

Research on Enterprise Financial Risk Early Warning Based on Deep Learning—Taking the Listed Companies in the Information Service Industry as an Example

Jiajun Liu

Chongqing University of Science & Technology, Chongqing, 401331, China

Abstract

This study focuses on the financial risk prediction of listed companies in the information service industry, aiming to solve the challenges they face in the digital age. By introducing one-dimensional convolutional neural network (CNN) technology, the historical financial data is analyzed in depth to improve the prediction accuracy. The study first collected and processed a large amount of financial data, extracted key temporal features using a one-dimensional convolution kernel, and then designed and implemented a CNN-based model. The experimental results show that the model significantly improves the accuracy and timeliness of early warning, verifies the effectiveness of CNN in the field of financial risk prediction, and provides scientific risk management tools for information service companies. This research provides a direction for the development of intelligent financial early warning system, highlights the potential of deep learning technology in financial analysis, and provides a new path and strategy for the sustainable development of enterprises.

Keywords

information service industry; convolutional neural network; financial early warning; financial crisis

基于深度学习的企业财务风险预警研究——以信息服务业上市公司为例

刘家俊

重庆科技大学, 中国·重庆 401331

摘要

本研究聚焦于信息服务业上市公司的财务风险预测,旨在解决其在数字化时代面临的挑战。通过引入一维卷积神经网络(CNN)技术,深度分析历史财务数据以提高预测准确性。研究首先收集并处理了大量财务数据,利用一维卷积核提取关键时序特征,随后设计并实施了基于CNN的模型。实验结果表明,该模型显著提升了预警的准确性和及时性,验证了CNN在财务风险预测领域的有效性,为信息服务业公司提供了科学的风险管理工具。该研究为智能化财务预警系统的发展提供了方向,突显了深度学习技术在财务分析中的潜力,为企业可持续发展提供了新的路径和策略。

关键词

信息服务业;卷积神经网络;财务预警;财务危机

1 引言

随着全球化和科技的快速发展,信息服务业成为推动现代经济增长的关键力量。尤其在中国,信息服务业上市公司数量的增加,显著推动了经济创新和高质量发展。然而,这些企业在享受数字化带来的便利和机遇的同时,也面临着越来越复杂的财务风险,这些风险源自市场的竞争激烈和经营模式的快

速变化。

传统财务风险预警方法,如财务比率分析和统计模型在应对快速变化的市场和复杂数据结构时显得力不从心^[1]。在1968年,美国学者Altman^[2]开创性地将多变量分析技术应用到财务预警模型中。他利用多元线性判别分析方法对多家财务困境的企业及同数量的稳定企业进行了分析,从中筛选出五个关键的财务指标进而创建了著名的Z-Score模型。发现该模型高效识别期较短,且预测准确率随着时间推移而逐渐降低。除此之外,如Logistic模型^[3]和多元判别分析^[4]这类传统统计方法在某些场景下表现优异,但它们的效果仍受限于统计假设。而如层次分析法等主观赋权的风险评估方法,其结果易受个人偏好影响。TOPSIS^[5]这类客观赋权模型在变

【基金项目】重庆科技大学研究生创新计划项目(项目编号:YKJCX2320910)。

【作者简介】刘家俊(1999-),男,中国重庆人,在读硕士,从事智能财务与大数据应用研究。

量较少时表现良好,但这些模型和方法在处理大规模财务数据方面存在局限且仅适用于短期预测,难以满足信息服务行业上市公司对长期发展的需求。相比之下深度学习技术尤其是卷积神经网络(CNN),在处理大规模和非线性数据集方面展示了其独特的优势。它们能够识别出传统方法难以捕捉的细微风险信号,显著提高预警的准确性和及时性^[6]。

本研究聚焦于信息服务业上市公司,探讨如何利用卷积神经网络建立一个高效的财务风险预警模型。通过深入分析历史财务数据和市场动态,构建一个能够真实反映企业财务风险状况的模型。旨在这一模型不仅能帮助企业提前识别潜在的财务危机,还能为投资者和政策制定者提供科学的决策支持,继而促进整个行业的健康和可持续发展。

2 研究设计

2.1 样本选择

本项研究所使用的数据集选自中国经济金融研究数据库(CSMAR),这是一个集合了中国证券、期货、外汇、宏观经济及行业数据的精准研究型数据库,广泛应用于投资分析和实证研究中。在本研究中,选取了共466家在信息服务行业上市的公司作为分析样本,其中包括21家被特别处理(ST)的公司,其余均为经营正常的企业。

