

# 基于图卷积网络的中小企业信用风险预测

赵美, 张小宁, 董萍萍

同济大学经济与管理学院, 上海

收稿日期: 2023年12月29日; 录用日期: 2024年1月22日; 发布日期: 2024年3月21日

## 摘要

长期以来中小企业一直存在融资难的问题, 供应链金融被提出作为解决该问题的一个重要方案。如何更准确地评估供应链金融背景下的中小企业的信用问题成为一大难点。本文提出了一种基于图卷积网络的中小企业信用风险预测方法, 该方法充分考虑了整个供应链网络的信息。首先, 以化学制药行业为背景构建了包含420家核心企业、一级供应商和二级供应商的供应链网络, 然后构建两层图卷积神经网络, 将企业财务、基本信息等特征以及供应关系数据作为输入, 企业是否ST或破产清算等作为标签训练, 使其学习供应链网络间的复杂非线性关系并对末端中小企业进行风险预测。最后对比了SVM、AdaBoost等传统机器学习模型, 实验结果表明, 本文所提出的模型预测效果较好, 为供应链金融背景下的中小企业信用风险预测提供了新思路。

## 关键词

图卷积网络, 信用风险, 中小企业, 供应链金融

# Credit Risk Prediction for Small and Medium-Sized Enterprises Based on Graph Convolutional Networks

Mei Zhao, Xiaoning Zhang, Pingping Dong

School of Economics and Management, Tongji University, Shanghai

Received: Dec. 29<sup>th</sup>, 2023; accepted: Jan. 22<sup>nd</sup>, 2024; published: Mar. 21<sup>st</sup>, 2024

## Abstract

For a long time, small and medium-sized enterprises (SMEs) have faced challenges in accessing financing, with supply chain finance proposed as a significant solution to address this issue. Accu-

rately assessing the credit of SMEs within the context of supply chain finance has been a major challenge. This paper proposes a credit risk prediction method for SMEs based on graph convolutional networks, which takes into account information across the entire supply chain network. Firstly, this paper constructed a supply chain network comprising 420 core enterprises, primary suppliers, and secondary suppliers within the context of the pharmaceutical industry. Secondly, a two-layer graph convolutional neural network was developed. It utilized features such as financials, basic information, and supply relationship data as inputs, while training on labels indicating whether companies are flagged as “ST” (Special Treatment) or subjected to bankruptcy liquidation. This enabled the model to learn complex nonlinear relationships among the supply chain networks and predict risks for SMEs at the end of the chain. Comparative analyses were conducted with traditional machine learning models like SVM and AdaBoost. Experimental results demonstrated the effectiveness of the proposed model, offering new insights into credit risk prediction for SMEs within the domain of supply chain finance.

## Keywords

Graph Convolutional Networks, Credit Risk, Small and Medium-Sized Enterprises (SMEs), Supply Chain Finance

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

近年来，我国市场经济改革迅速推进，企业间竞争日益激烈。在经营规模、经营理念、信用评级和资产管理等因素的综合影响下，获取银行信贷成为企业发展的当务之急，直接影响着企业的融资能力和未来发展。然而，中小微企业长期以来面临着融资难的困境。尤其是新冠肺炎疫情的蔓延，给全球供应链和产业链带来了巨大的冲击。中小微企业因资金回流困难、运营成本上升、现金流紧张等问题，更加迫切地需要融资支持以渡过难关。在这种情况下，供应链金融成为缓解融资难题的重要手段备受政府和企业关注。2021年3月5日，十三届全国人大四次会议的《政府工作报告》中提出了“创新供应链金融服务模式”的重要内容，凸显了供应链金融创新在国家发展战略中的地位。政府和企业纷纷探索新的供应链金融服务模式，这意味着供应链金融已逐步成为我国经济发展的重要支撑。

供应链金融的核心在于以中小企业相关联的核心企业信用作为担保，将供应商、制造商和零售商整合为一个协调统一的体系，为中小企业提供全方位的融资或增信，从而优化供应链并提升整体竞争力。然而，这种模式下位于供应链远端的中小企业往往难以获得融资支持。若中小企业发生信用风险并扩散至核心企业，将对其经营造成严重影响，进而干扰整个供应链的平稳运作。因此，供应链金融中中小企业信用问题突出。如何有效识别中小企业的信用风险，加强风险管理，已成为供应链金融业务亟须解决的现实问题。有效的信用风险识别和管理可以有助于减少不良影响，维护整个供应链的稳定和持续性发展。

供应链金融背景下中小企业信用风险预测的是当前研究的一个重要问题，现有的研究方法包括传统机器学习方法和一些列数据驱动技术，然而，这些方法在处理复杂非线性特征方面存在一定局限性。传统的机器学习方法常常难以有效提取供应链金融中各个参与方之间复杂的非线性特征，例如，供应链金融涉及多个环节和参与方，其间的关联和相互作用相当复杂。传统机器学习方法在分析这些复杂关系时

存在局限,无法充分捕捉企业之间的动态互动、交易关系和潜在风险。因此,这些方法在提高信用风险预测精度和全面性方面存在挑战。此外,现有方法难以有效处理供应链金融背景下数据的特殊性。供应链金融数据通常具有高度动态性、异质性和不确定性,这对传统方法提出了更高的要求。传统机器学习方法可能无法充分利用这些数据的潜在信息,导致预测模型的鲁棒性和准确性受到限制。因此,本论文旨在探索新的研究方法以克服传统机器学习方法的局限性,更好地提取和分析供应链金融环境中的复杂非线性特征,以改善对中小企业信用风险的预测能力。通过引入先进的图卷积神经网络算法,提取供应链网络中各个节点的复杂非线性空间特征,期望能够有效克服传统方法的不足,提升预测模型的准确性和可靠性,为中小企业信用风险预测提供更可靠的决策支持。

本文的贡献主要体现在以下三个关键方面:首先,在数据收集和供应链网络构建方面,本文考虑了更为详细的数据,包括核心企业、一级供应商和二级供应商等,并充分考虑了这些企业之间复杂的关系。此外,本文还关注了供应链中节点和边的拓扑结构,从而更全面地描述了供应链网络。其次,在神经网络模型的构建方面,本文引入了图卷积神经网络(GCN)作为信用风险评估工具。GCN 具有强大的非线性特征学习能力,能够有效处理供应链网络数据,提高了模型的性能和效率。最后,本文运用化学制药行业上的供应链网络数据,将所提出的方法与传统机器学习模型(如 SVM、AdaBoost 等)进行了对比,并采用 KS 和 F1 值作为模型评价指标。实验结果显示,本文所提出的方法在信用风险评估方面表现出良好的性能和效果,相较于传统模型具有明显优势。

