

基于神经网络模型的智能产业板块股价探究

庄妍, 王林萍

(福建农林大学 经济与管理学院, 福州 350002)

摘要:针对金融波动性和市场风险,基于A股市场上70余只智能板块的股票近10年的四因子数据,从神经网络模型入手实证分析,利用随机梯度算法对收盘价预测,比较预测值与实际值的模型误差及损失函数,进行因子选取、算法改进及指标择优。结果表明,神经网络模型参数在批次为2、迭代次数为4150时,MSE(均方误差)、MAPE(平均绝对百分比误差)、MAE(平均绝对误差)分别为60.1911、30.7326、4.8032,收盘价的拟合效果最佳,该参数下的神经网络模型可用于探究股票市场价格趋势,为投资者、金融机构提供一定参考依据。

关键词:神经网络;智能产业板块;股票预测;随机梯度下降法;数据拟合

中图分类号:F224.9; F224.39 **文献标志码:**A **文章编号:**1671-1807(2023)14-0250-09

股票市场越来越被看作经济核心,截至2021年9月底,中国股市开户总量超过1.93亿户,与其他行业相比,金融市场的风险与短时间内获得巨额利润的可能性成正比。过去几年,中国人工智能应用的市场及规模有着显著发展,人工智能技术的应用提高了社会生产力,智能产业的范围逐渐拓宽到智能城市、智能制造、智能家居等行业,几乎每一个科学领域及其应用都日益智能化。伴随着数字金融的发展或电子金融新形式的出现,金融业也在此发展过程中获益。当代投资者对股票价格趋势的探究欲望越来越强烈,对于投资者来说,准确了解股票价格趋势对其投资和理财规划有着深远的意义;对于公司或机构来说,精准实现的股价预测有助于规划资金,制定合理的经营策略^[1]。

股市预测在计算机技术的快速发展下不断更新和整合,数学模型越来越多地被用于预测股票价格趋势。近年来,预测股票长短期趋势的方法有:①传统的与宏观经济相结合的分析方法。最初的股价趋势预测方法分为基本面分析与技术面分析两个方法,对宏观经济、行业包括公司经营策略、公司报表等的结合分析,判定股票的价格波动与投资性价比,提出投资建议的一种分析方法。②时间序列上的计量经济学分析法。基于计量经济学模型的股价预测方法主要使用金融时间序列来预测股价趋势,运用统计回归模型挖掘股票时序数据的内在规律,建立股票过去价格与未来价格的量化关系。③基于机器学习的

股票趋势分析^[2]。机器学习越来越多地应用于金融。与统计建模相比,机器学习的精力更多地集中在预测能力,而不是集中在对结果的理解上。如神经网络模型从人脑信息出发,根据其运行机制与数学建模结合,模拟人脑外部信息转换能力,广泛应用于模式识别、智能操控、信信息处理等领域。在金融市场的运作中,神经网络模型可以利用其合理性和适用性优势,对历史信息量化,找出股价的变化规律,为股市提供非线性预测系统,故越来越多人将神经网络模型运用于股票市场^[3]。

1 神经网络模型

股票市场本质是一种受多种因素综合影响的动态、非平稳、高噪声的系统,股票价格趋势预测是股票市场上一个具有挑战性的问题。建立准确度较高、科学实用的选股预测模型进行量化投资,是股票市场上风险有效管理,实现效益最大化的关键一环,能够处理非线性数据的神经网络模型也因此受到国内外学者的青睐。

1.1 文献综述

国外理论界关于神经网络的研究开始得较早,2001年Kuo等^[4]提出了一种遗传算法为基础的模糊神经网络(genetic fuzzy neural network, GFNN),以建立模糊推理规则的知识库,可以衡量对股票市场的定性影响。Majhi等^[5]提出了一个三角函数连接人工神经网络(functional link neural networks, FLANN)模型,用于中短期股票市场指

收稿日期:2023-03-12

作者简介:庄妍(2000—),女,福建泉州人,福建农林大学经济与管理学院,硕士研究生,研究方向为证券市场与投资;王林萍(1968—),女,福建永春人,福建农林大学经济与管理学院,教授,博士研究生导师,研究方向为金融市场、普惠金融。

