

基于 RNN 的多期财务数据危机预警模型构建与评估

段艳琼 任爱珍

内蒙古农业大学 理学院，内蒙古自治区呼和浩特，010010；

摘要：当前企业财务危机预警模型主要基于传统机器学习方法与静态截面数据构建，难以捕捉财务指标的时序依赖性与跨周期动态关联。本文引入循环神经网络（RNN）算法，构建基于时序特征的危机预警模型。研究分别采用单年度数据和多期时序数据构建 RNN 模型，并与 RF、SVM 和 BPNN 进行对比。结果表明，在多期时序数据建模中，RNN 凭借其时序建模优势，在准确率、精确率、召回率、F1 得分和 AUC 值上均显著优于其他模型，且较单期预测表现出更强的鲁棒性与跨期风险传导识别能力。RF 则在单期中预测表现出了更强的稳健性，而 BPNN 对数据变化更为敏感。

关键词：企业危机预警；RF；SVM；BPNN；RNN

DOI：10.69979/3041-0673.26.02.012

引言

在宏观经济波动、政策调整等因素影响下，企业经营环境不确定性加剧，财务风险持续积累，构建高效准确的财务危机预警系统成为企业稳健经营与市场稳定的关键支撑。当前，机器学习凭借优秀的非线性建模能力与自动化特征提取优势，已成为财务危机预测研究中的主流技术。黄衍^[1]基于随机森林（Random Forest, RF）构建制造业上市公司财务预警模型，验证了其在风险识别方面的优越性。吴恒铭^[2]提出基于哈夫曼树结构的多分类支持向量机（Support Vector Machine, SVM）模型，并在制造业财务数据中验证了该模型在风险预警中的高效性。Ciampi^[3]和 Yu^[4]则验证了 BP 神经网络（Backpropagation Neural Network, BPNN）算法在拟合财务数据非线性关系与实现模型自适应学习方面的优势。然而，现有研究多使用截面数据，不能捕捉企业风险演化的动态特征，限制了模型的泛化能力。

此外，Kim 等^[5]分析了企业风险的渐进过程，强调在建模中纳入时序财务指标的必要性。之后，徐静等^[6]验证了循环神经网络（Recurrent Neural Network, RNN）在时序预测中的有效性。然而，不同时间窗口的数据在风险信息的覆盖范围上存在差异。目前的研究多采用一年或三年的数据来构建预警模型，这可能忽视了诸如市场份额逐步下降、债务结构持续恶化等对企业稳健性产生长期影响的因素。

基于此，本文采用连续五年度数据，更能全面刻画财务危机从潜伏形成到爆发的动态过程。本文分别使

用单年度截面数据和五年时序数据构建 RNN 预警模型；并在两种数据结构下，与 RF、SVM 及 BPNN 进行对比，旨在探究时间序列信息在提升财务危机预警准确性和稳健性中的作用，揭示模型在不同数据结构与场景下的适应性，为企业选择合适的预警模型提供参考。

1 研究方法

1.1 RF

RF 通过引入随机抽样和特征选择机制来增强模型的准确性与鲁棒性。主要步骤为：（1）对训练数据集进行有放回的随机抽样，生成 K 个自助数据集。（2）对每个自助数据集，从全部特征中随机选取特征子集，依据最小化基尼指数选择最优特征构建决策树。（3）利用 K 棵决策树对新数据进行预测，并根据标签为 1 的占比进行分类。

1.2 SVM

SVM 通过找到一个最优超平面来分隔样本并最大化分类边界，实现分类与回归。当数据分布线性不可分离时，需引入松弛变量和平衡间隔误差与模型复杂度的正则化参数。同时 SVM 通过引入拉格朗日乘子与核函数将数据映射到高维空间，将原问题转换为对偶形式求解，最终通过支持向量的线性组合预测新样本类别。