## 2. 文献综述

目前,国内外关于供应链金融背景下的中小企业信用风险研究主要集中于评价指标体系和评价方法两方面。

针对评价指标体系,Zhao *et al.* (2022) [1]和 Li & Guo (2021) [2]采用了不同的方法和因素选择,以应对供应链金融下的中小企业信用风险。Zhao *et al.*通过定性定量筛选,从中小企业能力、核心企业能力、融资目标情况、第三方物流企业、供应链状况和外部环境等方面选取了 46 个评价指标,构建了一套综合的评价指标体系。与此同时, Li & Guo 则运用两阶段贝叶斯判别模型,将内部财务因素、内部非财务因素、外部环境、公司声誉以及抵押品担保系数等因素融合,形成了另一套多维度评价指标体系。韩琴(2019) [3]的研究认为核心公司的信用状况与融资企业的信用状况相互影响,共同塑造了企业的还款能力。而邓爱民(2016) [4]等学者则侧重于第三方物流企业对供应链金融的影响,提出了考虑第三方物流企业信用能力、竞争能力以及与供应链协调的合作能力和信用记录等因素的评价指标体系。这些不同研究的评价指标体系涵盖了从企业内部能力到外部环境因素的多个维度,充分考虑了供应链金融下中小企业信用风险评估的多样性和复杂性。

针对评价方法,目前对于供应链上中小企业信用风险评价模型的研究主要可分为两大类。首先是基于主观或主客观相结合的方法构建评价指标体系,例如 Fan (2021) [5]基于供应链金融和风险相关理论,采用模糊综合评价法建立了针对风险评价的指标体系。Huang *et al.* (2021) [6]则运用灰色关联分析方法构建了中国家电行业的供应链金融信用风险评价模型。另一类研究采用基于数据驱动的方法构建信用风险评价模型,如 Zhu *et al.* (2019) [7]、Zhang *et al.* (2019) [8]和 Sang (2021) [9]。这些研究借助于新技术的发展,包括大数据、云计算和人工智能等,使得信用风险评价方法更为全面和准确。Zhu 提出了 RS-MultiBoosting 这一增强混合集成机器学习方法,以提高中小企业信贷风险预测的准确性。另一方面,Zhang 利用修正的 KMV 模型和 Copula 函数来衡量供应链中单个融资企业和融资企业组合(上下游)的信用风险。而 Sang 则提出了一种利用反向传播神经网络(BPNN)预测中国中小企业信用风险的新方法。这些研究方法在评价模型的构建上各有侧重,一些采用传统的主观或客观相结合的方法,而另一些则更倾向于数据驱动的技术

术手段。这种多样性的方法为我们提供了不同的思路 and 选择, 对于供应链金融中小企业信用风险评价提供了广泛的视角和理论基础。

GCN 在近年备受研究者关注, 得益于其在处理图结构数据方面的强大功能。其主要优势在于有效捕捉复杂的非线性特征, 这使得其在多个领域取得了创新性应用, 尤其是个人信贷风险预测和企业信用风险预测。在个人信贷风险预测方面, Cheng *et al.* (2019) [10] 利用图注意力机制获取供应链网络上的节点表示, 并设计目标函数, 使具有相似网络特征的节点表示更为相似。Xu *et al.* (2021) [11] 则基于用户多种关系构建网络, 并运用图神经网络预测用户信用特征。在企业信贷风险预测方面, Zhang *et al.* (2022) [12] 基于企业间供应关系构建供应链网络, 利用图神经网络(GNN)模型研究供应链企业间的风险传播模型。另一方面, Wu *et al.* (2023) [13] 构建上市公司供应链网络, 并运用 GNN 对企业行业进行分类。值得注意的是, 图卷积目前主要应用于个人信贷风险预测问题, 而在对企业进行信用风险评价方面应用较少。这主要由两个因素造成: 一是企业关系数据难以获取, 二是非上市企业标签难以获得, 导致样本类别极度不平衡, 这给利用该方法带来了一定挑战。因此, 尽管 GCN 在个人信贷风险预测中展现出了潜力, 但在企业信用风险评价方面仍需克服上述不足才能更广泛地应用于该领域。

综上所述, 国内外学者在供应链金融的风险评价开展了大量的研究, 取得了一系列有价值的研究成果, 但对供应链上末端中小企业的评估仍无能为力, 因此本文建立供应链网络, 旨在通过供应链网络, 将大企业的信用赋予供应链远端的中小企业, 为中小企业增信, 解决中小企业融资难问题。

### 3. 评价指标体系

本文研究的核心为如何利用供应链网络上的核心企业为供应链末端中小企业增信。因此, 在设计指标体系时不仅要考虑中小企业的特征, 同时也应包含企业所处供应链网络结构特征。本文借鉴了张发明等(2019) [14] 提出的评价指标体系, 将企业特征信息分为“硬信息”和“软信息”。“硬信息”为企业的财务数据, 包括盈利能力、偿债能力、经营能力和成长能力, “软信息”则主要为企业的基本信息, 主要包括成立年限、注册资本等。另外, 为了评估供应链网络的结构特征, 本文借鉴了匡海波等(2020) [15] 提出的指标体系中的供应链运营状况指标, 同时考虑到数据的可得性, 主要设计了供应数量和供应比率等指标。本文最终建立的指标体系如表 1 和表 2 所示, 主要包含企业的财务数据、企业的基本信息和供应链网络关系数据等 3 个一级指标, 其中, 企业的财务数据包括盈利能力、偿债能力、经营能力和成长能力 4 个二级指标和应计利润与总资产比、净资产报酬率等 30 个三级指标。

Table 1. Index system (1)

表 1. 指标体系(1)

一级指标	二级指标	三级指标	指标含义
企业财务数据	盈利能力	应计利润与总资产比	公司净利润与总资产之间的比率(连续变量)
		净资产报酬率	单位净资产创造的利润水平(连续变量)
		总资产报酬率	公司净利润与其总资产之间的比率(连续变量)
		毛利率	销售收入中去除直接生产成本后的利润比例(连续变量)
		营业利润率	销售产品或服务过程中, 除去所有直接和间接费用后的利润比例(连续变量)
		成本费用率	公司的总成本与销售收入之比(连续变量)
		核心利润率	排除非核心业务或非经常性收益支出后, 公司的核心业务利润占销售收入比例(连续变量)