2.2 财务风险预警指标体系

参考相关研究^[7],从偿债能力、经营能力、盈利能力、现金流能力、发展能力五个方面选取财务指标,同时,本研究额外选取了每股指标作为本研究的参考指标,暨共选择6个一级指标和47个二级指标作为反映企业财务危机的指标项。引入每股指标不仅增强了对公司财务状况和股票价值的理解,而且促进了绩效管理和公司治理的进步。详细的各类指标展示如表1所示。

2.3 数据预处理

加载数据集涉及将数据读取到计算机内存中,并执行预处理步骤,包括数据清洗、特征选择和缺失值处理,以提升数据集的品质和完整性。在本研究中,我们分析了2020至2022年间中国信息服务行业的466家A股上市公司的财务数据。我们以企业是否被特别处理(ST)作为财务困境的标志,即连续两年净利润为负且被证监会标记为ST的公司被分类为面临财务危机,其余则被认为财务状况健康。在数据处理阶段,我们删除了财务健康样本中的缺失值,而对危机样本采用了一种保守的方法,用相邻两季度的平均值填补缺失值。经处理后,数据集包含1398个样本,其中63个标记为ST,再通过标准化处理,解决了不同特征尺度差异的问题,加速了模型的收敛速度,并提高了可解释性。最后根据时间序列将数据集划分为训练集(2020年和2021年数据)和测试集(2022年数据),从而评估模型的预测能力以达到企业财务风险预警的目的。

本研究数据来源于CSMAR数据库。本研究所有实验均基于Pytorch深度学习框架的PyCharm编程软件完成。

表1 财务指标

指标类型	序号	指标
每股指标	X ₁	摊薄每股收益(元)
	X ₂	加权每股收益(元)
	X ₃	每股收益_调整后(元)
	X ₄	每股净资产_调整前(元)
	X ₅	每股净资产_调整后(元)
	X ₆	每股经营性现金流(元)
	X ₇	每股资本公积金(元)
	X ₈	每股未分配利润(元)
盈利能力	X ₉	总资产利润率(%)
	X ₁₀	主营业务利润率(%)
	X ₁₁	总资产净利润率(%)
	X ₁₂	成本费用利润率
	X ₁₃	营业利润率(%)
	X ₁₄	主营业务成本率(%)
	X ₁₅	销售净利率(%)
	X ₁₆	股本报酬率(%)
	X ₁₇	净资产报酬率(%)
	X ₁₈	资产报酬率(%)
	X ₁₉	三项费用比重
	X ₂₀	非主营比重
	X ₂₁	主营利润比重
营运能力	X ₂₂	主营业务利润(元)
	X ₂₃	扣除非经常性损益后的净利润(元)
	X ₂₄	应收账款周转率(次)
	X ₂₅	应收账款周转天数(天)
	X ₂₆	存货周转天数(天)
	X ₂₇	存货周转率(次)
	X ₂₈	流动资产周转天数(天)
	X ₂₉	流动资产周转率(次)
	X ₃₀	股东权益周转率(次)
	成长能力	X ₃₁
X ₃₂		净资产增长率(%)
X ₃₃		总资产增长率(%)
偿债能力	X ₃₄	流动比率
	X ₃₅	速动比率
	X ₃₆	现金比率(%)
	X ₃₇	利息支付倍数
	X ₃₈	股东权益比率(%)
	X ₃₉	负债与所有者权益比率(%)
	X ₄₀	资本固定化比率(%)
	X ₄₁	产权比率(%)
	X ₄₂	资产负债率(%)
	X ₄₃	总资产(元)
现金流量	X ₄₄	经营现金净流量对销售收入比率(%)
	X ₄₅	资产的经营现金流量回报率(%)
	X ₄₆	经营现金净流量对负债比率(%)
	X ₄₇	现金流量比率(%)

2.4 建立卷积神经网络模型

本研究使用一维卷积神经网络(1D CNN)处理财务时间序列数据,旨在捕获潜在的趋势和模式。模型结构包括输入层、卷积层、池化层和全连接层。输入层接收的张量形状为[batch_size, 47, 1],代表1398家企业在47个财务指