1.3 BPNN

BPNN 是一种基于误差反向传播算法的多层前馈神经网络。在前向传播过程中，输入信号通过隐含层逐层传递，最终在输出层生成预测结果。反向传播则通过

链式法则计算损失函数对各参数的梯度，并利用梯度下降法优化模型，逐步最小化预测误差，从而完成预测任务。

1.4 RNN

RNN是一类用于处理时间序列数据的神经网络结构。前向传播为：序列 $\{x^{(1)}, x^{(2)}, \dots, x^{(t)}, \dots, x^{(T)}\}, x^{(t)} \in \mathbb{R}^m$ 按时间顺序进入网络，隐藏层表达式为：

$$\begin{cases} \mathbf{a}^{(t)} = \mathbf{W}_{xh} \mathbf{x}^{(t)} + \mathbf{W}_{hh} \mathbf{h}^{(t-1)} + \mathbf{b}_h \\ \mathbf{h}^{(t)} = f(\mathbf{a}^{(t)}) \end{cases}, t=1,2,\dots,T \quad (1)$$

其中， $\mathbf{a}^{(t)} \in \mathbb{R}^p$ 为隐藏层输入， $\mathbf{W}_{xh} \in \mathbb{R}^{p \times m}$ 为输入层权重矩阵， $\mathbf{W}_{hh} \in \mathbb{R}^{p \times p}$ 为隐藏层权重矩阵， $\mathbf{b}_h \in \mathbb{R}^p$ 为隐藏层偏置项， $\mathbf{h}^{(t)} \in \mathbb{R}^p$ 为隐藏层输出， $f(\cdot)$ 为激活函数。

最终输出层输入为： $z = \mathbf{W}_{hy} \mathbf{h}^{(T)} + b_y$ ，其中， $\mathbf{W}_{hy} \in \mathbb{R}^{1 \times p}$ 为输出层权重矩阵， $b_y \in \mathbb{R}$ 为输出层偏置项。对于二分类任务，使用 sigmoid 函数将 z 映射为类别概率 \hat{y} ，即 $\hat{y} = \text{sigmoid}(z) = \frac{1}{1+e^{-z}}$ 。设定决策阈值 $\theta = 0.5$ ，若 $\hat{y} \geq 0.5$ ，则预测标签为 1，反之为 0。

RNN 的反向传播采用随时间反向传播算法进行梯度计算。通过沿时间维度上展开网络结构，将其转换为一个等效的前馈神经网络，再基于链式法则计算损失函数对各时间步参数的梯度，沿时间反向更新参数。

2 模型设计及实证分析

2.1 数据选取与处理

本文以 2024 年为基期，选取该年度被 ST 处理的 A 股企业作为困境组，数据清洗后得到 152 家 ST 企业，按同行业与相似规模 1:1 配对非 ST 企业，形成 304 家企业的平衡数据集。选取 2019-2023 年年度 32 项财务与非财务特征指标构建样本集。数据均来自 CSMAR。

(1) 对缺失值使用同企业跨期均值填补后，将数据按 7:3 比例随机划分为训练集和测试集。采用 z-score

方法对输入特征进行标准化，测试集使用训练集的标准化参数进行处理。

(2) 单期数据处理。以标准化后的数据作为输入特征 $\mathbf{X} = (\hat{\mathbf{x}}^{(1)}, \hat{\mathbf{x}}^{(2)}, \dots, \hat{\mathbf{x}}^{(32)})_{n \times 32}$ ，其中 $\hat{\mathbf{x}}^{(i)}$ 为标准化后第 i 个特征指标列向量， n 为企业数量，目标变量为 2024 年企业类别标签。对 2019-2023 年构建 5 组独立数据集。

(3) 多期数据处理。因 RF、SVM 和 BPNN 本身不具备对时序数据直接建模的能力，本文将 2019-2023 年观测序列横向展开，对 32 维特征进行长度为 5 的固定窗口拼接，形成模型输入变量 $\mathbf{x} = [\hat{\mathbf{x}}_i^{(2019)}, \hat{\mathbf{x}}_i^{(2020)}, \dots, \hat{\mathbf{x}}_i^{(2023)}]$ ，其中 $\hat{\mathbf{x}}_i^{(t)}$ 为标准化后单个企业在 t 年的 32 个特征行向量。

