

魏玉洁. 基于 Bi-GRU 深度学习的财务报表舞弊检测模型[J]. 智能计算机与应用, 2026, 16(3): 135-141. DOI: 10.20169/j.issn.2095-2163.24050701

# 基于 Bi-GRU 深度学习的财务报表舞弊检测模型

魏玉洁

(合肥工业大学 管理学院, 合肥 230009)

**摘要:** 近年来,深度学习方法在财务报表舞弊检测领域已取得优越的预测性能。然而,现有研究往往忽略了财务数据中的时间序列依赖性,从而降低了财务报表舞弊检测的准确性。为此,本研究设计了一个基于 Bi-GRU 的深度学习方法 (BiGRU-DM),旨在更加准确地实现财务报表舞弊检测。首先,设计了基于 Bi-GRU 的特征提取模块,深入挖掘财务数据中的时间序列依赖性,从而获取深层财务特征。然后,利用注意力机制为不同年份的财务特征自适应地分配权重,实现特征融合。最后,将获取到的融合特征经过 MLP 进行财务报表舞弊检测。为了验证所提 BiGRU-DM 的有效性,本研究收集 CAMAR 数据库中 A 股非金融上市公司的数据进行大量实验。结果表明,BiGRU-DM 的财务报表舞弊检测效果优于其它基准模型。

**关键词:** 上市公司; 财务舞弊; 深度学习; Bi-GRU; 注意力机制

中图分类号: C931.6

文献标志码: A

文章编号: 2095-2163(2026)03-0135-07

## A deep learning method based on Bi-GRU for financial statement fraud detection

WEI Yujie

(School of Management, Hefei University of Technology, Hefei 230009, China)

**Abstract:** In recent years, deep learning methods have achieved superior predictive performance in the field of financial statement fraud detection. However, existing research has overlooked the time series dependencies in financial data, reducing the accuracy of financial statement fraud detection. Therefore, this study designs a deep learning method based on Bi-GRU (BiGRU-DM) to more accurately detect financial statement fraud. Firstly, a Bi-GRU-based feature extraction module is designed to deeply explore the time series dependencies among financial features, thereby obtaining deeper financial features. Then, an attention mechanism is employed to adaptively assign weights to financial features from different years, enabling effective feature fusion. Finally, the fused features are processed through an MLP for financial statement fraud detection. To validate the effectiveness of BiGRU-DM, this study collects data on A-share non-financial listed companies from the CAMAR database and conducts extensive experiments. The results demonstrate that BiGRU-DM outperforms other baseline models in financial statement fraud detection.

**Key words:** listed company; financial statement fraud; deep learning; Bi-GRU; attention mechanism

## 0 引言

财务报表舞弊通常指的是公司为了谋取不正当利益或掩盖真实财务状况,故意利用违反法律法规和会计准则的非法手段,出具虚假的财务报告,欺骗报表使用者的一种行为<sup>[1]</sup>。这种行为不仅严重损害了投资者的相关利益,更对资本市场造成了严重的“信任危机”。若放纵不管,必定会限制资本市场的运转,甚至影响到社会的发展<sup>[2]</sup>。因此,如何避免这种情况出现,真正发挥财务数据的作用,降低财务舞弊的影响和危害,成为现代资本市场监管面临

的一大难题。

对于财务报表舞弊检测来说,财务数据是决定舞弊检测效果的重要因素。因其不仅能够直接反映上市公司财务状况,具有良好的揭示公司财务风险的能力<sup>[3]</sup>。此外,还具有易获取和便于量化建模的优势,因而长期以来被广泛应用于财务报表舞弊检测,并占据主导地位。早期,主要是采用传统的机器学习方法进行财务报表舞弊检测,如决策树(DT)、支持向量机(SVM)和极端梯度提升算法(XGBoost)等<sup>[4-5]</sup>。这些方法能够提取和揭示大量财务数据背后隐藏的真相,并得到了广泛的应用。例如,