数的股价预测。Hafezi 等^[6]则创建一个蝙蝠神经网络多智能体系统(bar-neural network multi-agent system, BNNMAS)来预测长期股价。为了更好地利用智能化技术探究技术指标与股价未来走势之间的关系,支持向量机(support vector machine, SVM)^[7]、逐步回归和神经网络的联合使用^[8]、(Extreme Gradient Boosting, XGBoost)^[9]都得到广泛应用。Kara 等^[10]提出了基于两种分类技术的模型,即人工神经网络(artificial neural network, ANN)和支持向量机,结果表明,神经网络模型的平均性能明显优于 SVM 模型。Chang^[11]专注于人工神经网络、决策树及 ANN 与决策树的混合模型三种不同的算法,用于预测股价。研究发现,与其他两种方法相比,ANN 更适合在动荡的危机后股市中预测股价。在此背景下,神经网络模型在国外应用日益广泛,因此研究中也就不再只单独使用神经网络模型。Hajizadeh 等^[12]认为 GARCH 模型与神经网络模型相辅相成,能较好地模拟和预测高度波动市场的波动性。Zhuo 等^[13]引入主成分分析法,将 BP(back propagation)神经网络模型、PCA-BP(principal component analysis back propagation)模型和传统 ARIMA(3,1,1)模型的预测结果进行了对比。结果表明,神经网络模型在机器学习的高维时间序列数据预测方面表现突出,这也是神经网络模型研究的一大进步。

同美国股票市场相比,中国股票市场上近年来对神经网络模型的应用开始得较迟,但是由于神经网络模型的可行性强,发展势头是十分迅猛的,神经网络模型不仅被用于解决物理问题^[14],也广泛运用于量化选股、投资方面^[15]。最初谢琪等^[16]利用 2012—2017 年的上海证券交易所综合指数等数据,验证了神经网络模型预测精确度高;黄宏运等^[17]通过实证分析发现,神经网络模型仅对于短期数据的预测有效;曹晓^[18]提出了一类神经网络的混合模型,其在预测精度、效率方面都显著高于单个神经网络模型。纵观已有的关于股票市场的研究,学者们通常将模型建立在整个 A 股市场上,着眼于预测未来股票价格变化情况,鲜有从模型本身算法的改进入手进行优化。此外,大多数学者选用于研究的时间周期较短,仅选取了近几年的数据,而数据量不够大容易受“黑天鹅”事件的影响。基于此,在深入分析热门的智能产业数据的基础上,进一步阐述基于随机梯度下降算法对神经网络^[19]的模型优化,并将结果可视化,尝试对神经网络模型深入探究,

以将其应用到股票市场的预测中。

1.2 模型简介

神经网络模型是模拟人脑对外部输入信息的反应过程的计算机模型,用于分析大量特征和大数据下预测精度低的问题。神经网络模型由输入层、输出层和隐藏层组成,各层级连接线分别设置权重,通过随机抽取训练集计算各层的输出值及误差,由此调整各层权重值。选取恰当权重值检查网络总误差是否达到精度要求,若达到要求,则训练结束,否则继续训练。根据此权重值,形成一个训练好的神经网络模型,用于训练集。随着数据复杂性增加,神经网络算法凭借其预测准确度高、适用范围广、非线性数据分析能力强、不易过拟合等优势,成为股票市场中新的有效分析手段。图 1 显示了典型的三层神经网络模型的拓扑结构。




图 1 神经网络模型的拓扑结构

1.3 算法原理

假设一个神经网络中的神经元是 $R^n \rightarrow R$ 函数,

$$\text{输入函数为 } \mathbf{X} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}, \text{ 输出函数为 } \mathbf{Y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_t \end{bmatrix}, \text{ 隐藏}$$

$$\text{层输出为 } \mathbf{B} = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_m \end{bmatrix}, \text{ 输入层与隐藏层的权重值矩阵}$$

$$\text{为 } \mathbf{W} = \begin{bmatrix} w_1 \\ w_2 \\ \vdots \\ w_m \end{bmatrix}, \text{ 隐藏层与输出层的权重值矩阵为 } \mathbf{Z} =$$

$$\begin{pmatrix} z_1 \\ z_2 \\ \vdots \\ z_t \end{pmatrix}, \text{期望输出函数为 } Q = \begin{pmatrix} q_1 \\ q_2 \\ \vdots \\ q_t \end{pmatrix}。$$

