

基于 TCN 与交易结构特征融合的企业信用风险预测方法

方秋宇¹ 刘 君^{1*}
FANG Qiuyu LIU Jun

摘 要

企业信用风险评估是金融领域风险评价的研究内容之一。传统方法使用企业的财务报表、此前借贷信息等评估其信用风险，中小企业信息不完整更增加了识别企业信用风险的难度。随着企业的数字化程度逐步提升，发票交易数据成为评价企业真实的日常经营的信息来源。文章使用企业发票信息构造企业经营的时间序列特征和交易结构特征，并提出一种使用时间卷积网络（temporal convolutional network, TCN）和多层感知机（multilayer perceptron, MLP）技术结合的信用风险评估方法，TCN 刻画企业经营的时间演进特征，并嵌入企业交易的结构信息形成模型。实验结果表明，集成 TCN+MLP 模型实验比纯 TCN 模型更优。

关键词

信用风险评估；发票数据；TCN；MLP；融合网络

doi: 10.3969/j.issn.1672-9528.2026.06.032

0 引言

中小企业在我国经济发展中扮演着重要角色，但中小企业面临融资难、融资贵的问题。信息不对称是限制中小企业融资的一个重要原因。传统的企业信用评估数据依靠企业的财务报表、抵押物以及企业过去发放过哪些贷款等历史信息，许多中小企业没有完备的财务披露记录，或者没有习惯获取资本的信贷信用记录，使得金融机构很难准确地评估中小企业的真实信用风险。因此，寻找反映企业真实运营状况的替代数据，并将这样的数据用于企业信用评估是近年来金融科技的研究重点。

随着信息化、数字化水平的不断提高，企业在日常经营活动中积累了大量可以分析利用的数据。如增值税发票数据可以反映企业之间的交易行为和企业经营状况。发票信息可以反映发票的交易双方、交易金额、交易时间等信息，具有覆盖面广、时间点细、真实性强等特点，与企业传统的财务报表相比，发票信息能够比较动态地反映企业经营活动，因

此被一些人运用在企业的经营分析、供应链金融、信用评级等领域。近年来，一些研究试图利用企业交易数据或者企业供应链网络来刻画企业的经营状况，用于经营风险的发现，如企业的交易网络能够刻画企业在供应链中的结构位置及其交易集中性，用来发现潜在的经营风险。

与此同时，随着机器学习方法的发展，大量工作开始用数据驱动的方法进行信用风险预测，比如逻辑回归、随机森林、深度神经网络等方法被用来进行个人、企业信用评分等预测问题。但这些研究几乎大多关注静态特征建模，针对企业经营活动包含的时间序列特征关注得较少。事实上，企业经营活动的时间动态特征是一直存在的。企业销售额、采购额、交易笔数等指标，不同时间段的变化趋势也可能是不同的。用静态的统计特征难以很好地反映企业经营活动这种动态的变化。近年来深度学习中的时间序列模型开始应用于金融风险预测方面。如时间卷积网络 TCN 能够捕捉长时间依赖的关系，还具有并行时间效率高、训练稳定等特点，目前应用到时间序列数据也较为广泛。

在此背景下，本文利用企业发票交易数据进行企业经营时间序列特征构建，同时考虑企业交易结构特征，研究企业信用风险的评估问题。本文主要贡献如下：基于企业发票数据构建企业经营时间序列特征、企业交易结构特征用于企业信用风险的评估，给出了不同的数据视角；提出一种结合时间序列特征、结构特征的 TCN+MLP 模型，刻画企业经营活动的动态变化特征以及企业交易关系特征；在真实企业数据集上进行实验，实验结果表明本文的方法比单一模型具有更

1. 广州城建职业学院 广东广州 510900

[基金项目] 2022 年度广州城建职业学院科研项目（自科）立项课题“大数据下基于神经网络模型的商业银行对小微企业信贷决策研究”（2023XKZY12）；2024 年度广东省教育科学规划课题（高等教育专项）“基于 CIPP 模型的高职‘新工科’人才就业竞争力评价与提升策略研究”（2024GXJK940）；2024 年广东省高职院校课程思政示范课程建设项目“广东省课程思政示范课程《高等数学》”（KCSZ2024045）