Kotsiantis 等学者<sup>[6]</sup> (2006 年) 利用 DT 来检测财务报表舞弊行为, 发现了 6 个与舞弊关联度较高的财务指标。Cecchini 等学者<sup>[7]</sup> (2010 年) 将 SVM 作为财务报表舞弊检测模型, 验证其准确性优于其他基准模型。周卫华等学者<sup>[8]</sup> (2022 年) 将 XGBoost 应用到上市公司财务舞弊检测分析中, 有效提高了舞弊检测模型的准确率。然而, 传统的机器学习方法往往需要基于领域知识和专家经验进行手工特征工程检测, 费时费力。近年来, 大量学者开始关注深度学习方法, 因为该方法能自动地从原始财务数据中提取深层表征, 有效减少手工特征工程所造成的偏差<sup>[9-10]</sup>。常用的卷积神经网络 (CNN)、长短期记忆网络 (LSTM) 和注意力机制 (Attention) 等深度学习方法, 表现出优越的预测性能。例如, Wu 等学者<sup>[11]</sup> (2022 年) 采用卷积神经网络挖掘财务模态内的深层财务特征, 挖掘了财务特征之间的非线性依赖性, 能够有效预测上市公司的财务报表舞弊行为。Wang 等学者<sup>[12]</sup> (2023 年) 提出了基于 MLP 的比率注意力机制、基于 LSTM 的章节注意力机制以及多模态注意力机制的深度学习方法进行财务报表舞弊检测, 结果表明该方法在检测财务报表舞弊方面优于其他基准方法。

值得注意的是, 财务数据具有随时间动态变化的特性, 即存在时间序列依赖性。充分捕捉这一特性有助于揭示上市公司财务状况的变化趋势, 从而提升财务报表舞弊检测的准确性。然而, 现有基于深度学习方法构建的财务报表舞弊检测模型往往忽略了财务数据中的时间序列依赖性, 在一定程度上限制了财务报表舞弊检测效果。

为了解决上述问题, 本文研究提出了一种基于 Bi-GRU 的深度学习方法 (BiGRU-DM), 旨在充分挖掘财务模态数据中的时间序列依赖性, 提取更具表征能力的深层财务特征, 从而提升财务报表舞弊检测效果。首先, 设计了基于 Bi-GRU 的特征提取模块, 深入挖掘财务数据中的时间序列依赖性, 从而获取深层财务特征。然后, 利用注意力机制为不同年份的财务特征自适应地分配权重, 实现特征融合。最后, 采用 MLP 对获取的融合特征进行财务报表舞弊检测。为了验证所提方法的有效性, 本研究使用从中国证券市场会计研究 (CSMAR) 数据库收集的 A 股非金融上市公司数据集进行了大量实验。结果表明, 所提出的 BiGRU-DM 方法实现了最佳的舞弊检测性能, AUC 值达到了 73.06%。

本研究的主要贡献在于:

(1) 提出了一种深度学习的框架, 深入挖掘财务数据中的时间序列依赖信息。

(2) 提出了一种基于 BiGRU 和注意力机制的深度学习方法 BiGRU-DM。在该方法中, 不仅设计了基于 Bi-GRU 的特征提取模块, 充分挖掘财务报表内财务特征的时间序列依赖性, 还设计了基于注意力机制的特征融合模块, 为不同年份合理分配权重。

(3) 在 CSMAR 数据集上进行大量实验。结果表明, 所提 BiGRU-DM 方法优于其他基准模型。

## 1 模型构建

### 1.1 模型结构

本研究设计了一种基于 Bi-GRU 的深度学习方法来检测财务报表舞弊行为。首先, 对资产负债表、利润表和现金流量表三张财务报表数据进行预处理, 将其输入基于 Bi-GRU 的特征提取模块, 捕捉财务特征之间的时间序列依赖性, 提取更有效的深层财务特征; 其次, 对获取的不同年份的财务特征采用基于注意力机制的方法, 分别赋值权重, 得到融合特征; 最后, 采用 MLP 对融合特征进行二分类, 检测出上市公司是否存在财务报表舞弊行为。本研究模型结构如图 1 所示。

