

# 基于特征选择和深度学习模型的经济效益风险预测

刘海宏<sup>1,2</sup>, 鱼明<sup>3</sup>, 刘静<sup>4</sup>, 吴睿辉<sup>1,2</sup>

(1. 广州南洋理工职业学院经济管理学院, 广东 广州 510900)

(2. 马来西亚吉兰丹大学管理学院, 马来西亚 吉兰丹州哥打巴鲁 16250)

(3. 石河子大学经济与管理学院, 新疆 石河子 832000)

(4. 喀什大学计算机科学与技术学院, 新疆 喀什 844000)

**[摘要]** 大数据、云计算和人工智能技术的结合显著提升了企业金融数据处理能力。为提高对中小企业经济效益风险预测的准确性和可靠性,提出了基于多元宇宙优化(multi-verse optimization, MVO)算法和双向门控递归单元(bidirectional gated recurrent units, BiGRU)的经济效益风险预测框架。首先,对复杂金融数据进行特征归一化。其次,使用 MVO 算法选出最优特征子集。其后,利用 BiGRU 深度学习模型完成对中小企业经济效益风险的评估。利用基于模型的序贯优化(sequential model-based algorithm configuration, SMAC)算法对 BiGRU 模型进行参数调优,优化 BiGRU 模型的参数配置,提高模型的性能和泛化能力。SMAC 算法可以自动搜索参数空间中的最佳组合,从而找到最优的模型配置。实验结果表明,所提混合模型在预测中小企业经济效益风险任务中表现出较高的准确性和预测能力,优于同类先进方法,证实了特征选择和深度学习模型在经济效益风险分析中的潜力和重要性。

**[关键词]** 经济效益风险预测,深度学习,特征选择,多元宇宙优化,双向门控递归单元

**[中图分类号]** TP391 **[文献标志码]** A **[文章编号]** 1672-1292(2024)04-0087-06

## Economic Benefit Risk Prediction Based on Feature Selection and Deep Learning Model

Liu Haihong<sup>1,2</sup>, Yu Ming<sup>3</sup>, Liu Jing<sup>4</sup>, Wu Ruihui<sup>1,2</sup>

(1. School of Economics and Management, Guangzhou Nanyang Polytechnic College, Guangzhou 510900, China)

(2. School of Management, Universiti Malaysia of Kelantan, Kota Bharu, Kelantan 16250, Malaysia)

(3. School of Economics and Management, Shihezi University, Shihezi 832000, China)

(4. School of Computer Science and Technology, Kashi University, Kashi 840000, China)

**Abstract:** The combination of big data, cloud computing and artificial intelligence technologies has significantly enhanced the capability of enterprise financial data processing. In order to improve the accuracy and reliability of financial risk prediction for small and medium-sized enterprises (SMEs), an financial risk prediction framework based on multi-verse optimization (MVO) algorithm and bidirectional gated recurrent units (BiGRU). Initially, complex financial data are subjected to feature normalization, followed by the selection of the optimal feature subset using the MVO algorithm. Subsequently, the evaluation of economic benefit risk for SMEs is accomplished using the BiGRU deep learning model. The sequential model-based algorithm configuration (SMAC) is employed to perform parameter tuning for the BiGRU model, optimizing its parameter configuration to enhance model performance and generalization ability. The SMAC algorithm automatically searches for the best combination of parameters in the parameter space, thereby identifying the optimal model configuration. Experimental results demonstrate that the proposed hybrid model exhibits higher accuracy and predictive capability in the task of predicting financial risk for SMEs, outperforming similar state-of-the-art methods, thereby confirming the potential and importance of feature selection and deep learning models in economic benefit risk analysis.

**Key words:** financial risk prediction, deep learning, feature selection, multi-verse optimization, bidirectional gated recurrent units

收稿日期: 2024-05-14.

基金项目: 广东省教育厅项目(2021GXJK595、2021TSZK021)、广东省哲学社会科学规划项目(GD22XYJ28).