好的预测性能。

基于上述背景,本文利用企业发票交易数据构建企业经营时间序列特征,并结合交易结构特征,研究企业信用风险评估问题。

1 相关研究

1.1 企业信用风险评估

对信用风险进行评估是金融风险的一个重要课题,其目标是在对借款人相关信息的处理基础上对借款人违约概率进行评估。传统的信用评估技术多为统计类方法,如判别分析、逻辑回归等^[1-3]。这些方法具有较好的可解释性,因此在银行风险管理中被广泛应用。然而,由于企业经营环境日益复杂,传统统计模型在处理高维和非线性数据时存在一定局限性。这些技术的优点就是便于分析和解释,在银行风险的管理中得到了较好应用。随着企业经营环境的变化,传统统计技术在高维度、非线性数据上使用具有局限性。

随着机器学习技术的发展,也有一些研究人员采用数据驱动的方法来进行信用风险预测,如支持向量机、随机森林、梯度提升树等对信用评分数据进行了很好的应用^[4]。近年来,深度学习方法也被应用到金融风险领域,建立深度神经网络以便于自动提取数据的特征,并得到较好的预测结果^[5]。然而大多数研究仍然偏向于使用财务指标或者结构化的数据,对于企业经营活动数据的使用仍然较少。

1.2 交易网络与供应链金融研究

企业之间的交易关系也形成各种供应链网络。供应链金融的研究中,在供应链网络中,企业在交易网络中的位置与其信用风险具有重要的关系。如企业的客户集中度、供应商数量、交易稳定性等因素都会对企业的经营风险产生影响^[6]。有研究构建了企业交易网络,使用网络特征提取出企业节点特征用于企业的风险识别^[7]。

随着企业发生交易数据的逐渐累积,利用发票或者交易记录构建企业的关系网络也是一种新兴的研究思路。发票可以记录真正的企业交易关系,因此可以用发票记录企业之间的供应链关系及结构,稳定性也能被很好地分析出来。一些研究发现,企业交易网络结构特征可以帮助找到潜在的高风险企业^[8-9]。

1.3 时间序列建模方法

企业经营活动一般都会有明确的时间演化特征,例如销售额、采购额等数据会随着市场环境及企业的经营情况而变化。因此,提出信用风险的时间序列建模方法也是很有必要的,过去常用的时间序列方法包括ARIMA等统计方法,这些方法建模的特点对于非线性情况不能很好表现出来。

近年来,深度学习模型被广泛应用于时间序列研究中,如循环神经网络(RNN)、LSTM等,能够学习时间序列数据中的长依赖关系并且可以用于金融预测等任务^[10]。不同于这些模型,时间卷积网络(TCN)可以利用卷积和扩张卷积来模型化长序列信息,也具有能快速并行计算和易于训练的优点。

针对以上研究,本文将TCN应用于企业经营时间序列建模,并利用交易结构特征预测企业信用风险,从而更加全面地刻画企业的经营行为和风险行为。

2 数据与特征

本文利用企业增值税发票数据来构造研究数据集。发票数据反映的是企业间的真实交易,能较为准确反映企业经营状况。每笔发票数据信息一般都包含企业的编号、交易“对户”编号、发票金额、发票开出日期及发票状态等信息。

整理增值税发票数据之后,本文共得到425家企业发票交易记录,其中包含123个企业有信贷记录、302个企业没有信贷记录。发票数据的跨度时间段是2016年10月—2020年2月,共41个月。使用发票数据能够统计得到企业经营相关的时间序列特征、交易结构特征。

为了确保数据质量,在本研究的处理过程中,对原始发票数据,本文进行如下处理:首先去除明显异常或缺失的发票数据;其次对发票金额进行统一处理,按月对企业交易的发票金额进行合计;此外识别作废发票,并总结出作废发票比例特征。对发票进行预处理以后,本文根据发票记录构造企业经营时间序列数据,如表1所示。

表1 企业特征构成

特征类型	特征名称	说明
时间序列	月度销售额	销项发票金额
	月度采购额	进项发票金额
结构特征	上游企业数量	供应商数量
	下游企业数量	客户数量
	客户集中度(HHI)	客户交易集中度
行为特征	进项发票作废率	作废进项发票比例
	销项发票作废率	作废销项发票比例

2.1 时间序列特征

企业的经营具有非常明显的时间变化性,比如企业的销售收入、采购支出等会随市场环境、企业经营状况而变化。为了体现企业经营时间变化的特征,本文利用发票数据构建企业月份经营时间序列。