续表

偿债能力	资产负债率	公司资产中由债务资金所占比例(连续变量)
	流动比率	公司流动资产与流动负债之比(连续变量)
	速冻比率	公司速动资产与流动负债之比(连续变量)
	现金比率	公司现金与流动负债之比(连续变量)
	长期负债与营运资本比	评估公司长期负债对营运资本的影响(连续变量)
	自由现金流与短期债务比	评估公司短期债务偿还能力和现金流关系(连续变量)
	现金流量比率	公司经营活动现金流量与总债务之比(连续变量)
经营能力	存货周转率	一定时间内公司存货的销售与更新频率(连续变量)
	应收账款周转率	公司应收账款的收回速度(连续变量)
	流动资产周转率	公司流动资产在营运过程中的周转速度(连续变量)
	总资产周转率	公司总资产在销售和运营中的周转速度(连续变量)
成长能力	利润留存率	公司将利润留存作为未来发展或再投资的比例(连续变量)
	净资产三年平均增长率	公司净资产在过去三年内的平均增长速度(连续变量)
	营业收入三年平均增长率	公司营业收入在过去三年内的平均增长速度(连续变量)
	资本累积率	公司资本在一段时间内的累积增长率(连续变量)
	自由现金流三年平均增长率	公司自由现金流在过去三年内的平均增长速度(连续变量)
	总资产三年平均增长率	公司总资产在过去三年内的平均增长速度(连续变量)
	股东权益增长率	股东权益在特定时间段内的增长百分比(连续变量)
	总资产三年平均增长率	公司总资产在过去三年内的平均增长速度(连续变量)

Table 2. Index system (2)

表 2. 指标体系(2)

一级指标	二级指标	指标含义
企业基本数据	成立时间	公司的成立年限(连续变量)
	公司类型	包括上市公司、股份有限公司、国有企业、有限责任公司、合伙企业(分类变量)
	注册资本	公司注册登记时申报最初设立的资本金额(连续变量)
供应关系数据	供应比率	2017 年该供应商的供应量占总供应量比例(连续变量)

## 4. 模型构建

### 4.1. 基本原理

#### 4.1.1. SMOTE 过采样

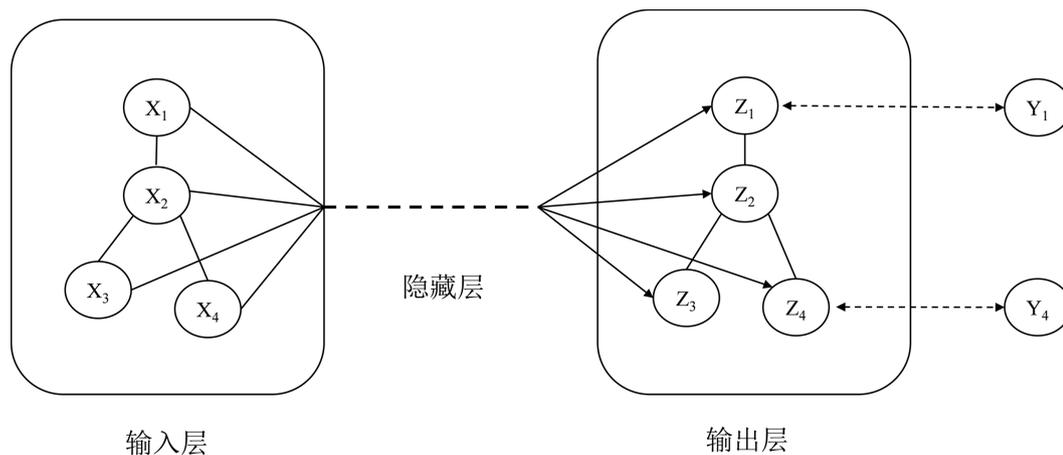
SMOTE (Synthetic Minority Over-sampling Technique) 是一种过采样方法, 通过生成合成实例来平衡数据集, 特别是对于少数类样本。其基本原理可由以下式(1)表示。在此方法中, 假设给定一个少数类实例, SMOTE 从同一类中选择  $k$  个最近邻, 其中  $k$  是用户定义的参数。然后通过结合所选实例及其邻居的属性, 并引入一定的随机性, 创建合成实例。这些合成实例位于连接原始实例与其邻居在特征空间中的线段上, 从而扩展了少数类的样本空间。

$$X_{ik}^{Mino-SMOTE} = X_i^{Mino} + rand(0,1) * X_{ik}^{Near} - X_i^{Mino} \tag{1}$$

### 4.1.2. 图卷积网络

图卷积网络(Graph Convolutional Network, GCN)是一种用于处理图结构数据的深度学习模型。在GCN中,图由节点和边构成,每一个节点代表一个实体,每一条边代表节点之间的关系。GCN的核心思想在于其能够将节点的特征与其相邻节点的特征进行信息传递和聚合,通过多层的卷积操作来学习节点的特征。GCN通过图结构进行信息传递,学习节点的低维表示,使节点的表征能够全局图结构的信息,从而实现节点分类、图分类、链接预测等任务。GCN采用了谱域卷积方法,其原理如式(2)所示。 $\hat{D}^{-\frac{1}{2}}\hat{A}\hat{D}^{-\frac{1}{2}}$ 对邻接矩阵进行了归一化处理,将邻接矩阵转换成了对称归一化的形式,用于保留图结构中节点之间的关系信息。 $H^l$ 代表第  $l$  层的节点特征,  $H^lW^l$  为节点特征矩阵与权重矩阵的乘积,用于将节点特征进行线性变换。 $\sigma(\cdot)$  表示 ReLU 激活函数,用于引入非线性。 $H^{l+1}$  表示经过当前层的信息聚合和特征变换后得到的新的节点表示矩阵。

$$H^{l+1} = \sigma\left(\hat{D}^{-\frac{1}{2}}\hat{A}\hat{D}^{-\frac{1}{2}}H^lW^l\right) \tag{2}$$