### 1.2 特征提取

在检测财务报表舞弊行为的过程中, 财务报表作为企业财务信息的核心载体, 扮演了至关重要的角色。具体来说, 资产负债表反映了企业在特定日期的资产、负债和所有者权益状况, 利润表反映了企业在一定时期内的收入、费用和利润情况, 而现金流量表反映了企业在一定时期内现金流入和流出的情况。这 3 张财务报表相互补充、相互印证, 不仅反映了企业当前的经济状况和经营成果, 同时也映射出公司过去一段时间内的经济活动轨迹和趋势, 呈现出一种长期依赖关系, 即时间序列依赖性<sup>[13]</sup>。然而, 传统的神经网络在处理这类具有时间序列特征的财务报表数据时, 难以充分捕捉这些时间序列依赖性。LSTM 则凭借其独特的记忆单元和门控机制, 有效地解决了这一问题, 能够深入挖掘数据中的时间序列依赖性<sup>[14]</sup>。但是在处理大规模财务报表数据时, LSTM 存在梯度爆炸或消失的潜在问题。相比之下, GRU 简化了门控机制的结构, 主要由重置门和更新门组成, 可以更好地应对梯度问题且有效地捕捉时序数据中的关键信息<sup>[15]</sup>。GRU 的结构如图 2 所示, 由重置门、更新门和候选隐藏层组成。

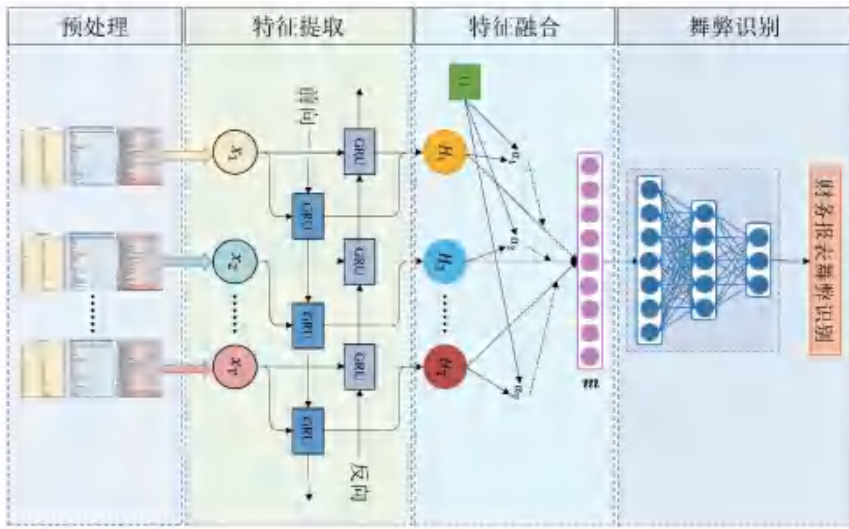


图1 BiGRU-DM 框架

Fig. 1 The framework of the proposed BiGRU-DM

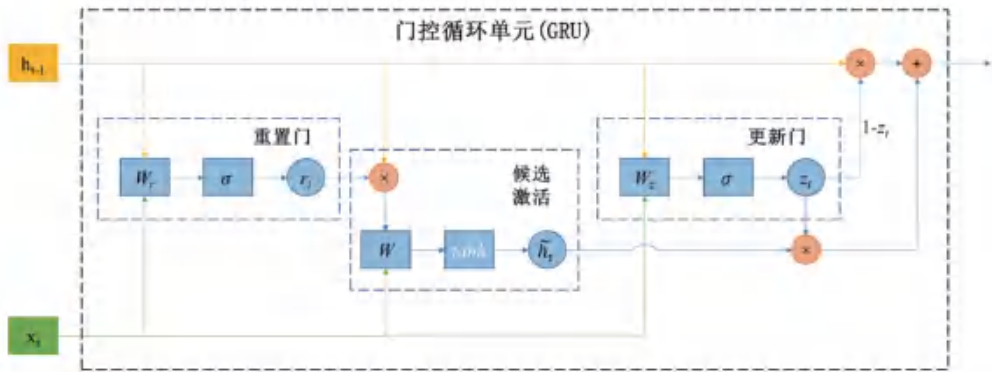


图2 GRU 细节图

Fig. 2 The details of the GRU

研究推得的公式具体如下：

$$\begin{cases}
 \uparrow r_{it} = \sigma(W_{xr}x_{it} + W_{hr}h_{it-1} + b_r) \\
 \uparrow z_{it} = \sigma(W_{xz}x_{it} + W_{hz}h_{it-1} + b_z) \\
 \uparrow \tilde{h}_{it} = \tanh(W_{xh}x_{it} + W_{hh}(r_{it} \odot h_{it-1}) + b_h) \\
 \uparrow h_{it} = (1 - z_{it}) \odot h_{it-1} + z_{it} \odot \tilde{h}_{it}
 \end{cases} \quad (1)$$

