	316.363 8
N225	2 665	24 270.619	8 160.009	16 130.340	5 040.198
HSI	2 668	33 154.121	16 250.269	23 760.891	3 129.092
DJI	2 721	29 551.419	9 686.480	18 262.766	5 496.737

(2) 基线模型。为了验证模型的预测能力, 本文选取 HFCMs、FCMs、BPNN 作为基线模型进行比较。这些基线模型的详细描述见如下。

① HFCMs: HFCMs 是在处理金融领域预测中较为常见的一种预测方法, 因此将其作为基线模型之一。此外, HFCMs 模型的最佳权重矩阵由 TVAC-PSO 算法得到。

② FCMs: FCMs 是用于预测的基础模型之一, 因此将其作为基线模型之一。

③ BPNN: BPNN 是神经网络中最为经典的预测模型之一, 本质上可以将其认为是用训练样本构造的回归模型。通过各股票的 4 个基本价格(开盘价、收盘价、最高价和最低价)作为输入来对股票的收盘价进行预测。

(3) 评价指标: 在实验中用平均绝对误差(MAE)和均方根误差(RMSE)对实验结果进行评价。这两个指标均用于衡量股票价格的真实值和预测值之间的差异, 其值可由式(12)、式(13)来求得:

$$MAE = \frac{1}{T} \sum_{i=1}^T |y_i - \hat{y}_i| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{T} \sum_{i=1}^T (y_i - \hat{y}_i)^2} \quad (13)$$

其中, T 表示预测数据的总数, y_i 和 \hat{y}_i 分别表示实际值和预测值。并且, MAE 和 RMSE 的值越

测结果训练误差预测模型 BPNN, 以及结合 HFCMs 模型对真实值的预测和 BPNN 对误差的预测, 从而得到最终的预测值。在对 BPNN 模型的训练中, 首先用 HFCMs 模型对 50% 的数据集进行预测, 这由 HFCMs 模型预测得到的 50% 数据即为 BPNN 模型的输入。此后再将这 50% 的数据集以 80%:20% 的比例划分为训练集和测试集进行误差预测, 并与 HFCMs 模型中的预测值相结合。即从总体上来看, 数据集中 10% 数据被用于测试集, 剩余的 90% 均用于模型的训练。在表 1 中对这 5 个金融数据集进行了统计描述。

小, 表示模型的性能越好。

2.2 实验结果

本小节将对实验结果进行展示分析。首先, 为了使预测结果更加准确, 本文将股票价格数据映射到了 $[0, 1]$ 区间内, 再对所提出的模型进行训练。对于每个归一化后的金融数据集, 将其分为 3 个部分, 即: 训练集、验证集和测试集。

考虑到高阶 HFCMs 模型对计算机运算能力会产生较大负荷, 本文中使用的 HFCMs 的阶数为二阶, 以减小模型计算量。

本文利用提出的 BPNN-HFCMs 模型对各金融数据集进行预测, 并与各基线模型的预测效果进行对比。表 2~表 3 给出了不同模型在各数据集预测上的 MAE 对比以及 RMSE 对比结果, 而图 4~图 5 则是多次运行 BPNN-HFCMs 模型得到的在各数据集上 MAE、RMSE 值的箱型图。

表 2 各模型 MAE 值对比

Tab. 2 The comparison of MAE on each model

数据集	HFCMs	BPNN-HFCMs	FCMs	BPNN
SP500	63.717 6	45.058 8	64.054 1	63.787 4
RUT	29.936 9	26.095 7	36.978 1	35.022 5
N225	415.276 6	318.668 1	419.997 5	418.533 6
HSI	301.418 5	298.881 3	316.939 6	304.479 6
DJI	605.779 4	425.022 2	635.867 3	606.547 9

表 3 各模型 RMSE 值对比

Tab. 3 The comparison of RMSE on each model

数据集	HFCMs	BPNN-HFCMs	FCMs	BPNN
SP500	98.255 5	74.013 8	101.770 6	100.264 2
RUT	41.376 8	40.737 7	47.010 2	45.347 5
N225	503.524 5	402.246 7	517.848 4	506.327 2
HSI	400.804 6	398.310 9	408.152 0	405.294 8
DJI	928.877 9	765.901 1	956.284 7	929.183 6