**Figure 1.** Principles of graph convolutional network  
**图 1.** 图卷积网络原理

Thomas *et al.* (2016) [16]提出了一种在图结构数据上进行半监督学习的图卷积网络方法,如图1所示。该方法基于卷积神经网络的思想,能够有效地学习图数据中的节点表示并完成节点分类任务。该方法包含两层图卷积,其原理如式(3)、式(4)所示。GCN包含两层卷积,首先对输入特征进行卷积操作,得到新的节点特征表示,然后对卷积后的结果应用 ReLU 激活函数,引入非线性,接着再次进行图卷积操作,得到最终节点表示,最后添加 softmax 层,得到输出分类结果。GCN采用交叉熵作为损失函数,损失函数的计算如式(5)所示。

$$Z = f(X, A) = \text{softmax}\left(\hat{A} \text{ReLU}\left(\hat{A}XW^{(0)}\right)W^{(1)}\right) \tag{3}$$

$$\hat{A} = \hat{D}^{-\frac{1}{2}}\hat{A}\hat{D}^{-\frac{1}{2}}, \hat{A} = A + I \tag{4}$$

其中,  $\hat{D}$  代表  $\hat{A}$  的度矩阵,  $\hat{A} = A + I$ 。  $W^l$  是第  $l$  层神经网络的权重。

$$L = -\sum_{l \in y_l} \sum_{f=1}^F Y_{lf} \ln Z_{lf} \quad (5)$$

其中,  $L$  表示整体损失函数,  $y_l$  表示样本  $l$  的真实标签,  $F$  表示类别的数量,  $Y_{lf}$  表示样本  $l$  是否输入类别  $f$ , 若属于则为 1, 否则为 0.  $Z_{lf}$  表示模型对样本  $l$  预测为类别  $f$  的概率。

## 4.2. 模型构建

现有的基于数据驱动的企业信用风险评价模型可以分为两大类, 即传统的机器学习方法和深度学习算法模型。传统的机器学习方法如 SVM (支持向量机) 和 AdaBoost 等在一定程度上已经被应用于企业信用风险评估。然而, 随着深度学习技术的兴起, GCN(图卷积网络)等深度学习方法也逐渐引起了广泛关注。本文选择采用 GCN 深度学习方法, 并将本文提出的方法与 SVM 和 AdaBoost 等传统机器学习方法进行对比实验, 验证模型的有效性。GCN 作为一种能够学习邻居节点信息的深度学习方法, 能够将供应链网络上核心企业的信用信息传递给中小企业, 从而实现为中小型企业增信的目标。因此本文选择采用 GCN 来构建模型, 研究框架如图 2 所示, 主要包括供应网络构建、数据预处理和 GCN 模型三部分。

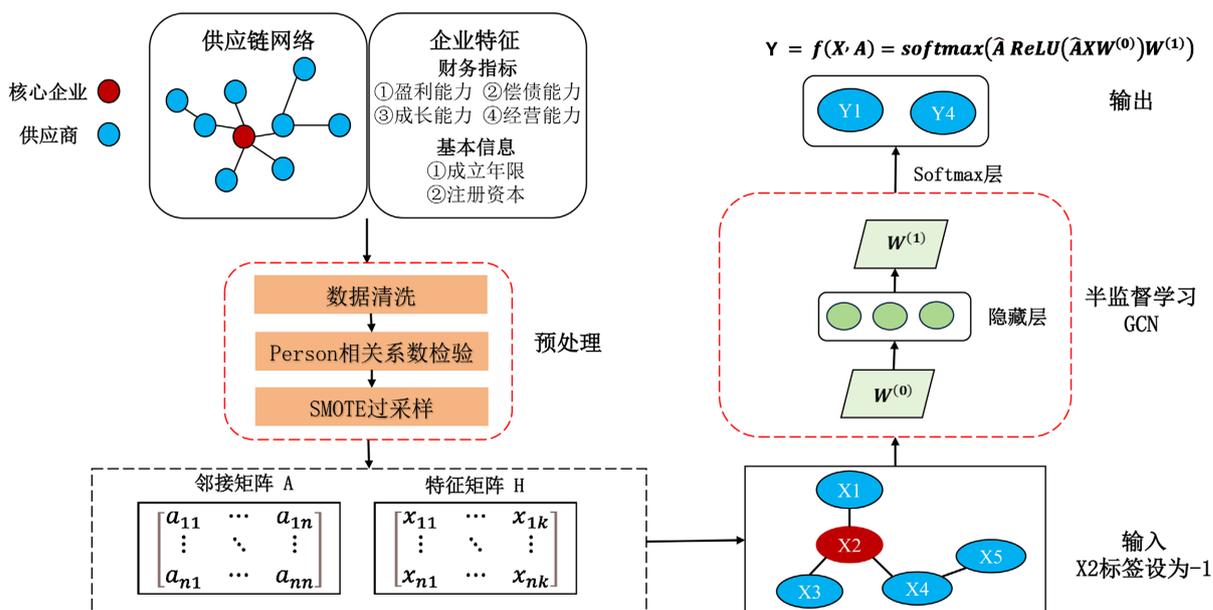


Figure 2. Model framework

图 2. 模型框架

一是供应链网络构建过程, 本文主要通过企业间的供应关系来定义供应链网络。首先将企业划分为核心企业、一级供应商企业和二级供应商企业。以核心企业为基准, 寻找一级供应商, 然后再以一级供应商为基准, 寻找一级供应商的一级供应商。最终构造成一个包含核心企业和一二级供应商的供应链网络。其中节点表示企业, 节点的属性为根据企业财务数据(包括盈利能力、偿债能力、成长能力和经营能力)、企业基本数据(包括成立年限和注册资本)等指标, 边表示企业之间的供应关系, 边的属性为节点之间的连接权重, 其物理意义是供应商的供应比。

二是数据预处理阶段, 主要包括数据清洗、相关性分析和 SMOTE 过采样过程。中小型企业由于信息披露不全面, 收集到的数据往往存在大量的缺失值, 同时在数据采集的过程中也会发生数据重复和异

常情况,因此本文的数据清洗工作主要包括填充缺失值、删除重复值和处理异常值。其次,为了避免指标之间的多重共线性,本文选择采用皮尔逊相关系数(Pearson Correlation Coefficient)计算指标之间的相关性,并剔除相关性较强的指标。最后,信贷数据存在严重类别不平衡问题,即发生信用风险的企业占企业总数比率较小,会使得预测结果不准确,因此需要通过增加负样本的数量来平衡数据集。SMOTE (Chawla N V. *et al.*, 2002) [17]作为一种有效的过采样方法在企业信用风险预测问题中被频繁使用,本文选择了 SMOTE 过采样方法来增加发生信用风险的企业数量。