其中， $r_{it}$ 、 $z_{it}$  分别表示重置门和更新门； $\sigma$  表示 Sigmoid 激活函数； $\tanh$  表示非线性激活函数； $h_{it-1}$  和  $h_{it}$  分别表示前一时刻的隐藏层状态以及当前时刻的隐藏层状态； $\tilde{h}_{it}$  表示当前时刻的候选隐藏状态； $W_{xr}$ 、 $W_{hr}$ 、 $W_{xz}$ 、 $W_{hz}$ 、 $W_{xh}$ 、 $W_{hh}$  表示权重参数； $b_r$ 、 $b_z$ 、 $b_h$  表示偏置参数；“ $\odot$ ”表示元素乘法。

传统的 GRU 模型存在一定的局限性，往往只考虑序列中单一方向上数据间的相关性，而忽略了对未来信息的考量。相比之下，Bi-GRU 具有前向和后向两个方向的信息传递，能够同时考虑过去和未

来的信息，从而更全面、更深入地捕捉时序数据中的长期依赖关系<sup>[16]</sup>。因此，本研究提出将资产负债表、利润表和现金流量表输入基于 Bi-GRU 的特征提取模块，捕捉其间的时间序列依赖性，进而获取深层的财务表征。Bi-GRU 的公式如下：

$$\vec{h}_{it} = \overrightarrow{\text{GRU}}(x_{it}, \vec{h}_{it-1}) \quad (2)$$

$$\overleftarrow{h}_{it} = \overleftarrow{\text{GRU}}(x_{it}, \overleftarrow{h}_{it+1}) \quad (3)$$

$$h_{it} = [\vec{h}_{it}; \overleftarrow{h}_{it}] \quad (4)$$

其中， $\vec{h}_{it}$  和  $\overleftarrow{h}_{it-1}$  分别表示前向层  $t$  时刻和  $t-1$  时刻隐藏层输出； $\overleftarrow{h}_{it}$  和  $\overleftarrow{h}_{it+1}$  分别表示后向层  $t$  时刻和  $t+1$  时刻隐藏层输出；“ $[\ ]$ ”表示拼接操作。

### 1.3 特征融合

在财务报表舞弊检测中，不同年份的财务数据对于舞弊检测结果的贡献程度存在差异。然而，传统的特征融合方法往往忽略了这种差异性，简单地将所有特征进行拼接或相加。这导致模型无法充分

挖掘与财务报表舞弊行为相关的关键年份信息,从而限制了舞弊检测效果。为了解决这一问题,引入权重分配策略以实现更为精准的特征融合显得尤为重要。注意力机制正是这样一种策略,能够根据各年份数据的重要性和相关性动态分配权重,使模型关注对财务报表舞弊检测更有意义的特征<sup>[17]</sup>。通过运用注意力机制,模型能够自动聚焦于那些与财务报表舞弊行为紧密相关的财务特征,同时降低无关或干扰信息的影响。因此,本文采用注意力机制合理地评估和权衡不同财务特征在舞弊检测中的相对重要性,有效地实现了不同年份财务特征的深度融合,从而提高模型的检测效果。

具体来看,首先将获得的不同财务特征表示为  $H = (h_{i1}, h_{i2}, \dots, h_{iT})$ , 这里  $T$  表示时间序列长度。然后,将财务特征  $H$  作为注意力机制中的键值向量与值向量,  $h_{it}$  与查询向量  $u$  计算生成不同年份财务特征对应的权重值,然后对值向量进行加权融合,具体公式如下:

$$\alpha_u = \frac{\exp(u^T h_{it})}{\sum_T \exp(u^T h_{it})} \quad (5)$$

$$m_i = \sum_{t=1}^T \alpha_u h_{it} \quad (6)$$

其中,  $u$  表示注意力机制中的查询向量,在模型训练过程中优化,并用来与键值向量  $h_{it}$  计算生成注意力权重。通过上述步骤,可以得到考虑各年份财务特征差异化预测能力的更新后的财务特征  $m_i$ 。