通讯作者: 吴睿辉, 副教授, 博士, 研究方向: 数字经济、人工智能. E-mail: liu8928114@sina.com

经济效益风险预测(financial risk prediction, FRP)对于企业、政府和其他利益相关者的决策过程具有重要的指导作用<sup>[1]</sup>. FRP 模型可以帮助企业和金融机构确定未来项目、政策或投资的潜在风险,并提供决策支持<sup>[2]</sup>. 运用 FRP,政府和金融机构可更有效地分配资源,通过将资源重点投入到具有较低风险并可能带来更高回报的项目或政策中,最大化经济效益<sup>[3]</sup>.

统计方法在 FRP 中发挥重要作用,可以用于数据分析、关联分析、时间序列分析、风险评估等多个方面,帮助决策者更好地理解经济风险并做出相应的决策<sup>[4]</sup>. 通过对历史经济数据进行描述统计分析,包括计算平均值、标准差、变异系数等指标,帮助理解数据的基本特征和分布情况<sup>[5]</sup>. 通过回归分析等方法,可探索经济效益与各种因素(如市场因素、政策因素、竞争因素等)之间的相关性,并评估这些因素对经济效益的影响程度. 通过识别数据中的趋势、季节性和周期性,可预测未来的经济效益,并评估不确定性和风险<sup>[6]</sup>. 通过建立概率分布模型,可评估不同经济效益水平的概率分布. 但传统统计方法多基于线性假设,可能会导致模型拟合不足,无法准确反映实际情况. 此外,由于忽视了数据的时序动态性,无法充分利用时间序列数据的信息,导致预测结果不准确.

随着人工智能(artificial intelligence, AI)的迅速发展, AI 模型在 FRP 领域的应用呈现出越来越多的潜力,可提供更准确、更智能的预测能力<sup>[7]</sup>. 但在高维经济数据中存在各种特征导致了低互操作性、过拟合和高计算复杂性问题. 解决此问题的便利方法是通过特征选择方法减少可用特征的数量. 文献[8]采用长短期记忆(long short-term memory, LSTM)模型作为基准预测模型,基于有形资产回报率、销售价格比和市盈率进行预测,以评估企业经济效益风险程度,文献[9]提出了结合互补经验模态分解(complete ensemble empirical mode decomposition, CEEMD)和 LSTM 的 FRP 方法,将 CEEMD 作为顺序平滑和分解模型,分解不同时间序列尺度的趋势/波动,生成一系列具有不同特征尺度的本征模态函数,其后将高级抽象特征分别输入到 LSTM 网络中完成预测. 文献[10]提出的 FRP 方法利用象群优化(elephant herd optimization, EHO)算法完成特征选择,并结合改进水波优化(modified water wave optimization, MWWO)和深度信念网络(deep belief network, DBN)完成分类预测.

本文提出了一种面向中小企业的优化深度学习 FRP 模型,以确定中小企业的经济效益状况. 所提方法创新点列举如下:

(1)对归一化后的经济效益数据,使用多元宇宙优化(multi-verse optimization, MVO)算法从复杂数据中选择最具信息量的特征子集,有效识别对 FRP 预测最有贡献特征的最佳子集.

(2)使用双向门控递归单元(bidirectional gated recurrent units, BiGRU)模型有效处理序列数据,捕捉数据中的复杂时间依赖关系. 通过基于模型的序贯优化(sequential model-based algorithm configuration, SMAC)算法进行参数调优,自动搜索最佳参数组合,优化 BiGRU 模型的性能和泛化能力,从而提高模型在 FRP 任务中的准确性和稳健性.

## 1 本文方法

所提 FRP 方法包括数据预处理,基于 MVO 算法的最佳特征子集选择,以及结合 BiGRU 模型和 SMAC 算法的预测分类,图 1 给出了所提 MVO-BiGRU 方法的整体流程.

### 1.1 数据预处理

经济效益数据具有极高的复杂性. 在数据预处理中,所提方法采用线性变换技术进行数据归一化. 数据归一化可以将数据的取值范围限制在一个较小的区间内,有助于加速深度学习模型的收敛速度. 归一化后的数据使得模型对于输入数据的变化更加稳定,减少了模型在训练过程中的波动性<sup>[11]</sup>. 通过消除不同特征之间的尺度差异,使得模型更加关注数据本身的特征,有助于提高模型的泛化能力.