三是 GCN 模型部分。在 GCN 中,模型被分为输入、特征提取、预测输出三个模块。在输入模块,输入数据为图数据,既包含企业节点的特征矩阵  $H$ ,同时还包含了企业节点之间的关联信息,企业之间的供应关系信息以邻接矩阵的形式  $A$  作为输入。在特征提取模块,将邻接矩阵  $A$  和特征矩阵  $H$  输入到 GCN 单元通过图卷积表示以进行特征提取,企业节点学习到邻接节点的信息。在预测输出模块,GCN 通过 softmax 层实现判断企业是否发生违约风险的二分类问题,并采用交叉熵作为损失函数。

## 5. 实验分析

### 5.1. 数据收集

本文以化学制药行业企业为研究对象,构建了一个包含 70 家核心企业,120 家一级供应商企业和 230 家二级供应商企业的数据集。其中,数据来源于企查查网站<sup>1</sup>和 wind 数据库<sup>2</sup>。

数据收集策略主要分为四步。首先确定核心企业,核心企业为规模大、信誉好、抗风险能力强的企业。设置注册资本、企业类型和成立年限等筛选条件,框定注册资本大于 2000 万成立时间超过 10 年且为上市公司的企业作为核心企业,最终选定了 70 家企业作为核心企业。其次确定核心企业的一级供应商和二级供应商。本文从招标公告数据中获取供应关系数据,主要包括供应时间、供应数量和供应比例等数据,共匹配到约 120 家一级供应商企业和 230 家二级供应商企业。接着,搜集核心企业和供应商企业的基本信息和财务信息,上述信息均来自 wind 数据库。最后,考虑数据可获得性,本文选用了 2017 年的药品供应商的供应数据,并将 2018 年企业是否被标记为 ST、是否连续两年净利润为负或破产清算等作为评价指标,若发生则将其标签设置为 1,否则设置为 0。

### 5.2. 供应链网络构建

从企业的招标公告和企业年报信息中获取了大量数据,并利用这些数据挖掘了企业之间的供应关系,进而构建了一个具有丰富信息的供应链网络。本文的构建方法遵循以下步骤:首先,将每个企业视作网络图中的一个节点。这些节点代表着各个企业实体,包含了其基本信息特征和财务特征。这一步的关键在于数据的收集和整理,以确保后续分析能够基于充分而准确的信息展开。其次,利用这些企业间的供应关系构建了网络图中的边。这些边直观地展示了企业之间的供应联系,边的方向性描述了供应关系的方向,边的权重则根据供应比例而设定。这种权重设置能够突出不同供应关系的重要性,为后续的分析提供了更为精细的数据基础。至此,构建了一个庞大的供应链网络图,如图 3 所示。整个网络由 420 个节点和 267 条边组成,展示了供应链的复杂性和多样性。这个网络图中,节点代表了企业实体,而边则直观地展示了企业间的供应关系。这种图形化呈现有助于深入理解供应链网络中不同企业之间错综复杂的联系。节点和边之间的关系性使我们能够更全面地把握供应链中各环节的联系和依赖关系,为后续的深入分析和决策提供了重要的信息基础。

<sup>1</sup><https://www.qcc.com/>。

<sup>2</sup><https://www.wind.com.cn/mobile/Home/zh.html>。

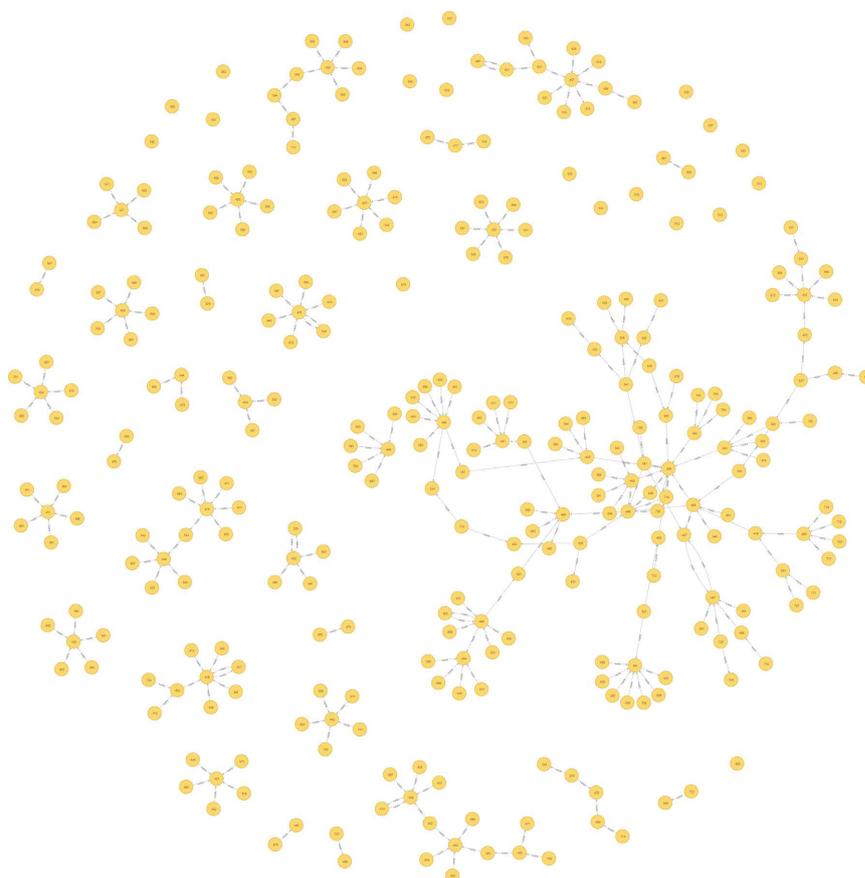


Figure 3. Enterprise supply chain network  
图 3. 企业供应链网络

### 5.3. 实验设计

本文首先对数据清洗，包括处理重复值、缺失值和异常值，以及数据归一化等操作，处理后共得到 364 个样本和 25 个特征。中小企业由于信息披露不完善，会存在部分数据缺失的情况，针对此种情况，本文利用中小企业与核心企业的供应关系，对缺失的中小企业进行加权平均填充。而对于数据缺失较多的企业和重复值，直接删除数据。另外，采用箱线法识别异常值，并按照处理缺失值的方法对异常值进行处理。