对于 RNN，单个企业输入数据由连续五年的 32 个特征指标构成，即 $\mathbf{M} = [\hat{\mathbf{x}}_{2019,i}, \hat{\mathbf{x}}_{2020,i}, \dots, \hat{\mathbf{x}}_{2023,i}]^T$ ， $\hat{\mathbf{x}}_{t,i}$ 为标准化后单个企业在 t 年的特征行向量。将所有企业的输入数据堆叠为三维张量 $\mathbf{N} \in \mathbb{R}^{n \times 5 \times 32}$ 构成 RNN 模型的输入特征样本集。

(4) 将 (2) 和 (3) 构建的数据集分别输入 RNN、RF、SVM 和 BPNN，构建危机预警模型，通过混淆矩阵、准确率、精确率、召回率、F1 得分和 AUC 值评估模型性能。

2.2 实证分析和对比试验

单期数据下各模型预测性能见表 3。RF 表现出较高的稳定性，在 2022 年和 2023 年中，AUC 值分别达 0.8916 和 0.9299，显著优于其他模型，显示其在不同年度数据集下的强适应能力。SVM 虽整体波动较大，但其 F1 得分表现相对稳定，表明其在识别危机企业方面具备较为稳健的能力。BPNN 在 2021 年表现较好，AUC 值为 0.9105，F1 得分为 0.8958，但在 2022 年受数据分布变化影响，预测性能下降。RNN 虽有一定的泛化能力，但整体预测性能略低于其他模型，这可能与其依赖时序信息有关，建模优势未能充分发挥。

表 3 单期数据下模型评估结果比较

年份	模型	准确率	精确率	召回率	F1 得分	AUC 值
2019	RF	0.7500	0.7660	0.7500	0.7579	0.8527
	SVM	0.7391	0.7222	0.8125	0.7647	0.7306
	BPNN	0.7500	0.7907	0.7083	0.7473	0.7822
	RNN	0.8261	0.8636	0.7917	0.8261	0.8395
2020	RF	0.8261	0.7963	0.8958	0.8431	0.9119
	SVM	0.8152	0.8039	0.8542	0.8283	0.8904

	BPNN	0.8478	0.8148	0.9167	0.8627	0.8745
	RNN	0.8370	0.8367	0.8542	0.8454	0.8152
2021	RF	0.8261	0.7963	0.8958	0.8431	0.8868
	SVM	0.8587	0.8571	0.8750	0.8660	0.8902
	BPNN	0.8913	0.8958	0.8958	0.8958	0.9105
	RNN	0.8370	0.9024	0.7708	0.8315	0.9015
2022	RF	0.8152	0.8039	0.8542	0.8283	0.8916
	SVM	0.7935	0.7843	0.8333	0.8081	0.8026
	BPNN	0.7935	0.8222	0.7708	0.7957	0.8423
	RNN	0.7935	0.8372	0.7500	0.7912	0.8741
2023	RF	0.8913	0.9318	0.8542	0.8913	0.9299
	SVM	0.8261	0.8810	0.7708	0.8222	0.8468
	BPNN	0.8478	0.9048	0.7917	0.8444	0.8982
	RNN	0.7935	0.8222	0.7708	0.7957	0.8755