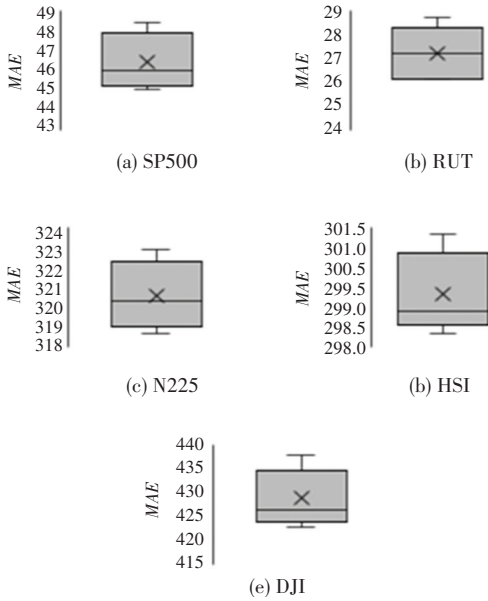


图 4 BPNN-HFCMs 模型在各数据集上的 MAE 值

Fig. 4 The MAE value of BPNN-HFCMs model on each dataset

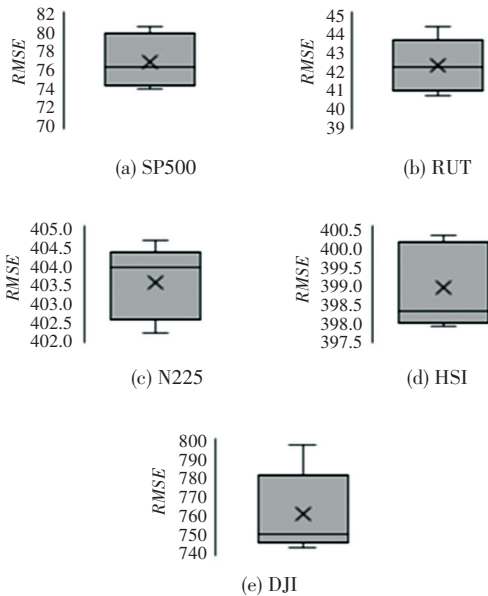


图 5 BPNN-HFCMs 模型在各数据集上的 RMSE 值

Fig. 5 The RMSE value of BPNN-HFCMs model on each dataset

从表 2~表 3 可以看出,传统 FCMs 模型的预测效果最差, BPNN 的预测效果次之,而 BPNN-HFCMs 模型对于各个金融数据集的预测效果则要

优于本文选取的 3 个基线模型的效果。根据图 4~图 5,可以认为 BPNN-HFCMs 模型的预测结果是较为稳定的。因此可以认为,在股票价格预测中, BPNN-HFCMs 模型是一种较好的预测方法。

并且,通过对比 BPNN-HFCMs 模型与 HFCMs 模型的预测结果,可以得出以下结论:用 BP 神经网络对 HFCMs 模型的预测误差做进一步预测,对于提高模型的最终预测精度是有效的。根据表 2 和表 3 中 2 个模型在 5 个数据集预测上的 MAE 和 RMSE 值,可以得出对于数据集 SP500、N225 和 DJI,其 MAE、RMSE 值均有了显著的降低。对于 SP500,预测结果的 MAE 值降低了 29.2%, RMSE 值降低了 24.6%;对于 N225,预测结果的 MAE 值降低了 23.2%, RMSE 值降低了 20.1%;对于 DJI,预测结果的 MAE 值降低了 24.6%, RMSE 值降低了 17.5%。尽管金融数据集 RUT 和 HSI 在预测结果的 MAE、RMSE 值上降幅并不大, RUT 上的降幅为 12.8% 和 1.5%, HSI 上的降幅为 0.8% 和 0.6%,但 BPNN-HFCMs 模型的预测结果依然优于 HFCMs 模型。

此外,本文还应用了 Diebold-Mariano 检验 (DM 检验) 来验证 2 个模型之间在预测能力上的差异。DM 检验的无效假设是:2 个被测模型之间的预测能力没有明显的差异。其中,将第 i 个模型在 t 时刻的预测误差定义为 $e_{i,t} = y_{i,t} - \hat{y}_{i,t}$, 则 DM 统计数据可由式 (14) 运算得到:

$$DM = \frac{\bar{g}}{\sqrt{2\pi\hat{f}_g(0)/T}} \quad (14)$$

$$\bar{g} = \frac{1}{T} \sum_{t=1}^T \delta_t \quad (15)$$

其中, $\hat{f}_g(0)$ 表示 $f_g(0)$ 的一致估计值,即频率为 0 的损耗差的频谱密度。根据 DM 检验的 p 值可以判断 2 个模型预测能力是否存在差异,若 p 值小于 0.05,则 2 个模型的预测能力存在差异。BPNN-HFCMs 模型与其他模型之间 DM 检验的 p 值见表 4。根据表 4 可得,本文提出的 BPNN-HFCMs 模型与 HFCMs、FCMs、BPNN 模型的预测能力存在显著差异。