接着计算 25 个指标特征的皮尔逊相关系数进行相关性分析。皮尔逊相关系数是一种用于衡量两个连续变量之间线性关系强度和方向的统计量，取值范围在-1 到 1 之间，如式(6)。当相关系数  $|r| > 0.7$  时，认为两个变量之间具有较强的线性相关性。样本变量之间的皮尔逊相关系数计算结果如图 4 所示，可以发现营业利润率和营业成本率、流动比率和速动比率、资本累计率和权益增长率、总资产三年平均增长率和净资产三年平均增长率之间相关性较高，相关系数  $|r| > 0.7$ ，选择对营业利润率、流动比率、资本累计率和总资产三年平均增长率等 4 个变量进行剔除，剔除后共剩余 21 个变量作为模型的指标特征。

$$r = \frac{\sum (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum (X_i - \bar{X})^2 \sum (Y_i - \bar{Y})^2}} \quad (6)$$

其中， $X_i$  和  $Y_i$  是样本中的两个变量值， $\bar{X}$  和  $\bar{Y}$  分别是  $X$  和  $Y$  的均值。

最后，考虑到样本未发生信用风险企业与发生风险企业数量之比为 330:34，即存在信用风险的企业仅占企业总数的 10%，样本数据存在类别极其不平衡问题。因此采用 SMOTE 方法对样本进行过采样处

理, 用来增加存在信用风险企业的样本数量, 将正负样本比控制在 8:2 左右, 最终得到企业样本总数 422 家, 未发生信用风险企业与发生风险企业数量之比为 340:82。

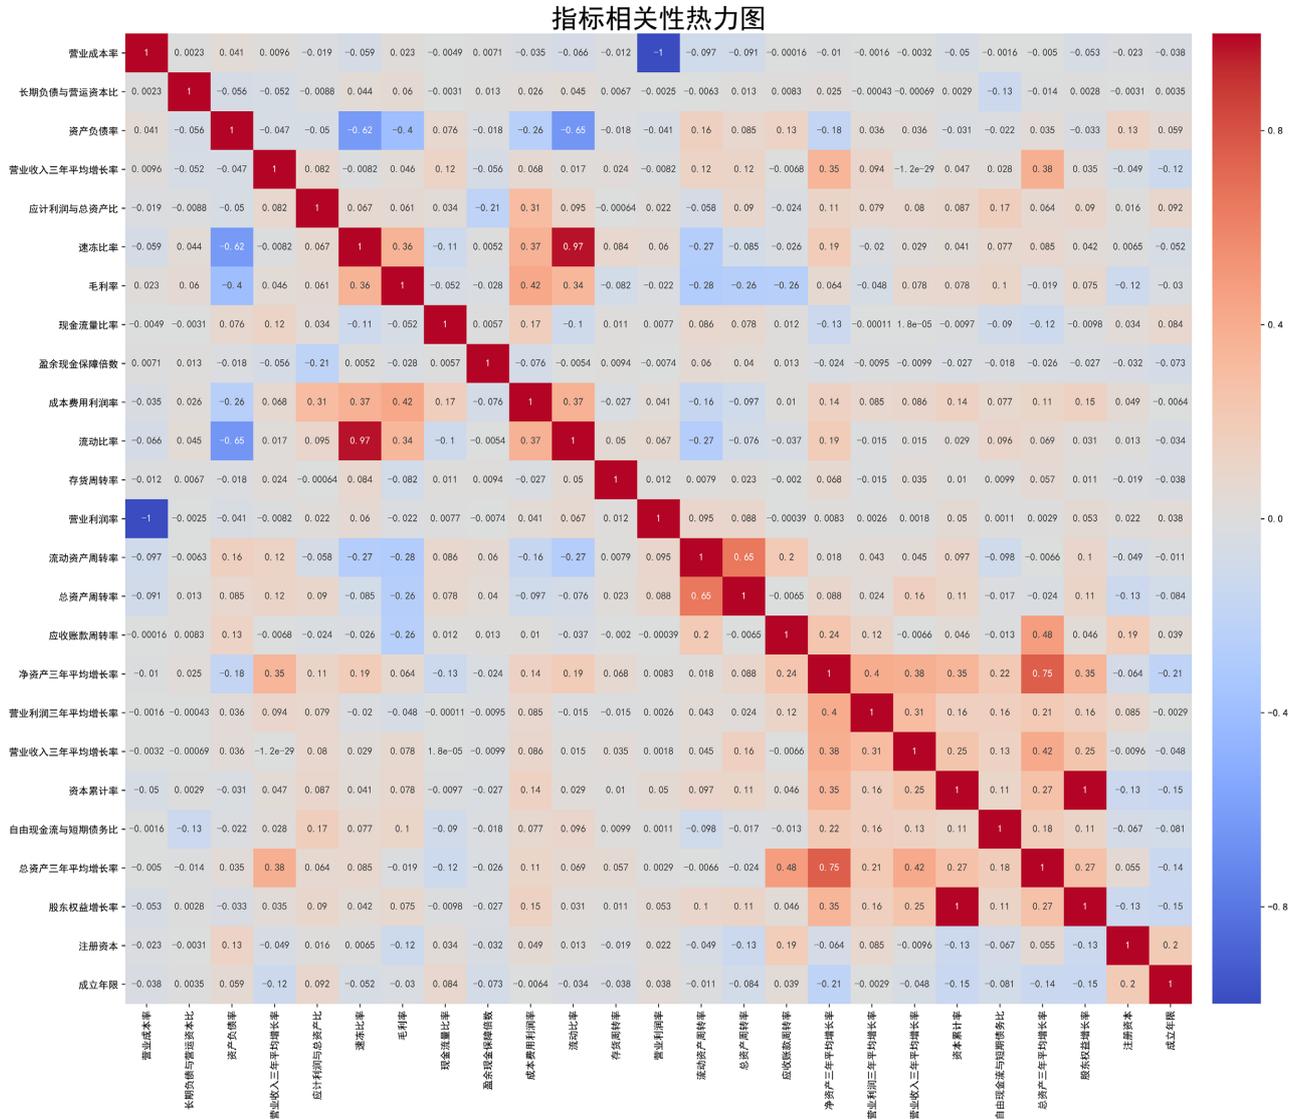


Figure 4. Heatmap of feature correlation analysis  
图 4. 特征相关性分析热力图

在模型训练的过程, 由于各指标之间的量纲差异, 往往会使得模型在训练过程中出现过拟合或者梯度消失的状况, 因此需要对数据进行归一化处理, 来消除量纲不一致的影响。本文对数据采用最大最小归一化处理, 处理过程如式(7)所示。

$$x' = \frac{x - \min(X)}{\max(X) - \min(X)} \tag{7}$$

本文将数据集划分为按照 8:1:1 划分训练集、验证集和测试集, 将 338 个数据用来进行训练, 将 42 个数据进行测试。图卷积的输入为企业节点的特征向量  $H$  和邻接矩阵  $A$ , 特征向量  $H$  的维度为  $338 \times 21$ , 邻接矩阵  $A$  的维度为  $338 \times 338$ 。另外, 一般而言两层图卷积层的模型已经可以很好地对节点进行分类,