数据归一化可表示为:

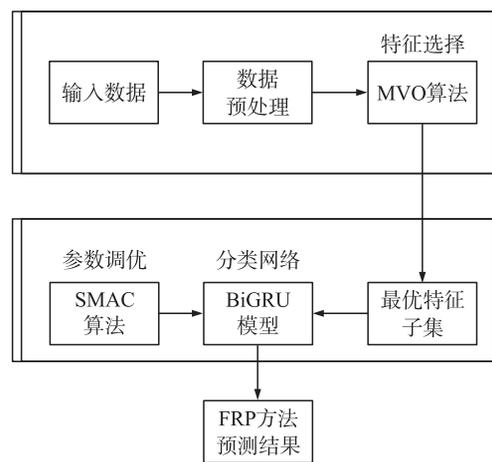


图 1 方法流程图

Fig. 1 The flowchart of the proposed method

$$x_{\text{norm}} = \frac{(x - X_{\min})}{X_{\max} - X_{\min}} (X'_{\max} - X'_{\min}) - X'_{\min}. \quad (1)$$

式中,  $x$  为原始数据某个特征值.  $x_{\text{norm}}$  为归一化后特征值.  $X_{\min}$  和  $X_{\max}$  分别为该特征值在数据集中的最小值和最大值.  $X'_{\max}$  和  $X'_{\min}$  分别为新的最大值和最小值. 由此,将  $X$  线性地映射到  $[X'_{\min}, X'_{\max}]$  内.

## 1.2 特征选择

MVO 算法源于宇宙模型,通过模拟多个宇宙间的物质交换来寻找最优解. 该算法的主要灵感来源于多元宇宙存在理论及其通过黑洞、白洞和虫洞进行交互的概念<sup>[12]</sup>. 作为一种基于群体的随机算法,旨在利用一组解来近似全局最优解. 该算法需要计算两个关键参数来更新解,即虫洞存在概率 (wormhole existence probability,  $WEP$ ) 和行进距离比率 (traveling distance rate,  $TDR$ ):

$$WEP = a + t \cdot \left( \frac{b-a}{T} \right), \quad (2)$$

$$TDR = 1 - \frac{t^{1/p}}{T^{1/p}}. \quad (3)$$

式中,  $a$  为最小值,  $b$  为最大值,  $t$  为当前迭代次数,  $T$  为最大迭代次数,  $p$  为利用精度.

$TDR$  中的利用率与  $p$  值成正比. 完成  $WEP$  和  $TDR$  计算后,对解的位置进行更新. 令  $r_1, r_2, r_3$  为  $[0, 1]$  区间内的随机数,若  $r_1 < WEP$ ,则有:

$$x_i^j = \begin{cases} x_j + TDR + (ub_j - lb_j) \cdot r_3 + lb_j, & r_2 < 0.5, \\ x_j - TDR + (ub_j - lb_j) \cdot r_3 + lb_j, & r_2 \geq 0.5. \end{cases} \quad (4)$$

若  $r_1 \geq WEP$ ,则  $x_i^j = x_{\text{RW}}^j$ . 式中,  $x_j$  为最优个体的第  $j$  个元素,  $lb_j$  和  $ub_j$  分别是第  $j$  个元素的下界和上界,  $x_i^j$  表示第  $i$  个个体的第  $j$  个参数,  $x_{\text{RW}}^j$  则是由轮盘赌选择机制选中的解的第  $j$  个元素. 由此,可基于当前  $WEP$  获得的最佳个体而更新. 若  $r_2 < 0.5$ ,要求获得最优解的第  $j$  个维度的值. 优化过程中,  $WEP$  逐渐增加,以增加获得最优解的利用率. 为避免陷入局部最优,将解  $i$  中的第  $j$  个变量替换为轮盘赌选择的解中的变量. 由此,当前解被认为存在黑洞,而最优解则包含白洞. 白洞根据适应度值使用轮盘赌选择,黑洞根据适应度值反比例创建. 由此,利用迭代过程中的最优解改善不良解,并通过变量交换提高探索能力.