1) 输入层、隐藏层、输出层的连接: 以 x_i 为输入层, w_{ij} 为输入层与隐藏层之间的权重; w_j 为所得隐藏层输入向量, 通过函数变化转化为隐藏层输出向量 y_j 。同理, z_{ij} 为隐藏层与输出层之间的权重, h_k 为所得输入层输入向量, 通过函数转化成隐藏层输出向量 O_k 。隐藏层接受输入层, 是第 j 个隐藏层神经元的输出, 有

$$u_j = \sum_{i=1}^n w_{ij} x_i \quad (1)$$

式中: $i=0, 1, \dots, n; j=1, 2, \dots, m$ 。

$$y_j = f(u_j) \quad (2)$$

式中: $i=0, 1, \dots, n; j=1, 2, \dots, m$ 。

输出层接受隐藏层, 是第 k 个输出神经元的输出, 有

$$h_k = \sum_{j=1}^m z_{jk} y_j \quad (3)$$

式中: $k=1, 2, \dots, t$ 。

$$O_k = f(h_k) \quad (4)$$

式中: $k=1, 2, \dots, t$ 。

sigmoid 函数作为神经网络的阈值函数, 也是激活函数, 它将变量 x 映射到 $(0, 1)$ 。将映射后的函数用 $S(x)$ 表示, sigmoid 函数在 x 过大或过小时, 函数变化非常小, 即梯度非常接近 0, 随着神经网络的加深, 在使用梯度下降方法的时候, 由于梯度接近 0, 参数更新接近 0, 神经网络开始学不到东西, 即梯度消失。所以经常使用 RELU 激活函数, 在模型中每层之间加入 RELU 函数作为非线性激活单元来防止过拟合, 增加非线性表达能力, 在股票市场上发挥的作用突出。计算公式为

$$S(x) = \frac{1}{1 + e^{-x}} \quad (5)$$

2) 为进一步提升神经网络模型对非线性数据的描述, 在求解股票的模型参数时, 为了让神经网络模型可以更好地获得数据中蕴含的规律, 利用随机梯度下降算法优化。

对于一个任意非线性函数 $y=f(x, \theta)$, 假设其损失函数为 $L(f(x_i, \theta), y_i)$, 学习率为 ϵ 。在机器学习算法中, 通过将损失函数优化, 以达到最优参数寻找的目的, 该过程使神经网络训练集的损失 (loss) 无限小, 而学习率可以用来控制梯度下降的步长, $L(f(x_i, \theta), y_i)$ 关于 θ 的梯度值 (偏导) 记为

$\nabla_{\theta} L(f(x_i, \theta), y_i)$, 最优拟合直线用 g 表示, 有

$$g = \frac{1}{N} \nabla_{\theta} L(f(x_i, \theta), y_i) \quad (6)$$

梯度指向为函数增长最快的方向, 为找到梯度 θ 最优值, 若 θ 沿着梯度的负向移动, 即 $\theta \leftarrow \theta - \epsilon g$, 即可实现损失函数值 (loss) 最小化的目的, 得到局部最优解^[20]。

在这个过程中, 需要计算出所有样本损失函数的梯度, 以此求得平均值来更新 $g = \frac{1}{N} \nabla_{\theta} L(f(x_i, \theta), y_i)$, 这需要很大的内存开销, 故随机选取梯度列入考虑范围, 仍然可以按正确的梯度列入收敛函数, 有

$$g' = \frac{1}{m} \nabla_{\theta} \sum_{i=1}^m L[f(x_i, \theta), y_i] \quad (7)$$

为更高效地测试损失函数达到最小值, 引入 ∂ 控制动量, v 为动量。有

$$v \leftarrow \partial v - \epsilon g \quad (8)$$

$$\theta \leftarrow \theta + v \quad (9)$$

一般情况下, 为了在开始时快速地找到神经网络模型正确的收敛方向, 设置一个较大的学习率, 但需要逐渐地优化防止震荡, 故引入梯度大小随时间的积累量 r, δ 是一个稳定数值计算的小量, 有

$$r \leftarrow r + g^2 \quad (10)$$

$$\theta \leftarrow \theta - \frac{\epsilon}{\sqrt{r} + \delta} g \quad (11)$$

由式(10)和式(11)可知, 梯度波动很大时, 学习率会快速下降, 反之下降速度慢, 从而实现了学习率的自动调整。随机梯度下降算法如图 2 所示。

3) 训练神经网络的过程, 实际上就是在样本输入并运行状态下调整并优化神经网络的权重和偏置值, 从而使神经网络模型输出值的误差足够小, 损失函数接近预期。神经网络模型的训练过程分前向传输与逆向反馈, 随机梯度下降算法是更新层