本文构建了两层的图卷积网络，每一层的神经元的数量分别设置为 32、32。最后接 sigmoid 激活函数作为模型的输出。采用 Pytorch 框架进行实现，选择 Adam 作为优化器，将学习率设为 0.01，正则化项系数设置为  $5e^{-4}$ ，模型选用交叉熵损失函数。

#### 5.4. 对照模型

本文将 SVM 和 AdaBoost 作为基准模型。SVM 和 AdaBoost 作为经典的机器学习模型，在企业信用风险评价领域被广泛应用。SVM 适用于线性和非线性分类问题，能够处理高维数据，且在小数据集上表现良好，对于特征空间中的异常点具有较好的鲁棒性。AdaBoost 用于处理复杂问题，能够有效地降低偏差并提高泛化能力，但对噪声和异常值较为敏感。

由于所采用的基准模型的数据输入为非图结构数据，因此本文设计了三种数据集来满足 GCN 模型和基准模型的需要，如表 3 所示。数据集 1 和数据集 2 作为 SVM 和 AdaBoost 模型的输入，数据集 3 作为 GCN 模型的输入。其中，数据集 1 包含企业基本信息和企业的基本财务指标，模型的输入维度为  $21 \times 338$ ；数据集 2 则将中小企业的核心企业的特征作为自身的特征进行评价，包括企业基本信息、企业财务数据、核心企业基本信息、核心企业财务数据、供应关系数据等指标，模型的输入维度为  $42 \times 338$ 。数据集 3 是按照供应关系构成了供应链网络图数据，包含企业基本信息、企业财务数据、供应关系数据等指标，模型的输入维度为  $21 \times 338$ 。实验将数据集 1 输入到基准模型和数据集 2 输入到基准模型分别与数据集 3 输入到 GCN 模型进行对比，观察 GCN 模型的性能。

Table 3. Dataset

表 3. 数据集

数据集	特征	维度	训练集	测试集	数据量
数据集 1	企业基本信息、企业财务数据	$21 \times 338$	338	42	422
数据集 2	企业基本信息、企业财务数据、核心企业基本信息、核心企业财务数据、供应关系数据	$42 \times 338$	338	84	422
数据集 3	企业基本信息、企业财务数据、供应关系数据	$21 \times 338$	338	84	422

## 6. 结果分析

### 6.1. 评价指标

关于模型的性能评价指标，现有研究表明综合多个评价指标有利于更加准确地比较不同模型的性能 (Lessmann S. *et al.*, 2015) [18]。由于未发生信用风险企业与发生风险企业的比例不均衡，本文选择了 AUC，KS 和 F1 值作为模型的评价指标，如式(8)、式(9)和式(10)所示。AUC 值是计算 ROC 曲线下方的面积，是信用评价中最为常用的评价指标。KS 指标用于衡量好坏样本累计分布之间的差值，可以有效评估模型风险区分能力。在信用评估过程中，将一个信用好的企业评估为信用差的企业，对于信贷机构来说，只是客户未来贷款利息的损失，如果将一个信用差的企业评估为信用好的企业，则面临借款者违约风险，对信贷机构造成无法收回本金和利息的损失，因此本文选择 F1 作为评价指标，来充分反映发生信用风险企业预测的准确率。总体而言，AUC，KS 和 F1 指标的值越大，则表明评价模型的效果越好。

$$AUC = \int_0^1 TPRd(FPR) \quad (8)$$

$$KS = \max(TPR - FPR) \quad (9)$$

$$F1 = \frac{2 * Precision * Recall}{Precision + Recall}, Precision = \frac{TPR}{TPR + FPR}, Recall = \frac{TPR}{TPR + FNR} \quad (10)$$

其中, TPR 表示真正例率, 即召回率, FPR 表示假正例率, FNR 表示假负例率。

## 6.2. 实验结果和分析

图 5 展示了 GCN 模型的训练过程, 结果显示 GCN 模型训练到 200 轮时, 模型开始收敛。表 4 和表 5 分别展示了数据集 1 和数据集 2 在四种分类算法模型的整体分类结果, 表 6 则展示了数据集 3 在 GCN 模型的整体分类结果, 即模型的 KS、AUC 值和 F1 值等三种评估指标。结果表明, 所有模型在分类企业信用风险方面表现出了有效性, 其中最低的 AUC 值为 74%。本文所提出的 GCN 模型相较于传统的 SVM 和 AdaBoost 等其他模型表现更优, 且 AUC 值、KS 值和 F1 等三种模型性能评价指标具有一致性, 这表明 GCN 能够对企业的信用风险进行准确的预测。模型取得了良好的效果是由于 GCN 模型能够充分挖掘邻居节点的信息, 并在特征提取方面表现良好。GCN 模型通过利用图结构数据中节点之间的关系, 能够更好地捕获企业间复杂的相互影响和连接, 从而提高了风险评估的准确性和精度。