图3显示了多期数据下各模型预测结果与真实标签的匹配情况，可以看出，RNN在两类企业识别中展现

出优异的平衡性，假阳性率与假阴性率最低。

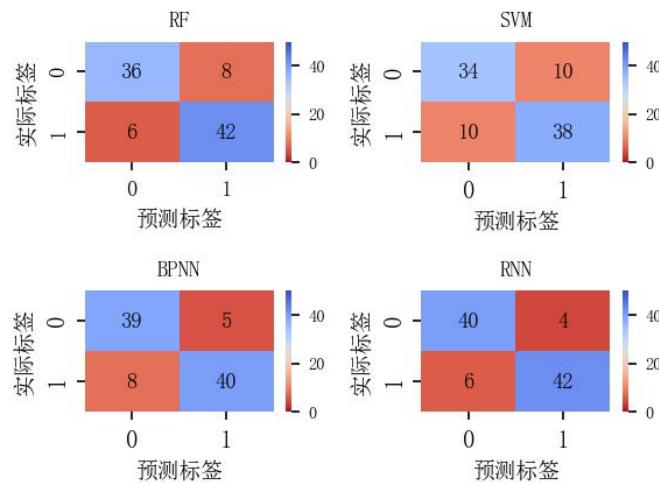


图3 多期数据下模型混淆矩阵热力图

多期数据下，各模型评价指标结果见表4。其中，RNN在各项指标中表现最优，准确率为0.8913，F1得分为0.8936，AUC值达到0.9342，表明其有效捕捉了

财务数据中的时序依赖性。RF和BPNN在特征维度扩展后仍能维持较好的预测性能。SVM虽在精确率与召回率之间维持较好的平衡，但整体表现略逊于其他模型。

表4 多期数据下模型评估结果比较

模型	准确率	精确率	召回率	F1得分	AUC值
RF	0.8478	0.8400	0.8750	0.8571	0.9271
SVM	0.7826	0.7919	0.7917	0.7917	0.8518
BPNN	0.8587	0.8889	0.8333	0.8602	0.9214
RNN	0.8913	0.9130	0.8750	0.8936	0.9342

此外，图4展示了四种模型在多期数据预测任务中的ROC曲线。其中，RNN的ROC曲线显著贴近左上边界，在FPR小于0.1的范围内，TPR超过80%，表明在严格控制误报的条件下，该模型具备较高的危机识别

能力。RF在FPR为0至0.2区间内曲线最为陡峭，显示其对风险阈值变化高度敏感，在需平衡误报与漏报代价的决策场景中具有一定优势。

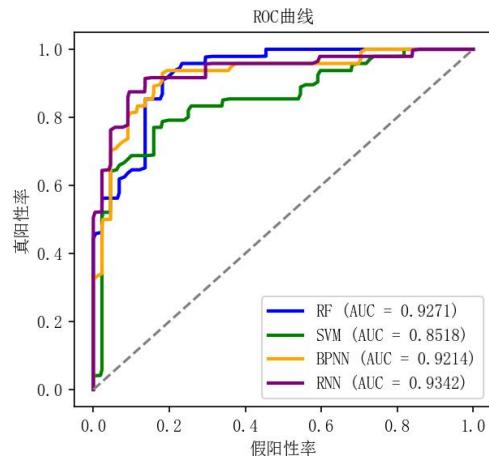


图 4 多期数据下模型的 ROC 曲线

3 总结

综上所述,本研究挖掘了财务数据中的时序特征在企业危机预警中的重要性,验证了RNN在企业财务危机预警中的有效性,其能够更有效地捕捉财务演变规律,降低短期波动干扰。同时揭示了各类算法的适应性差异,为企业根据实际风险管理需求选择最适模型提供了实证支持。

参考文献

- [1] 黄衍. 基于随机森林的制造业上市公司财务预警模型研究[D]. 华东交通大学, 2013.
- [2] 吴恒铭. 基于多分类不均衡支持向量机的制造型企业

业财务风险预警研究[D]. 杭州电子科技大学, 2024.

[3] Ciampi F. Corporate governance characteristics and default prediction modeling for small enterprises. An empirical analysis of Italian firms[J]. Journal of Business Research, 2015, 68(5): 1012–1025.

[4] Yu L, Hong Y, Lin H, et al. Arrears behavior prediction of power users based on BP neural network and multi-scale feature learning: a refined risk assessment framework[J]. Energy Informatics, 2025, 8(1): 4.

[5] Kim H, Cho H, Ryu D. Corporate default predictions using machine learning: Literature review[J]. Sustainability, 2020, 12(16): 6325.

[6] 徐静, 王勃, 孙雪莹. 基于 RNN 神经网络的人力资源管理风险预警模型 [J]. 计算机与数字工程, 2020, 48(7): 1727–1730.

作者简介: 段艳琼 (2000—), 女, 河南驻马店人, 研究生在读, 研究方向: 经济统计分析。

通讯作者简介: 任爱珍 (1974—), 女, 内蒙古呼和浩特人, 蒙古族, 副教授, 研究方向: 经济统计分析、机器学习。