图2 随机梯度下降算法

与层之间参数的过程,直到所有的参数都被更新即为训练好的神经网络模型,迭代公式为

$$f_{ij}^{(I)} = f_{ij}^{(I)} - \epsilon \frac{\partial L}{\partial f_{ij}^{(I)}} \quad (12)$$

$$y_i^{(I)} = y_i^{(I)} - \epsilon \frac{\partial L}{\partial y_i^{(I)}} \quad (13)$$

式中: I 为神经网络中的层数; $f_{ij}^{(I)}$ 为连接 I 的第 j 个节点到 $I+1$ 层的第 i 个节点的偏置项的值^[5,21]。

2 研究设计

2.1 数据及参数设定

特别关注数学模型的实现细节,研究了用于实现机器学习和深度学习模型的Python编程语言,这在以前的调查中很少被讨论到。Python代码中运用了pandas、numpy、torch、sklearn等库进行模型的训练及预测,并将数据标准化、缺失值填充等预处理过程写入Python代码中。

由于不同产业股价变化趋势不同,为更好地训练神经网络模型,提取智能产业板块股票作为研究对象,从RESEET数据库中下载了A股市场上70余只智能板块的股票2010年1月1日至2021年12月31日的数据集,以每周为一个研究周期,累计有效数据2万余条,将有效数据按照8:2划分为训练集和测试集。为达到误差值较小、准确度较高的目的,在训练样本过程中,引入均方误差(mean square error, MSE)、平均绝对误差(mean absolute error, MAE)、平均绝对百分比误差(mean absolute percentage error, MAPE)作为参照指标,并将批次batch_size与训练次数epoch不断修改、循环迭代将神经网络独立执行多次,直到训练集的误差足够小。计算公式为

$$\text{MAPE} = \frac{100\%}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (14)$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (15)$$

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

式中: $\hat{y}_i$ 为原始时间序列的预测值; y_i 为原始时间序列的实际值; n 为观测值个数。

2.2 变量选择

经过文献查阅,注意到在一些股票价格预测的论文中只考虑了平均价格,但在实际操作中认为收盘价更能体现股票未来变化趋势。因为收盘价既反映市场资金对某个股的关注程度,又反映一天中股票指数的所有行动,具有预示下一个交易日演绎方向的功能,特别是在神经网络模型中,每日收盘价也一定程度上减少数据的噪声。由于当下智能

产业景气度的提升,股价等财务指标的影响因素更加宽泛,故对收盘价影响因子划分如表1所示。

表1 股价预测四因子

影响因子	名称	符号	变动方向
市值因子	总股数	总股数_Fullshr	由非流通股数而定
	收盘价	收盘价_CIPr	—
	成交金额	成交金额_Trdsun	正向
	成交量	成交量_Trdrv	正向
价值因子	市净率	市净率_PB	负向
	市现率	市现率_PCF	负向
	市销率	市销率_PS	负向
成长因子	净资产收益率	净资产收益率(摊薄)_ROE	正向
	每股收益	每股收益(摊薄)/(元·股 ⁻¹)_EPS	正向
	加权平均市场周收益率	流通市值加权市场周收益率_Wrettmv	正向
	加权平均市场周资本收益率	流通市值加权平均市场周资本收益率_Warettmv	正向
质量因子	流通股周换手率	流通股平均周换手率%_AvgDtrdTurnR	—
	流通股日换手率	流通股平均日换手率%_AvgDtrdTurnR	—

市值因子:市值因子容易受到市场风格切换的影响,在市场波动较强的情况下小市值公司表现较为突出,一般以总股数与收盘价的乘积代替股票流通市值检测。

价值因子:估值较低的股票有着比高估值的股票更高的预期收益率,杠杆率较高的企业有着显著的超额收益。即使成长型股票有较高的发展空间,但在“价值异象”的驱动下,对价值型股票投资仍能获得比成长型股票更高的收益率。

成长因子:成长类因子值明显较高的股票,其获得超额收益的可能性越大,超额收益率也会越高。而超额收益率为周收益率与加权平均市场周收益率的差值,故它的股价在未来存在较大上涨可能性^[22]。