具体地说,对每一家企业,统计其销项发票、进项发票金额按月数据,分别记作企业的销售额、采购额。设企业在

第 t 个月的销售额为 S_t , 采购额为 P_t , 则企业的经营时间序列可以表示为:

$$X_t = (S_t, P_t), t = 1, 2, \dots, T \quad (1)$$

式中: T 表示时间长度。

在本文的数据集中, 每家企业都有 41 个月经营记录, 可得到一个 41×2 的时间序列特征矩阵, 用来度量企业经营随时间的变化情况, 如图 1 所示。




图 1 某企业月度经营时间序列示例

2.2 交易结构特征

除了经营的时间序列以外, 企业在交易网络中的位置结构也可能反映其经营风险。比如企业的客户数量、企业供应商数量、交易集中度均可能影响到企业的经营稳定性。

利用企业之间的发票交易关系可以构造企业的交易关系, 交易关系中点代表着一个企业, 点与点之间的线则表示交易行为。从交易关系中, 本文得到以下结构特征: 上游企业数量、下游企业数量和客户集中度。

其中, 客户集中度采用赫芬达尔指标 HHI (herfindahl-hirschman index) 来衡量:

$$HHI = \sum_{i=1}^n s_i^2 \quad (2)$$

式中: s_i 表示与第 i 个客户的交易金额占交易总额的比重, n 表示客户数量。HHI 越高则说明企业的客户集中度越高, 企业经营风险也随之增大。

2.3 交易行为特征

除了交易规模和结构信息外, 发票行为本身也可能嵌入一些风险信息。如发票作废行为则有可能体现企业交易稳定性或者异常经营状况。因此, 本文进一步构造如下行为特征: 进项发票作废率和销项发票作废率。

作废率的定义为: 作废的发票数量 / 发票张数。较高的作废率往往表示企业交易行为存在一定异常, 应该有一定的风险信号。

综合以上特征, 本文最后实现的是由时间序列特征和静态结构特征构造出来的企业特征, 用于后续模型的训练。

3 方法

3.1 模型总体框架

为了同时表达出企业经营交易活动的时间维度特征和交易结构特征, 本文提出了一种结合时间卷积网络 TCN 和多层感知机 MLP 的信用评估模型。模型总体结构图如图 2 所示。




图 2 TCN+MLP 企业信用风险评估模型结构

一是将企业的月份经营时间序列数据输入到时间卷积网络 (TCN), 得到时间序列; 二是将企业的交易结构特征和行为特征输入多层感知机 (MLP) 实现特征映射; 三是将两部分特征表示信息拼接, 并通过全连接层表示预测企业的信用风险。

设企业时间序列特征为 X , 结构特征为 Z , 模型最终违约概率为 $\hat{y}$, 则模型可以表示为:

$$\begin{aligned} h_{tcn} &= f_{tcn}(X) \\ h_{mlp} &= f_{mlp}(Z) \\ \hat{y} &= \sigma(W[h_{tcn}, h_{mlp}] + b) \end{aligned} \quad (3)$$

式中: $[\cdot, \cdot]$ 表示特征拼接, σ 表示 Sigmoid 函数。

3.2 时间卷积网络

时间卷积网络 (TCN) 是一种基于卷积结构的时间序列建模方法。相对于循环神经网络 (RNN), TCN 采用卷积结构捕捉序列之间的依赖, 具有计算效率高、训练过程稳定等优点。

TCN 通常采用扩张卷积结构来扩大感受野。对于一维时间序列 x_t , 扩张卷积可以表示为:

$$y_t = \sum_{k=0}^{K-1} w_k x_{t-dk} \quad (4)$$

式中: K 为卷积核, d 为扩张系数, w_k 为卷积核参数。通过逐层增加扩张系数, TCN 可以在较浅的层数内捕捉较长时间范围内的依赖关系。

本文模型中, TCN 的作用是从企业的经营时间序列中捕捉销售额、采购额随时间变化的发展模式。

3.3 多层感知机

对于企业交易结构特征和行为特征, 本文采用 MLP (multilayer perceptron) 映射特征。MLP 即多个全连接神经网络层的集合, 通过对网络的输入特征进行非线性映射变换, 得到更多层次的特征。