MVO 算法首先生成一组随机解,并计算其对应目标值. 然后,用式(4)重复更新解的位置,直到满足终止条件为止. 同时,随机参数 ( $r_1, r_2, r_3$ )、 $WEP$  和  $TDR$  也会针对每个解进行更新.

## 1.3 分类网络

门控递归单元 (gated recurrent unit, GRU) 是 LSTM 的一种变体,使用门控机制控制输入、记忆等信息,在当前时间进行预测<sup>[13]</sup>. 与 LSTM 的结构相比,该网络将输入门和遗忘门合并为单个更新门,去除了输出门,并添加了重置门,减少了参数并提高了计算效率. 更新门控制了当前状态中保留多少先前状态信息,较高的值表示保留了更多的先前状态信息. 重置门控制了当前状态与先前信息相结合的程度,较小的值表示更多的信息被忽略. 更新门和重置门的计算可表示为:

$$z_t = \sigma(\mathbf{w}_z [h_{t-1}, x_t] + b_z), \quad (5)$$

$$r_t = \sigma(\mathbf{w}_r [h_{t-1}, x_t] + b_r). \quad (6)$$

式中,  $x_t$  为当前时刻输入,  $h_{t-1}$  是上一时刻的状态,  $\sigma$  为 sigmoid 激活函数,  $\mathbf{w}_z$  和  $\mathbf{w}_r$  分别为更新门和重置门的权重矩阵,  $b_z$  和  $b_r$  为相应偏置.

BiGRU 是 GRU 的改进版本,添加了神经网络对未来信息的学习功能,从而克服了传统 GRU 只能处理历史信息的缺点<sup>[14]</sup>. BiGRU 的网络结构如图 2 所示,由前向 GRU 和反向 GRU 组成,网络的输出是从前向和反向输出的叠加中获得的. 通过这样的结构,可为经济效益预测的输出层提供完整的输入序列上下文信息,有效提高了网络的学习能力.

BiGRU 的输出可表示为:

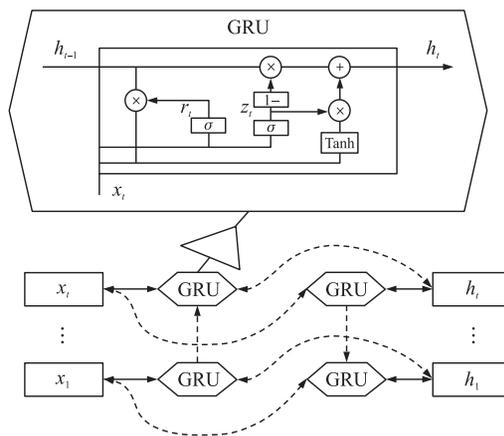


图 2 BiGRU 网络结构

Fig. 2 Network structure of BiGRU

$$\vec{h}_t = \text{GRU}(x_t, \vec{h}_{t-1}), \quad (7)$$

$$\overleftarrow{h}_t = \text{GRU}(x_t, \overleftarrow{h}_{t-1}), \quad (8)$$

$$h_t = \vec{w}_t \vec{h}_t + \overleftarrow{w}_t \overleftarrow{h}_t + b_t. \quad (9)$$

式中,  $x_t$  为时刻  $t$  的隐藏层状态.  $\vec{h}_t$  和  $\overleftarrow{h}_t$  分别为时刻  $t$  的前向隐藏层和反向隐藏层的输出.  $\vec{w}_t$  和  $\overleftarrow{w}_t$  分别表示与时刻  $t$  的 BiGRU 对应的前向隐藏层状态  $\vec{h}_t$  和反向隐藏层状态  $\overleftarrow{h}_t$  相关联的权重.  $b_t$  为偏置.

#### 1.4 SMAC 超参数调优

在神经网络中,超参数的选择非常重要,决定了模型是否处于最佳性能状态并能够获得良好的结果. BiGRU 网络包含许多超参数,其中离散变量包括递归单元中的节点数量、批大小和完全连接层中的节点数量等,连续变量则包括初始学习率等. 手动调整超参数极为耗时,基于高斯过程的传统贝叶斯优化则仅能处理连续参数空间变量.