#### 1.4 学习策略

基于上述融合得到的融合特征  $m_i$ , 本文利用 MLP 生成最后的财务报表舞弊检测结果:

$$p_i = p(y_i | x_i) = \text{Sigmoid}(W_m m_i + b_m) \quad (7)$$

其中,  $p_i$  表示对样本中标签  $y_i$  的预测概率;  $\text{Sigmoid}(x)$  表示非线性激活函数;  $W_m$  和  $b_m$  表示可学习的参数。这里,  $\text{Sigmoid}$  的数学公式为:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

财务报表舞弊检测任务本质上是一个二分类任务,所以本文通过计算 BCE Loss 损失,衡量模型对舞弊和非舞弊的预测结果与真实标签之间的差异。其计算过程如下:

$$L_{\text{BCE}} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (9)$$

其中,  $N$  表示总样本数;  $y_i$  表示第  $i$  个样本的所

属类别;  $p_i$  表示第  $i$  个样本的预测值。

## 2 实验设计

### 2.1 样本数据选取

本研究以中国证监会、中国深圳、中国上海证券交易所会对因违反会计准则的公司贴上 ViolationType ID P2501 ~ P2506 标签,并受到警告、罚款或禁止进入市场的处罚,作为判断公司样本是否舞弊的依据<sup>[12]</sup>。因为当公司被贴上这些类型的标签时意味着发生财务报表舞弊的风险很高。此外,剔除了金融行业等特殊样本。最终,本研究共收集了 2015 年至 2022 年区间的 4 864 条样本记录,其中 1 645 条被标记为舞弊,3 219 条为非舞弊。

### 2.2 结果评估指标

为了评估方法的有效性,本文采用 AUC 值、一类错误率 (Type I Error) 和二类错误率 (Type II Error) 作为评估指标,旨在全面地评估模型的财务报表舞弊检测效果。具体而言,AUC 值是由 ROC 曲线下方的面积计算而来,其数值越高,则说明模型分类效果越好<sup>[18]</sup>。ROC 曲线的横轴为假正例率 (FPR)、纵轴为真正例率 (TPR)。此外, Type I Error 衡量了非舞弊公司被错误归类为舞弊公司的概率,而 Type II Error 衡量了舞弊公司被错误归类为非舞弊公司的概率。各评估指标的计算公式如下:

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

$$\text{FPR (Type I Error)} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (11)$$

$$\text{Type II Error} = \frac{\text{FN}}{\text{TP} + \text{FN}} \quad (12)$$

其中, TP (True Positive) 表示真正例,即舞弊公司样本中被正确分类的个数; TN (True Negative) 表示真负例,即非舞弊公司样本被正确分类的个数; FP (False Positive) 表示假正例,即非舞弊公司样本中被错误分类为舞弊公司样本的个数; FN (False Negative) 表示假负例,即舞弊公司样本被错误分类为非舞弊公司样本的个数。

### 2.3 模型实现细节

为了验证所提方法的检测性能相对较优,将 BiGRU-DM 与 2 种单一分类器方法 (LR 和 SVM)、3 种集成学习方法 (Bagging、XGBoost 和 RF),以及 2 种深度学习方法 (MLP 和 LSTM) 进行比较。具体而言,LR 作为一种经典的线性分类模型,可基于对数

据特征的线性组合来预测样本属于某一类别的概率。SVM 则是一种强大的非线性分类器,通过构建最优超平面来实现对不同类别样本的分类。Bagging 通过有放回的采样生成多个子数据集,训练多个弱分类器,最终通过投票或平均的方式得出结果。XGBoost 是一种基于梯度提升的集成学习方法,在训练过程中不断拟合上一轮模型的残差,逐步构建多个决策树并将其结果累加起来进行预测。RF 则是通过随机选择特征和样本构建多棵决策树,最终以多数投票的方式确定预测结果。MLP 是由多个神经元层组成,通过非线性激活函数对输入数据进行特征提取和分类。LSTM 是一种擅长处理具有时序性的数据的深度模型,能够捕捉数据中的长期依赖关系。