设输入特征为 z , 则 MLP 的计算可以表示为:

$$h = \phi(Wz + b) \quad (5)$$

式中: W 和 b 为网络参数, $\phi(\cdot)$ 为激活函数。

在本文实验中选用了 ReLU 作为激活函数。

通过 MLP 处理后, 得到了企业的交易结构特征的嵌入表示, 并和 TCN 的时间序列表示进行拼接。

3.4 模型训练

本文采用模型训练方法将企业的信用风险预测看作是一个二分类问题。代码实现将风险数值标签“1/2 级”当作高风险(正类), 将“3/4 级”当作低风险(负类)。假设真实标签为 y , 模型对样本的预测概率为 $\hat{y}$, 采用二元交叉熵作为损失函数:

$$L = -(y \log \hat{y} + (1 - y) \log(1 - \hat{y})) \quad (6)$$

模型的参数用随机梯度下降方法进行优化。实验中, 本文采用交叉验证的方式对模型的准确率进行评测, 采用 AUC 作为主要评价指标。

4 实验设计

4.1 实验设置

实验的目的是验证本文提出方法在企业信用风险评估上的有效性和可行性。本文使用前述发票数据构建实验样本, 其中 425 家企业中有 123 家具有信贷记录及风险标签, 用于模型训练与评估; 其余 302 家无信贷记录企业仅用于最终预测, 不参与 AUC 评价。对于每个带标签企业, 利用发票信息得到企业的月度经营历史数据序列及交易结构, 并将企业风险等级转换后的二分类结果作为标签。

在训练和评估模型的时候, 本文采用交叉验证的方式进行实验。具体做法是将数据划分成 5 个数据集, 每次都选取其中 4 个数据集当作训练集, 余下的 1 个数据集作为测试集完成一次模型训练和评估。为了降低随机划分的影响, 本文在不同随机种子条件下重复上述过程。对于基础模型性能比较, 重复上述过程 6 次, 因此共进行 $5 \times 6 = 30$ 次实验; 对于集成模型相对于纯 TCN 模型的统计显著性检验, 进一步重复 10 次, 因此共进行 $5 \times 10 = 50$ 次配对实验。

4.2 对比模型

为进一步说明本文方法的有效性, 进行以下 3 种模型对比:

MLP 模型: 仅输入交易结构特征、行为特征, 用一个多层感知机做分类;

TCN 模型: 仅输入企业经营时间序列特征, 用时间卷积网络来做风险预测;

TCN+MLP 模型: 时间序列特征和结构特征综合的模

型, 即本文的方法。

对比以上 3 种模型结果可以分析不同种类特征对企业信用风险预测的影响。

4.3 评价指标

信用风险预测模型中数据样本严重不平衡是正常现象, 本文采用 AUC (area under ROC curve) 用于评价模型的性能。AUC 反映了模型在给定阈值下辨别能力的强弱, 是最常见的信用评分的评价指标之一。

AUC 取值范围为 0~1。AUC 等于 0.5, 表示模型预测能力与随机猜测相当; 而 AUC 越接近 1, 则表示模型区分能力越强。

此外, 为检验不同模型之间性能差异是否具有统计显著性, 本文在实验结果基础上进一步采用符号检验 (Sign Test) 以及 Bootstrap 方法进行统计分析。

5 结果与分析

5.1 模型性能比较

表 1 为不同模型在实验数据上的平均 AUC 结果, 图 3 为不同模型的 ROC 曲线比较。

表 1 不同模型的预测性能比较

模型	平均 AUC
MLP	0.562 3
TCN	0.671 0
TCN+MLP (集成)	0.748 1




图 3 不同模型 ROC 曲线比较

实验结果显示, 仅有交易结构特征信息的 MLP 模型的预测能力并不强, 平均 AUC 为 0.562 3, 虽比随机预测结果高, 但远低于用时间序列建模的模型, 说明单独静态结构信息远远不够充分刻画企业信用度。

相比之下, 仅使用时间序列特征的 TCN 模型能够获得明显更好的预测性能, 平均 AUC 达到 0.671 0。这表示企业经营时间序列中也有一部分风险信息, 例如企业销售和进货

额的变化趋势可能反映企业经营情况的变化。

在综合时间序列特征和结构特征以及进行模型集成时, TCN+MLP 模型进一步提升预测结果的性能, 平均 AUC 达到 0.748 1。这说明交易结构特征可以补充时间序列特征, 而模型集成可以把模型鉴别企业信用风险的效果再提升。