所提方法使用 SMAC 算法进行自动超参数优化. SMAC 算法是基于随机森林(random forest, RF)的贝叶斯优化算法<sup>[15]</sup>. RF 的训练和预测时间复杂度较低,因此在 SMAC 算法中可以轻松地对候选点进行采样. 此外,RF 擅长处理离散值输入,适用于较为复杂的高维超参数空间. 算法如表 1 所示.

表 1 SMAC 算法  
Table 1 SMAC algorithm

算法	SMAC 算法
1.	随机初始化 $M$ 个点, $\{(x_1, f(x_1)), (x_2, f(x_2)), \dots, (x_M, f(x_M))\}$ , 其中, $x_M$ 为模型的超参数, $f(x_M)$ 为损失函数;
2.	令 SMAC 算法的最大迭代次数为 $N$ ;
3.	使用初始化的 $m$ 个点训练 RF 模型;
4.	if $n \leq N$ then 使用大规模随机抽样方法生成候选点,并将候选点引入已训练 RF,基于结果计算平均值、标准差、期望改善(expected improvement, EI) 采集函数 $a_n(x)$ ;
5.	将使 $a_n(x)$ 最小化的点选择为 $x_{n+1}$ ;
6.	将 $x_{n+1}$ 输入模型,得到 $f(x_{n+1})$ ;
7.	更新 $n = n+1$ ,使用当前 $n$ 个点重新训练 RF;
8.	合并所有验证数据,并选择使 $f(x)$ 最小化的点,完成搜索.

## 2 实验

### 2.1 数据集

使用 FRP 研究中常用的数据集 German credit 和 Australian credit,评估所提方法在 FRP 任务中的性能. 数据集 German credit 为德国信用数据集,包含了德国银行客户信息以其信用申请的审批结果. 该数据集包含 1 000 个样本,每样本共 24 个特征. 特征包含定性和定量信息,如客户收支情况、贷款用途、每月还款额等. 审批结果为有风险和无风险两类. Australian credit 也是常用的数据集 FRP,包含共计 690 个样本和 24 个特征<sup>[16-17]</sup>.

### 2.2 实验平台和评估指标

所提方法的实验环境为 Win10 操作系统,硬件配置为 Intel i5-12400 CPU, NVIDIA GeForce RTX 3080 GPU 和 32 GB RAM. 使用 TensorFlow 2.1.0 和 Cuda 10.2 框架,并使用 Python 3.7 编程语言.

在分析所提基于 MVO 的特征选择方法的性能时,使用平衡分类成本(balanced classification cost, BCC)指标. BCC 综合考虑分类任务中的不平衡性,将不同类别的错误分类给予不同的权重,然后计算加权后的分类错误率.

$$BCC = \frac{FP \cdot w_{FP} + FN \cdot w_{FN}}{TP + FN + TP + FN}. \quad (10)$$

式中,  $FP$  为将负例误分类为正例的数量.  $FN$  为将正例误分类为负例的数量.  $TP$  为正确将正例分类为正例的数量.  $TN$  为正确将负例分类为负例的数量.  $w_{FP}$  和  $w_{FN}$  分别为误分类负例和正例的权重.

在 FRP 评估中,使用常用的灵敏度( $Sen$ )、准确度( $Acc$ )和  $F_1$  得分( $F_1$ )指标. 灵敏度反映模型对正例

的识别能力,准确率反映模型整体的分类准确程度, $F_1$ 得分则综合考虑了模型的精确度和召回率:

$$Sen = \frac{TP}{TP+FN}, \quad (11)$$

$$Acc = \frac{TP+TN}{TP+TN+FP+FN}, \quad (12)$$

$$F_1 = \frac{2 \cdot \frac{TP}{TP+FP} \cdot \frac{TP}{TP+FN}}{\frac{TP}{TP+FP} + \frac{TP}{TP+FN}}. \quad (13)$$

### 2.3 实验结果

表 2 给出了所提方法使用 MVO 算法,在实验数据集上选出的特征子集.从结果中可发现,MVO 算法在数据集 German credit 上选择 11 个特征,在数据集 Australian credit 上选择 8 个特征. MVO 算法通过探索和利用平衡,既能够广泛地搜索特征空间以发现新的解,又能够充分利用已有的信息,从而在特征选择过程中取得较好的平衡.通过特征选择,可以减少不相关或冗余的特征,降低了模型的复杂度,有助于减少过拟合的风险.