质量因子:股票质量主要体现在盈利能力与资金周转率两个方面,质量因子表现越优,投资者会更愿意选择此类蓝筹股。

将初始学习率lr设置为0.01,初始动量momentum设置为0.9,数据的导入批次batch_size在2、4、8中选取,迭代次数epoch在500~5000进行调试,虽然模型迭代次数多可以有更高的准确度,但是训练次数过高,模型就会过拟合,最终的预测结果与真实值反而相差甚远。随着给定epoch的增大,最终预测误差先减小后增大,这意

意味着在不改变其他条件的情况下,存在最合适的 epoch 取值,使预测误差最小。为在保障数据精度的同时兼顾计算效率,将导入数据转化为“float32”形式。建模的过程中,通过比较训练步骤和误差,设置神经网络模型总层数为 5,利用上采样法选取到 32 个参数传入隐藏层,由于输入的有效因子为 11 个,输出样本维数为 1,因此 5 层神经网络的结构为 11-32-16-8-1(图 3)。

3 实施效果与实证研究

3.1 共线性诊断

由不同自变量之间的热力图(图 4)可以看出,流通股日换手率与流通股周换手率之间的相关性高达 0.9 左右,即存在很强的多重共线性。在神经网络拟合中也剔除二者之一,以免导致因多重共线性造成的过拟合。

3.2 参数的比较择优

由于神经网络模型的训练需要更大的计算量,基于 CPU 的良好代码通常被设计为尽可能从高速缓存中读取更多的信息,故将数据放置于 CPU 中训




图 3 神经网络模型




图 4 因子热力

练与测试。不同批次 batch_size 与训练次数 epoch 节点数有不同的拟合误差^[23],模型训练完成后,用测试集进行股票预测并将预测效果可视化。以下分别对不同 batch_size 与 epoch 下对应的 loss、MSE、MAPE、MAE 对比。

图 5 展示了批次为 2 时的拟合效果,表 2 是对应的误差情况。从图 5 可以看出,随着 epoch 在 500~4 000 的不断增大,预测效果越来越好。通过误差的对比分析发现,最优 epoch 为 4 000~5 000。最后利用二分法不断寻找,得到了局部最优值 epoch=4 150, MSE=60.191 1, MAE=4.803 2, MAPE=30.732 6,拟合曲线与损失函数变化情况如图 6、图 7 所示。

图 8 展示批次为 4 时的拟合效果,表 3 是批次为 4 的误差情况。对比实验的结果可知,仅仅对 batch_size 参数进行增大的神经网络模型预测误差并没有减小,反而有所提升。由表 3 可知,epoch 在 500~2 000 的预测误差不断增加,epoch 在 2 000~4 000 的误差值达到相对最优,但从图 8 来看,拟合最优值应在 epoch=1 000~3 000 时取得,在 epoch=3 000~4 000 时图形出现过拟合现象。

再对批次为 8 时做实验,可以发现批次越大,预测点的分散程度越低,但误差值不佳。综合误差值与拟合效果图来看,批次为 2 时的神经网络拟合效果比批次为 4 和 8 的时候好,在每类批次上,拟合效果也随着 epoch 的变化而变, batch_size=2 且 epoch=4 150 时预测效果最好,不仅预测误差最小,loss 的下降速度也稳定,证明了所提模型的有效性。

4 总结与展望

预测股票趋势如今仍是金融市场上一大热点问题,在对神经网络模型与股票市场非线性适用性探究的基础上,运用神经网络模型从特征因子对 A 股市场上 70 余只智能板块的股票股价情况模拟预




图 5 批次为 2 时的拟合效果
表 2 批次为 2 时的误差值

epoch	MAPE	MAE	MSE
500	441.288 8	37.559	1 658.692
1 000	464.246 9	33.559 2	1 411.176 6
2 000	117.539 1	9.956 7	232.234 4
3 000	60.964 9	9.761 3	208.593 5
4 000	64.184 1	7.799 2	152.257 1
5 000	271.435 8	27.400 8	885.550 2




图 6 epoch=4 150 时的 loss 值




图7 epoch=4 150时的拟合效果




图8 批次为4时的拟合效果

表3 批次为4时的误差值

epoch	MAPE	MAE	MSE
500	68.611 6	10.086 1	215.743
1 000	106.738 7	9.529 7	242.408 7
2 000	114.079 3	10.123 9	378.104 5
3 000	67.808 9	7.793 2	187.480 9
4 000	69.708 8	9.347 4	198.786 3
5 000	87.654 4	9.251 2	223.964 3