此外,本文按照 8:2 的比例将数据集划分为训

练集和测试集,以进行实验分析<sup>[19-20]</sup>。为了降低随机性对实验结果的不利影响,并确保实验结果的稳健性,本文对每个训练过程进行了 10 次重复训练,并计算各评估指标的平均值作为模型的最终预测性能指标。训练期间的网络超参数设置如下:优化器设为 Adam,损失函数设为 BCE Loss,学习率设为 0.002,训练轮次设为 150,批次大小设为 128。

### 3 实验结果

#### 3.1 实验结果分析

表 1 呈现了不同评估指标的实验结果,并以加粗字体展示了不同方法下的最优值。可以看出,本文提出的 BiGRU-DM 方法在所有比较方法中均取得了最好的效果,AUC 为 0.730 6、Type I Error 为 0.094 3 和 Type II Error 为 0.244 4。

表 1 对比实验结果

Table 1 Comparative experimental results

方法	AUC		Type I		Type II	
	Mean	Std	Mean	Std	Mean	Std
LR	0.588 5	0.015 4	0.368 9	0.012 3	0.454 2	0.028 9
SVM	0.590 9	0.002 5	0.295 2	0.007 3	0.423 1	0.008 0
Bagging	0.625 5	0.005 1	0.199 7	0.016 3	0.357 5	0.021 9
XGBoost	0.631 8	0.004 5	0.191 4	0.019 3	0.353 3	0.013 3
RF	0.645 9	0.006 6	0.154 9	0.026 2	0.336 7	0.029 0
MLP	0.673 0	0.007 1	0.120 8	0.027 6	0.333 4	0.019 1
LSTM	0.682 4	0.005 2	0.101 9	0.024 5	0.333 1	0.017 9
BiGRU-DM	<b>0.730 6</b>	0.005 9	<b>0.094 3</b>	0.014 7	<b>0.244 4</b>	0.013 0

进一步分析,从 AUC 来看,首先可以发现单一分类器方法 LR 和 SVM 的 AUC 值相对较低。而 Bagging、XGBoost 和 RF 作为集成学习方法,其舞弊检测性能虽优于单一分类器方法,但仍低于深度学习方法 MLP、LSTM 和 BiGRU-DM。这体现了集成学习方法通过结合多个模型,在财务报表舞弊检测中的准确性和稳定性优于单一分类器方法。更重要的是,这也体现了深度学习方法优于传统的机器学习方法,因为深度学习方法能够自动从数据中提取更深层次、更抽象的深层特征,从而能够更有效地检测财务报表舞弊行为。而在深度学习方法中,相较于 MLP 和 LSTM 而言,本文所提 BiGRU-DM 方法取得了最高的 AUC 值,验证了深入挖掘财务模式时间序列依赖性的重要性。从 Type I Error 和 Type II Error 来看,可以发现包括 LR, SVM, Bagging, XGBoost 和 RF 在内的传统机器学习方法,在财务报表舞弊检测中均表现出较低的一类错误率和略高一

些的二类错误率,这表明机器学习方法在准确检测出非舞弊公司样本上表现相对较好。而本文所提 BiGRU-DM 方法的一类错误率和二类错误率均最低,展现了本文所提方法相较于其他对比方法在检测出舞弊公司样本方面的优越性。综上所述,BiGRU-DM 在多个评估指标上均优于其他基准方法,表明其在财务报表舞弊检测任务中能够更好地检测出舞弊公司样本,具有更高的准确性和稳定性。

#### 3.2 消融实验研究

为了验证所提方法 BiGRU-DM 中每个模块对于财务报表舞弊检测的贡献程度,本文进行了消融实验<sup>[21]</sup>。具体而言,本文生成 6 种消融变体,包括去除 Bi-GRU 和 Attention 机制的 MLP、使用 LSTM 替换 Bi-GRU 并去除 Attention 机制的 LSTM、使用 GRU 替换 Bi-GRU 并去除 Attention 机制的 GRU、去除 Attention 机制的 Bi-GRU、使用 LSTM 替换 Bi-GRU 的 LSTM-A,以及使用 GRU 替换 Bi-GRU 的