标上的数据。卷积层通过滑动卷积核提取局部特征，并经过 ReLU 激活函数处理。池化层采用最大池化，降低特征维度。全连接层将卷积层提取的特征映射到最终的高风险和低风险分类。每个线性层后都引入了 ReLU 激活函数以增强非线性学习能力。

3 模型分析

3.1 训练模型

在数据预处理阶段，将整体数据集划分并格式化为神经网络可识别的张量结构。数据标准化确保模型在各特征维度上能以均衡的方式学习。结合多个层次构建卷积神经网络 CNN 模型，使用交叉熵损失函数评估模型输出。采用 Adam 优化器进行训练，以提高整体预测精度。这种优化策略与模型架构相结合，确保在训练和测试集上都有较高的性能。

3.2 模型预测

在经过 140 个训练周期 (Epochs) 后，本研究中的模型在测试数据集上展示了极高的准确性，预测准确率高达 99.97%。这一结果说明模型具备优秀的预测能力。然而，单一的准确率指标往往无法全面反映模型在处理正负样本本方面的表现。因此，为了深入了解模型的实际效能，我们必须进行更综合的定量评估。

这包括但不限于使用混淆矩阵来分析模型对正例和负例的识别能力，以及计算如精确率 (Precision)、召回率 (Recall) 和 F1 分数等指标。通过这些衡量工具，我们可以更准确地评估模型在各类样本上的分类效果，从而确保模型在实际应用中的可靠性和有效性。

3.3 模型评估

3.3.1 混淆矩阵

混淆矩阵 (Confusion Matrix) 是一个用于评估分类模型性能的表格，在机器学习领域中广泛应用。它以表格形式呈现，真实情况沿行排列，模型预测则沿列展开。在混淆矩阵中，TP (True Positives) 表示正类别正确被识别的情况，FN (False Negatives) 表示正类别被错误地识别为负类别的情况，FP (False Positives) 表示负类别被错误地识别为正类别的情况，而 TN (True Negatives) 表示负类别正确被识别的情况 (见表 2)。下面是二分类问题的混淆矩阵示例。

表 2 混淆矩阵

	预测为正例	预测为负例
实际为正例	True Positive (TP)	False Negative (FN)
实际为负例	False Positive (FP)	True Negative (TN)

由 Python 程序生成的混淆矩阵如图 1 所示。

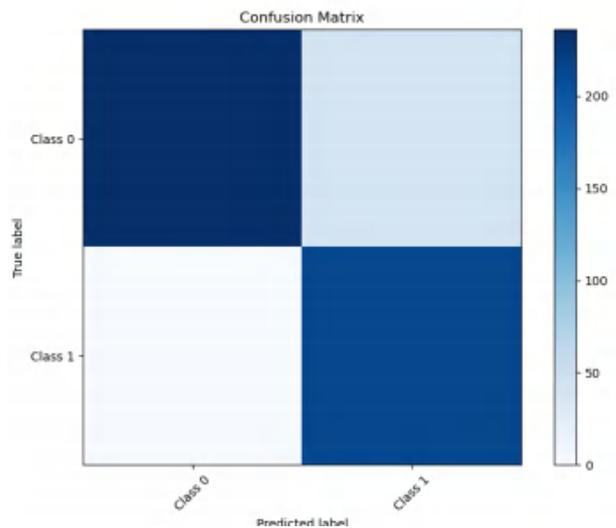


图 1 混淆矩阵

如表 3 所示，在模型性能评估中，精确率是一个关键指标，衡量了被模型预测为正类中真正为正类的比例。本研究中，精确率达到 85.20%，表明模型在识别潜在高风险企业方面表现出高准确性。召回率衡量了模型对实际正例的识别能力，即在所有真正的正例中，有多少被模型正确预测。本研究的召回率为 100%，显示了模型在覆盖所有真实正类样本方面的优异能力。但较高的召回率可能伴随着增加的假阳性。为了平衡精确率和召回率，F1 值成为一个重要的综合评估指标。F1 值通过精确率和召回率的调和平均来评价分类器的总体性能，较高的 F1 值表明分类器在维持精确性和覆盖率之间达到了良好的平衡。在本研究中，F1 分数为 0.92，表明本研究采用的一维卷积神经网络在预测财务风险方面具有强大的综合性能。

表 3 评价指标汇总

Accuracy	Precision	Recall	Negative Coverage	F1 Score
99.97%	85.20%	100.00%	75.00%	0.9200