测。在收盘价的预测中,从市值、价值、成长、质量4个方面选取特征因子,充分利用神经网络模型处理高相关性及复杂性数据的优势进行模型仿真,最终误差优化以拟合收盘价格。模型实证中采用2010—2022年多个股票指数的周度数据,选择智能产业中股票11项指标,为了消除量纲对数据结果的影响,确定模型适用性后对数据标准化处理。经多次的调参及误差分析,对神经网络模型本身进行优化。试验得出,相对最优的神经网络模型参数为batch_size=2且epoch=4 150,此时MSE、MAPE、MAE分别为60.191 1、30.732 6、4.803 2。由实际值与预测值的可视化结果图7清楚地看出,经过不断训练的神经网络模型有较高的预测精度,这一结果与研究目的相吻合,进一步针对金融波动性和市场风险问题,提出了对股价预测模型本身的参数进行优化的一种全新思路,保证模型可行性的前提下,调试出的神经网络模型及可用参数更大程度地量化股票市场及趋势预测提供初步方法。

4.1 价值及局限性

神经网络模型可以表现出较好的预测能力,主要价值在于:一是通过随机梯度下降算法优化处理智能板块股票数据,改善了股票市场上数据的量大、非线性问题,在数据处理方面省去了较大的人工成本,优化基本神经网络模型的性能,实际上如果数据规模更大,随机梯度下降法的优势会更加明显。二是神经网络模型借助机器学习的智能性,化繁为简,将复杂的参数通过误差的数据形式展现,并可可视化,所取得的模型参数对股票市场投资者的投资决策与股价预测具有一定的实际应用价值,也可进行神经网络或更优的机器学习的深入探索。但研究仅处于理想状态,没有考虑其他外部因素,如经济发展势头、政策因素、“黑天鹅”事件发生等。事实上,这些外部因素对股票价格有一定的影响,仍可能影响到股票预测模型的准确性。

4.2 对策及建议

对监管者而言,秉持主动监管理念,保护投资者隐私安全。即使机器学习模型能对投资起到参考依据,仍应在股市量化发展的同时,降低股票市场分散化,防范风险的同时提升金融市场的稳定性。

对投资者而言,应在保持理性的同时加强投资决策敏感性。实际的股市操作中应多参考一些政策方针,加强对外界技术指标的研究,探究指标与预测精度之间的关系,这对实际趋势预测有利,尚可在其他研究领域开发神经网络的混合模型,使机

器学习更加智能化,也能更大限度地提高模型在股票市场预测质量。

对资本市场而言,作为一个信息不对称的市场,维护中小投资者利益是关键。一是做好信息披露。尽可能维持市场有效性,使更多的中小投资者能够保持信息对称,做出合理判断。二是数据公开问题。以近期瑞信事件为例,内控与风控机制存在漏洞,财务报表不对称问题导致抛售危机的前几天才察觉风险。因此定期对财务报表等数据核验、提升市场透明度是相当有必要的。三是创新型人才的培养,鼓励发展智能、科技相关产业。创新型人才的寻找在算法越来越接近于人的大脑的时代,用人脑战胜机器可能性极低,如今国内智能产业仍需突破技术壁垒,完善人才体系,加强资本市场的良性竞争。