5.2 统计显著性检验

为了进一步判断 TCN+MLP 模型相对于 TCN 模型的性能提升的统计显著性, 本文在 50 次配对实验结果的基础上做了检验。

实验显示: 50 次实验中, 39 次出现了比 TCN+MLP 模型更高的 AUC 的实验结果, 11 次出现了比 TCN 模型更大的 AUC 结果。根据以上结果进行符号检验 (Sign Test), 得到 $p=9.0 \times 10^{-5}$, 说明两种模型性能的差别有显著性。

此外, 本文还用 Bootstrap 方法对两种模型的 AUC 差值做了置信区间估计, 得到 AUC 平均差值为 0.077 0, AUC 差值的 95% 置信区间为: [0.046 0, 0.108 3]。由于该区间完全大于 0, 说明 TCN+MLP 模型无论在整体上要优于纯 TCN 模型。

5.3 结果分析

从实验结果中可以看出以下几点:

(1) 企业的经营时间序列特征对信用风险预测非常重要。与只使用了结构特征的 MLP 模型比较, 加入时间序列建模的模型精度有了明显的改进。

(2) 企业的交易结构特征对风险预测有一定补充作用。引入企业的供应商数目、客户的数目、客户的集中度等数据能够从企业交易关系的角度来刻画企业的经营稳定程度, 可以进一步提高模型精度。

(3) 企业的发票行为特征 (如发票作废率) 能够体现企业交易行为的非正常情况, 甚至可能与企业的经营风险有关。所以, 在信用风险预测中可以充分利用不同类型企业的经营数据。

6 结论

本文以企业发票交易数据为基础来研究企业信用风险预测问题。文章首先通过总结发票所蕴含的企业经营行为的统计信息来得到企业经营时间序列特征和交易结构特征; 然后提出一种融合时间卷积网络 (TCN) 和多层感知机 (MLP) 的信用风险预测方法, 用来同时刻画企业经营的时间序列变化以及交易结构特征; 最后在真实企业数据集上做了实验。实验结果表明, 单纯的静态结构特征难以取得好的预测效果, 加入时间序列特征构建时预测模型的效果有明显的改善。进一步地加入交易结构特征且融合模型会获得模型平均 AUC=0.748 1, 并且模型在统计实验上显著地优于纯 TCN 模型。

本文所提方法的研究结果表明, 企业的发票信息也能反映企业的经营行为特征, 为企业信用风险判别提供了信息来源, 有了新的数据类型。未来的研究还可以充分利用更大的企业交易数据类型, 并研究更丰富的交易网络结构特征, 进一步提高信用风险预测的准确度。

参考文献:

- [1]Altman E I. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy[J]. The Journal of Finance, 1968, 23(4): 589-609.
- [2]Bai Shaojie, Zico Kolter J, Koltun V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[PP/OL].(2018-04-19)[2026-05-29].<https://doi.org/10.48550/arXiv.1803.01271>.
- [3]Hand D J, Henley W E. Statistical classification methods in consumer credit scoring: a review[J]. Journal of the Royal Statistical Society: Series A (Statistics in Society), 1997, 160(3): 523-541.
- [4]Baesens B, Van Gestel T, Viaene S, et al. Benchmarking state-of-the-art classification algorithms for credit scoring[J]. Journal of the Operational Research Society, 2003, 54(6): 627-635.
- [5]Heaton J B, Polson N G, Witte J H. Deep learning for finance: deep portfolios[J]. Applied Stochastic Models in Business and Industry, 2017, 33(1): 3-12.
- [6]周利国, 粟金霞, 肖代友. 供应链关系对企业信用风险的影响研究: 基于供应商/客户集中度的分析[J]. 工业技术经济, 2021, 40(12): 14-24.
- [7]方匡南, 范新妍, 马双鸽. 基于网络结构 Logistic 模型的企业信用风险预警[J]. 统计研究, 2016, 33(4): 50-55.
- [8]崔鹏, 陈国文. 企业债务风险与风险传染性研究[J]. 东岳论丛, 2020, 41(6): 97-109.
- [9]王姝黛, 杨子晖, 张平森. 城投债信用风险传染的地理集聚、路径演变与驱动机制: 基于前沿弹性网络收缩技术的研究[J]. 统计研究, 2023, 40(3): 32-42.
- [10]Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

【作者简介】

方秋宇 (1998—), 男, 安徽铜陵人, 硕士, 助教, 研究方向: 机器学习与优化算法。

刘君 (1983—), 通信作者 (email: 153972135@qq.com), 男, 湖南怀化人, 硕士, 副教授, 研究方向: 群与图论。

(收稿日期: 2026-04-06 修回日期: 2026-06-11)