表 3 给出了在所提方法中,分别使用蚁群优化(ant colony optimization,ACO)算法、灰狼优化(grey wolf optimizer,GWO)算法和粒子群优化(particle swarm optimization,PSO)算法与 MVO 算法,在数据集 German credit 上不同迭代下的 BCC 结果.从中可发现,所提方法使用的 MVO 算法取得了最好性能,这是因为 ACO 算法、GWO 算法和 PSO 算法通常是基于群体的优化算法,它们可能会陷入局部最优解而无法全局搜索到最优解.与之相比,MVO 算法通过模拟宇宙中的黑洞和白洞等机制,具有更强的全局搜索能力,更有可能找到最优解.此外,ACO 算法、GWO 算法和 PSO 算法不够灵活,对于经济效益数据集中复杂的数据分布和特征之间的关系,无法进行有效的适应性调整,性能劣于 MVO 算法.

表 2 特征选择结果

Table 2 The results of feature selection

数据集	选定特征
German credit	1,3,7,8,9,10,12,14,18,21,23
Australian credit	1,2,4,8,9,11,12,13

表 3 数据集 German credit 上的 BCC 结果

Table 3 BCC results on dataset German credit

迭代次数	ACO 算法	GWO 算法	PSO 算法	MVO 算法	迭代次数	ACO 算法	GWO 算法	PSO 算法	MVO 算法
1	16.77	17.82	18.95	12.35	6	16.72	17.53	19.33	11.43
2	15.72	17.53	18.05	13.01	7	15.39	18.22	18.75	12.81
3	16.28	16.92	18.11	13.25	8	17.82	17.45	17.99	11.44
4	14.92	16.99	17.92	12.95	9	16.92	17.32	18.52	12.55
5	16.55	18.05	19.73	12.75	10	16.58	17.19	18.74	12.08

表 4 和图 3 分别给出了不同方法在数据集 German credit 和 Australian credit 上执行 FRP 任务时的结果.从结果中可发现,本文所提方法在两个数据集上均取得了最优性能.证明本文所提方法综合利用了 MVO 算法进行特征选择、BiGRU 模型进行分类和 SMAC 算法进行参数优化,充分利用了各种算法的优势,从而提高了整体性能.

表 4 不同方法在数据集 German credit 的性能比较

Table 4 Performance comparison of different methods in dataset German credit

运用方法的来源	Sen	Acc	$F_1$
文献[8]	71.95	73.37	71.45
文献[9]	81.79	82.95	80.30
文献[10]	90.11	92.54	91.03
本文	96.52	98.43	97.52

采用了 MVO 算法进行特征选择,相比于文献[10]中使用的象群优化算法,MVO 算法可能具有更强的全局搜索能力和更好的适应性,能够更有效地选择到与分

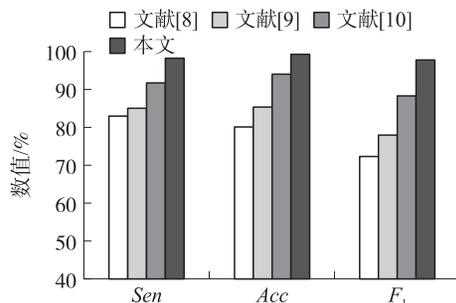


图 3 不同方法在数据集 Australian credit 上的性能比较  
Fig. 3 Performance comparison of different methods in dataset Australian credit

类任务相关的特征子集. 与文献[8]中采用的 LSTM 模型相比,所提出的方法使用了 BiGRU 模型,该模型在处理时间序列数据方面具有更好的表现,能够更好地捕捉到序列数据中的长期依赖关系. 所提方法使用了 SMAC 算法对 BiGRU 模型的参数进行优化,SMAC 算法采用了序列模型优化的方法,结合了贝叶斯优化和随机搜索的思想,在搜索过程中能够同时考虑探索性和利用性,具有较强的全局搜索能力,能够在参数空间中找到较优的解.