GRU-A。

消融实验结果如图3所示。由图3可知,包括LSTM、GRU和Bi-GRU在内的具备捕捉时间序列依赖性的消融方法的AUC均优于MLP,这验证了捕捉财务数据之间存在的时间序列依赖性的必要性。具体来看,可以发现GRU和Bi-GRU的AUC值优于LSTM,这表明虽然LSTM方法能够捕捉时间序列依赖性,但其复杂的门控结构可能导致其训练效率不如GRU和Bi-GRU。而Bi-GRU的AUC值优于GRU,验证了进一步考虑时间序列数据的前向和后向依赖有助于更全面地捕捉财务数据中的时间序列

依赖性,从而获得更好的财务报表舞弊检测效果。进一步分析,可以发现LSTM-A、GRU-A和BiGRU-DM方法的AUC值相较于LSTM、GRU和Bi-GRU方法均有所提高,这说明了采用Attention机制充分挖掘不同年份对于财务报表舞弊检测贡献的重要性。综上所述,验证了本文所提出的基于Bi-GRU的特征提取模块以及基于Attention机制的特征融合模块的合理性,通过深入挖掘财务报表内的时间序列依赖性以及不同年份对财务报表舞弊检测的贡献,显著提升了财务报表舞弊检测效果。

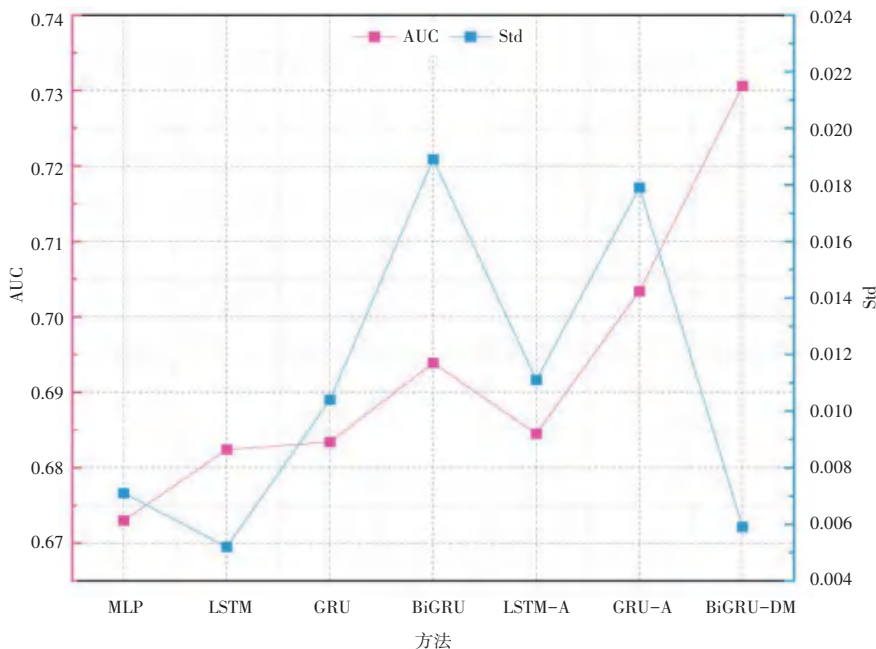


图3 消融实验结果图

Fig. 3 Graph of ablation experiment results

## 4 结束语

财务报表舞弊检测对于保障相关者根本利益,维护资本市场平稳运行具有重大意义。然而,现有研究往往未充分考虑到财务数据中的时间序列依赖性,导致舞弊检测准确性受到限制。为此,本文提出了一个基于Bi-GRU和Attention机制的深度学习方法,旨在深入挖掘财务模态内的时间序列依赖性,提取深层财务特征,从而提高舞弊检测的准确性。具体而言,首先设计了基于Bi-GRU的特征提取模块,提取财务报表内的深层特征。其次,采用注意力机制为不同年份分配合理的权重,进行特征融合。然后,将融合特征经过MLP进行财务报表舞弊检测。最后,利用中国上市公司的数据集进行了实验研究,验证本文所提方法BiGRU-DM的有效性和鲁棒性。