为了更好地观察模型 BPNN-HFCMs 的预测效果,模型在各数据集测试集上的预测结果与真实值的对比如图 6 所示。


由图 6 可知, BPNN-HFCMs 模型得到的预测值与真实值较为接近,但由于金融市场中诸多不确定性因素的存在,依然无法实现对金融数据集的零误

差预测。但本文提出的模型与其他作为对照的模型相比,依然取得了较为理想的预测效果。

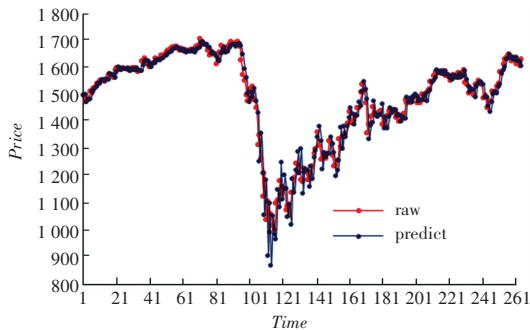
表 4 BPNN-HFCMs 模型与其他模型之间 DM 检验的 p 值

Tab. 4 The p -value of the DM test between the BPNN-HFCMs model and other models

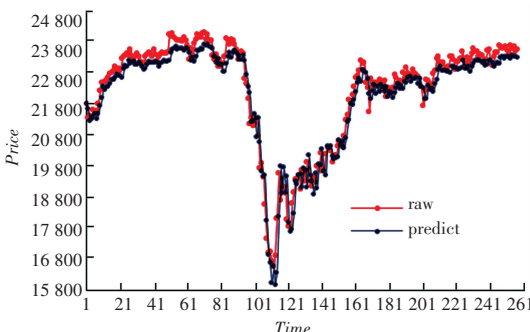
数据集	度量	HFCMs	FCMs	BPNN
SP500	RMSE	0.000	0.000	0.000
	MAE	0.000	0.000	0.000
RUT	RMSE	0.000	0.000	0.000
	MAE	0.000	0.000	0.000
N225	RMSE	0.000	0.000	0.000
	MAE	0.000	0.000	0.000
HSI	RMSE	0.000	0.000	0.000
	MAE	0.000	0.000	0.000
DJI	RMSE	0.000	0.000	0.000
	MAE	0.000	0.000	0.000



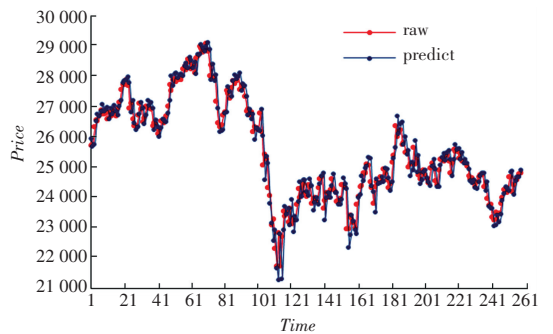
(a) SP500




(b) RUT



(c) N225



(d) HSI



(e) DJI

图 6 BPNN-HFCMs 模型在各数据集上预测结果与初始值对比图

Fig. 6 The comparison of predict outcomes and initial values on each dataset of BPNN-HFCMs

3 结束语

本文提出了一个基于 BP 神经网络和高阶模糊认知图的股票价格预测模型来预测金融市场。通过对初步预测值和真实值的误差构建的误差预测模型来提高预测的准确性。模型的最佳权重矩阵通过 TVAC-PSO 算法得出。该模型主要有以下 2 个优点:

- (1) 在预测中充分考虑了预测误差对模型精度的影响。
- (2) 采用 TVAC-PSO 算法得到模型的最佳权重矩阵。

最后,通过对 5 个金融数据集的实验,验证了该模型的有效性。

参考文献

[1] HUANG Yusheng, GAO Yelin, GAN Yan, et al. A new financial data forecasting model using genetic algorithm and long short-term memory network[J]. Neurocomputing, 2021, 425:207-218.

[2] 董雪建. 试用自回归模型预测股票市场的收益[J]. 时代金融, 2016(12):127-128.

[3] TOLEDO N I. The autoregressive integrated moving average model in forecasting philippine peso - United States dollar exchange rates [J]. Journal of Physics: Conference Series, 2021, 1936(1): 012002.