### 3 结论

本文提出了一种基于 MVO 算法和 BiGRU 的经济效益风险预测框架,以提高对中小企业经济效益风险预测的准确性和可靠性. 通过对经济数据进行特征归一化和特征选择,结合 BiGRU 以及 SMAC 算法的使用,所提混合模型在预测中小企业经济效益风险任务中表现出较高的预测能力. 实验结果表明,采用 MVO 算法进行特征选择,能够有效地识别出对 FRP 任务具有最大贡献的特征子集,提高了模型的特征表达能力. BiGRU 模型能够有效处理序列数据,捕捉数据中的复杂时间依赖关系,而通过 SMAC 算法进行参数优化,进一步提高了模型的性能和泛化能力. 所提方法在解决中小企业经济效益风险预测问题上具有很高的应用价值.

#### [参考文献](References)

- [1] PENG X, HUANG H. Fuzzy decision making method based on CoCoSo with critic for financial risk evaluation [J]. *Technological and Economic Development of Economy*, 2020, 26(4): 695–724.
- [2] 杨德杰,章宁,袁戟,等. 基于堆栈降噪自编码网络的个人信用风险评估方法[J]. *计算机科学*, 2019, 46(10): 7–13.
- [3] 李庆涛,林培光,王基厚,等. 基于板块效应的深度学习股价走势预测方法[J]. *南京师范大学学报(工程技术版)*, 2022, 22(1): 30–38.
- [4] 王立凯,曲维光,魏庭新,等. 基于深度学习的中文零代词识别[J]. *南京师范大学学报(工程技术版)*, 2021, 21(4): 19–26.
- [5] LI X, WANG J, YANG C. Risk prediction in financial management of listed companies based on optimized BP neural network under digital economy[J]. *Neural Computing and Applications*, 2023, 35(3): 2045–2058.
- [6] 苏云鹏,杨宝臣,周方召. 我国市场债券收益的可预测性及其经济价值研究[J]. *管理科学学报*, 2019, 22(4): 27–52.
- [7] KUMAR D, SARANGI P K, VERMA R. A systematic review of stock market prediction using machine learning and statistical techniques[J]. *Materials Today: Proceedings*, 2022, 49(1): 3187–3191.
- [8] YANG S. A novel study on deep learning framework to predict and analyze the financial time series information[J]. *Future Generation Computer Systems*, 2021, 125(1): 812–819.
- [9] ZHANG Y A, YAN B B, AASMA M. A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM[J]. *Expert Systems with Applications*, 2020, 159(1): 113609.
- [10] METAWA N, PUSTOKHINA I V, PUSTOKHIN D A, et al. Computational intelligence-based financial crisis prediction model using feature subset selection with optimal deep belief network[J]. *Big Data*, 2021, 9(2): 100–115.
- [11] 刘建伟,赵会丹,罗雄麟,等. 深度学习批归一化及其相关算法研究进展[J]. *自动化学报*, 2020, 46(6): 30–38.
- [12] ABUALIGAH L. Multi-verse optimizer algorithm: A comprehensive survey of its results, variants, and applications[J]. *Neural Computing and Applications*, 2020, 32(16): 12381–12401.
- [13] 牛红丽,赵亚枝. 利用 Bagging 算法和 GRU 模型预测股票价格指数[J]. *计算机工程与应用*, 2022, 58(12): 132–138.
- [14] 方娜,余俊杰,李俊晓,等. 基于 CNN-BIGRU-ATTENTION 的短期电力负荷预测[J]. *计算机仿真*, 2022, 39(2): 40–44.
- [15] WU J, CHEN S P, LIU X Y. Efficient hyperparameter optimization through model-based reinforcement learning [J]. *Neurocomputing*, 2020, 409(1): 381–393.
- [16] ALAM T M, SHAUKAT K, HAMEED I A, et al. An investigation of credit card default prediction in the imbalanced datasets[J]. *IEEE Access*, 2020, 8(1): 201173–201198.
- [17] DASTILE X, CELIK T. Making deep learning-based predictions for credit scoring explainable[J]. *IEEE Access*, 2021, 9(1): 50426–50440.

[责任编辑:陈 庆]