参考文献

- [1] 汪煜纯. 神经网络在股票预测中的应用[J]. 通讯世界, 2019, 26(1): 15-17.
- [2] MINTARYA L N, HALIM J N M, ANGIE C, et al. Machine learning approaches in stock market prediction: a systematic literature review[J]. Procedia Computer Science, 2023, 216: 96-102.
- [3] 江柏霖, 岳杰, 兰胜杰. 基于 LSTM 神经网络的股票预测系统的研究[J]. 河北建筑工程学院学报, 2021(4): 165-170.
- [4] KUO R J, CHEN C H, HWANG Y C. An intelligent stock trading decision support system through integration of genetic algorithm based fuzzy neural network and artificial neural network[J]. Fuzzy Sets and Systems, 2001, 118(1): 21-45.
- [5] MAJHI R, PANDA G, SAHOO G. Development and performance evaluation of FLANN based model for forecasting of stock markets[J]. Expert Systems with Applications, 2009, 36(3): 6800-6808.
- [6] HAFEZI R, SHAHRABI J, HADAVANDI E. A bat-neural network multi-agent system (BNNMAS) for stock price prediction: case study of DAX stock price[J]. Applied Soft Computing, 2015, 29: 196-210.
- [7] 张晶华, 甘宇健. 基于深度学习支持向量机的上证指数预测[J]. 统计与决策, 2019, 35(2): 176-178.
- [8] 胡玲燕, 朱家明. 基于逐步回归和 BP 神经网络对股票价格预测的对比分析[J]. 辽宁工业大学学报(自然科学版), 2019(3): 201-205, 10.
- [9] 郭元凯. 基于 XGBoost 的混合模型在股票预测中的应用研究[D]. 兰州: 兰州理工大学, 2020.
- [10] KARA Y, ACAR BOYACIOGLU M, BAYKAN Ö K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: the sample of the Istanbul Stock Exchange[J]. Expert Systems with Applications, 2011, 38(5): 5311-5319.
- [11] CHANG T S. A comparative study of artificial neural networks, and decision trees for digital game content stocks price prediction[J]. Expert Systems with Applications, 2011, 38(12): 14846-14851.
- [12] HAJIZADEH E, SEIFI A, FAZEL ZARANDI M H, et al. A hybrid modeling approach for forecasting the volatility of S&P 500 index return[J]. Expert Systems with Applications, 2012, 39(1): 431-436.
- [13] ZHUO X Y, QIN L, CHEN Y, et al. Stock price forecasting based on LLE-BP neural network model[J]. Physica A: Statistical Mechanics and Its Applications, 2020, 553: 124197.
- [14] 魏红伟, 袁江, 田杰. 融合物理模型和神经网络的图像去雾方法与实现[J]. 现代电子技术, 2022(9): 55-60.
- [15] 张驰, 郭媛, 黎明. 人工神经网络模型发展及应用综述[J]. 计算机工程与应用, 2021(11): 57-69.
- [16] 谢琪, 程耕国, 徐旭. 基于神经网络集成学习股票预测模型的研究[J]. 计算机工程与应用, 2019(8): 238-243.
- [17] 黄宏运, 吴礼斌, 李诗争. BP 神经网络在股票指数预测中的应用[J]. 通化师范学院学报, 2016(10): 32-34.
- [18] 曹晓. 基于灰色 GARCH-BP 组合模型的股票收益率预测[D]. 昆明: 昆明理工大学, 2019.
- [19] 李英, 贺春林. 面向深度神经网络训练的数据差分隐私保护随机梯度下降算法[J]. 计算机应用与软件, 2020(4): 252-259.
- [20] 刘书伦, 王东霞. 基于 Paddle 的股票预测深度学习模型[J]. 南京工程学院学报(自然科学版), 2020, 18(2): 76-80.
- [21] WANG YH. Nonlinear neural network forecasting model for stock index option price: Hybrid GJR-GARCH approach[J]. Expert Systems with Applications, 2009, 36(1): 564-570.
- [22] 褚文华. BP 人工神经网络在股票预测中的应用[J]. 哈尔滨商业大学学报(自然科学版), 2019, 35(2): 237-240.
- [23] 张倩玉. 神经网络在股票价格预测模型的研究与应用[D]. 天津: 天津财经大学, 2021.

Share Price Research of Intelligent Industry Plate Based on Neural Network

ZHUANG Yan, WANG Linping

(College of Economics and Management, Fujian Agriculture and Forestry University, Fuzhou 350002, China)

Abstract: For financial volatility and market risk, starting the empirical analysis by neural network model based on four-factor data of more than 70 stocks in smart industry sector in the A-share market for the past ten years. In this model, stochastic gradient algorithm for closing price prediction was used, then the model error and loss function of predicted and actual values was compared, and optimizing from factor selection, algorithm improvement and indicator merit. The results show that closing price is best fitted when neural network model at batch=2 and epoch=4 150, MSE, MAPE and MAE are 60.191 1, 30.732 6, 4.803 2 respectively. The neural network model with these parameters can be used to explore the stock market price trend and provide some reference basis for investors or financial institutions.

Keywords: neural network; smart industry sector; stock prediction; stochastic gradient descent algorithm; data fitting