3.3.2 ROC 曲线

ROC 曲线是评估二元分类模型性能的核心工具，通过展示真阳性率 (TPR，也称为灵敏度) 和假阳性率 (FPR，即 1-特异性) 之间的关系提供了直观的图形表示。在 ROC 曲线中，真阳性率在纵轴上，假阳性率在横轴上，显示了模型性能随分类决策阈值变化的轨迹。每个阈值下的模型表现由 ROC 曲线上的点表示，这种动态展示方式有助于理解模型在不同操作条件下的行为。此外，AUC (ROC 曲线下的面积) 是一个重要的度量指标，量化了模型区分正负类的整体能力。AUC 值的范围从 0 到 1，较高的值表示更强的分类能力。由 Python 程序生成的 ROC 曲线如图 2 所示。

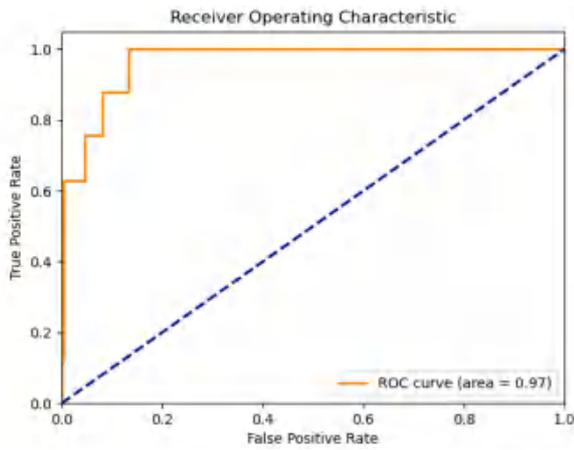


图2 ROC 曲线

在本研究中，该模型的 AUC 值高达 0.97，这不仅显示了模型具有极高的分类精度，也反映了其能够有效地识别和区分正负类样本。这样的高 AUC 值说明了神经网络模型对数据特征的刻画非常合理，表明模型在学习过程中已经逐渐达到并保持了稳定的高性能水平。

4 结论

本研究选择了 47 个关键财务指标，如偿债能力、盈利能力和现金流量等，通过深入分析信息服务行业的特点，以期提高对企业财务风险的准确预测能力。

设计的一维卷积神经网络模型专为处理顺序财务数据而定制，能够精确提取特征信号并预测企业的财务稳健性。模型采用双卷积层和双池化层结构，通过全连接层进行输出分类。经测试，模型在识别潜在风险方面表现出色。在测试集上，精确率达到 85.20%，表明模型能够准确分类高风险企业。同时，模型实现了 100% 的召回率，证明其在识别

真实高风险企业方面的无误性。F1 得分为 0.92，强调了模型在保持精确率和召回率之间良好平衡的能力。AUC 值为 0.97，显示了模型在区分高低风险企业方面的优越性能。

总的来说，模型在预测信息服务行业企业的财务风险方面表现出卓越的准确性和稳健性。虽然在低风险预测方面有待提高，但模型整体上为预测财务稳定性提供了一个有效工具，有助于及时发现并预警潜在风险。未来的研究将致力于进一步精炼特征选取，以增强模型在各种情况下的适应性和准确性。

参考文献

- [1] ZHANG R S, GUO X W, HE M Y. Intelligent Pseudo Solder Detection in PCB Using Laser-Pulsed Thermography and Neural Network[J]. IEEE Sensors Journal, 2021, 22(1): 631-638.
- [2] Altman E L. Financial Ratios, Discriminant Analysis and the Prediction of Corporate Bankruptcy, 1968.
- [3] Ardhy F, Hariadi F I. Development of SBC based machine-vision system for PCB board assembly Automatic Optical Inspection[J]. International Symposium on Electronics and Smart Devices (ISESD), IEEE, 2016.
- [4] 何国忠, 梁宇. 基于卷积神经网络的 PCB 缺陷检测[J]. 图学学报, 2022(5).
- [5] Wang D, He D. Channel pruned YOLO V5s-based deep learning approach for rapid and accurate apple fruitlet detection before fruit thinning[J]. Biosystems Engineering, 2021: 271-281.
- [6] 宋歌, 马涛. 基于深度学习的上市公司财务风险预警模型研究[J]. 价值工程, 2019(38): 53-56.
- [7] 王雪峰, 孙荣. 基于卷积神经网络(CNN)的医药行业上市公司财务预警研究[J]. 当代经济, 2023(6).