## 参考文献

- [1] ELLIOTT R K, WILLINGHAM J J. Management fraud: Detection and deterrence[M]. New York: Petrocelli Books, 1980.
- [2] 杨清香,俞麟,陈娜. 董事会特征与财务舞弊:来自中国上市公司的经验证据[J]. 会计研究, 2009(7): 64-70.
- [3] ASHTIANI M N, RAAHEMI B. Intelligent fraud detection in financial statements using machine learning and data mining: A systematic literature review [J]. IEEE Access, 2021, 10: 72504-72525.
- [4] GLANCY F H, YADAV S B. A computational model for financial reporting fraud detection [J]. Decision Support Systems, 2011, 50(3): 595-601.
- [5] RAVISANKAR P, RAVI V, RAGHAV A R G, et al. Detection of financial statement fraud and feature selection using data mining techniques [J]. Decision Support Systems, 2011, 50(2): 491-500.
- [6] KOTSIANTIS S, KOUMANAKOS E, TZELEPIS D, et al. Forecasting fraudulent financial statements using data mining [J].

- International Journal of Computational Intelligence, 2006, 3(2): 104-110.
- [7] CECCHINI M, AYTUG H, KOEHLER G J, et al. Detecting management fraud in public companies [J]. Management Science, 2010, 56(7): 1146-1160.
- [8] 周卫华, 翟晓风, 谭皓威. 基于 xgboost 的上市公司财务舞弊预测模型研究 [J]. 数量经济技术经济研究, 2022, 39(7): 176-196.
- [9] LECUN Y, BENGIO Y, HINTON G. Deep learning [J]. Nature, 2015, 521(7553): 436-444.
- [10] SEZER O B, GUDELEK M U, OZBAYGLU A M. Financial time series forecasting with deep learning: A systematic literature review: 2005 - 2019 [J]. Applied Soft Computing, 2020, 90: 106181.
- [11] WU Xiuguo, DU Shengyong. An analysis on financial statement fraud detection for Chinese listed companies using deep learning [J]. IEEE Access, 2022, 10: 22516-22532.
- [12] WANG Gang, MA Jingling, CHEN Gang. Attentive statement fraud detection: Distinguishing multimodal financial data with fine-grained attention [J]. Decision Support Systems, 2023, 167:113913.
- [13] KIM S, KANG M. Financial series prediction using Attention LSTM [J]. arXiv preprint arXiv,1902.10877, 2019.
- [14] SCHMIDHUBER J, HOCHREITER S. Long Short - Term Memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [15] CHO K, MERRIENBOER V B, GULCEHRE C, et al. Learning phrase representations using RNN Encoder-Decoder for statistical machine translation [J]. arXiv preprint arXiv,1406.1078, 2014.
- [16] JAIN V K, TRIPATHI M. An integrated deep learning model for Ethereum smart contract vulnerability detection [J]. International Journal of Information Security, 2024, 23(1): 557-575.
- [17] 陈艺丹, 马可, 李慧斌. 基于全局上下文注意力的风机叶片缺陷检测 [J]. 计算机与数字工程, 2023, 51(11): 2693-2699.
- [18] 刘云菁, 伍彬, 张敏. 上市公司财务舞弊识别模型设计及其应用研究: 基于新兴机器学习算法 [J]. 数量经济技术经济研究, 2022, 39(7): 152-175.
- [19] DOUMPOS M, ANDRIOSPOULOS K, GALARIOTIS E, et al. Corporate failure prediction in the European energy sector: A multi-criteria approach and the effect of country characteristics [J]. European Journal of Operational Research, 2017, 262(1): 347-360.
- [20] JARDIND P. A two-stage classification technique for bankruptcy prediction [J]. European Journal of Operational Research, 2016, 254(1): 236-252.
- [21] YANG Kai, LAU R Y, ABBASI A. Getting personal: A deep learning artifact for text-based measurement of personality [J]. Information Systems Research, 2023, 34(1): 194-222.