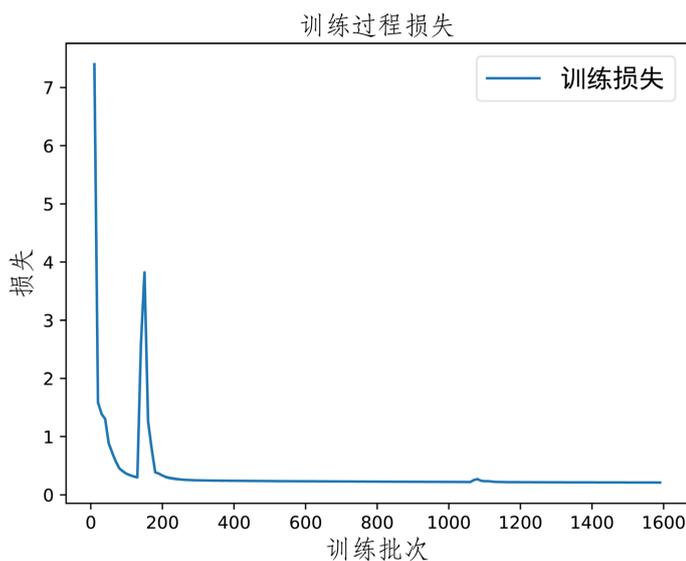


Figure 5. Training process of GCN model

图 5. GCN 模型训练过程

Table 4. Dataset 1-experimental results

表 4. 数据集 1-实验结果

方法	KS	F1	AUC
SVM	0.48	0.63	0.74
AdaBoost	0.70	0.75	0.81

Table 5. Dataset 2-experimental results

表 5. 数据集 2-实验结果

方法	KS	F1	AUC
SVM	0.51	0.66	0.76
AdaBoost	0.73	0.75	0.81

**Table 6.** Dataset 3-experimental results  
**表 6.** 数据集 3-实验结果

方法	KS	F1	AUC
GCN	0.76	0.81	0.83

## 7. 结论

目前对供应链金融信用风险的评估主要依赖于企业一级供应商的财务指标，将这些指标作为评价企业信用风险的依据。然而，这种方法在处理多级供应商问题上存在一定局限性。针对供应链金融背景下的多级中小型供应商信用风险的借贷问题，本文结合图卷积网络方法，提出了一种 SMOTE + GCN 信用风险评价模型，该模型可以充分利用整个供应链网络上企业信息，为中小企业增信，解决了供应链金融背景下的多级中小型供应商企业增信难问题。首先，本文构建了化学制药行业供应链网络数据集。选择了化学制药行业 70 家核心企业和 350 家中小型供应商企业作为研究对象，收集了企业的基本数据、财务数据和供应关系数据，构建了包含 420 个节点 267 对关系的供应链网络。其次，本文对现有信用风险评价指标体系做了进一步扩充。在前人研究的基础上，增加了供应比例、供应金额、企业注册资本等指标，丰富了现有的供应链金融企业信用风险评价指标体系。最后，本文创新性地使用 GCN 来提取供应链网络上企业节点的特征，并且考虑到类别不平衡问题，使用 SMOTE 方法解决负样本较少的问题。采用 AUC，KS 和 F1 作为模型性能评价指标，本文将所提出的 SMOTE + GCN 模型与 Adaboost 和 SVM 等多种先进方法相比，结果表明所提出的模型性能有较大提升，是深度学习方法在供应链金融领域的一次开创性的尝试。对于第三方物流机构，可以基于现有的掌握的企业供应链信息，利用本文所提出的企业信用风险评价模型，对供应链上的企业进行风险评估，开展供应链金融服务。对于银行等金融机构，可以基于企业的交易数据，利用本文所提出的信用评价模型对中小企业信用风险进行评估，进一步提升对中小企业的风险评估能力。

企业间的供应关系会随着时间动态变化，是一个动态变化的系统。如何处理动态的数据，构建基于动态交易关系的供应链网络，并针对动态网络上的节点进行预测，使得模型能够适应快速变化的交易环境，是未来继续研究的方向之一。另一个重要的研究方向是对供应链金融业务所产生的大量非结构化数据的提取和利用。这些数据来自诸如交易记录、市场趋势等多方面信息。如何从这些海量数据中提炼出有用的信息，并将其转化为企业节点的特征，对于风险管理和商业决策具有重要意义。这种转化有助于了解和预测金融风险，提高金融决策的准确性和效率。最后，在评估企业信用风险时，主要依赖于企业的财务信息。然而在实际交易中，涉及的数据要复杂得多，来源也更加多样。因此，将这些多源异构的非结构化数据纳入信用风险评估的过程中是非常重要的。这需要开发新的方法和模型，使得这些非结构化数据可以更好地融入信用评估体系中，以更全面、准确地评估企业的信用风险。

## 参考文献

- [1] Zhao, Y.D., Yang, M.Y., Peng, X.H. and Li, G. (2022) Research on SMEs' Credit Risk Evaluation Index System from the Perspective of Supply Chain Finance—R-Cluster and Coefficient of Variation Based on Panel Data. *Procedia Computer Science*, 214, 613-620. <https://doi.org/10.1016/j.procs.2022.11.219>
- [2] Li, Z. and Guo, L. (2021) Construction of Credit Evaluation Index System for Two-Stage Bayesian Discrimination: An Empirical Analysis of Small Chinese Enterprises. *Mathematical Problems in Engineering*, 2021, Article ID: 8837419. <https://doi.org/10.1155/2021/8837419>
- [3] 韩琴. 供应链金融视角下的中小企业信用风险评价指标体系构建[J]. 时代金融, 2019(9): 171-172.
- [4] 邓爱民, 文慧, 李红, 文小平. 供应链金融下第三方物流信用评价研究[J]. 中国管理科学, 2016, 24(S1): 564-570.

- 
- [5] Xuan, F. (2021) Regression Analysis of Supply Chain Financial Risk Based on Machine Learning and Fuzzy Decision Model. *Journal of Intelligent & Fuzzy Systems*, **40**, 6925-6935. <https://doi.org/10.3233/JIFS-189523>
- [6] Huang, X., Sun, J. and Zhao, X. (2021) Credit Risk Assessment of Supply Chain Financing with a Grey Correlation Model: An Empirical Study on China's Home Appliance Industry. *Complexity*, **2021**, Article ID: 9981019. <https://doi.org/10.1155/2021/9981019>
- [7] Zhu, Y., Zhou, L., et al. (2019) Forecasting SMEs' Credit Risk in Supply Chain Finance with an Enhanced Hybrid Ensemble Machine Learning Approach. *International Journal of Production Economics*, **211**, 22-33. <https://doi.org/10.1016/j.ijpe.2019.01.032>
- [8] Zhang, M., Zhang, J., et al. (2019) Quantifying Credit Risk of Supply Chain Finance: A Chinese Automobile Supply Chain Perspective. *IEEE Access*, **7**, 144264-144279. <https://doi.org/10.1109/ACCESS.2019.2939287>
- [9] Sang, B. (2021) Application of Genetic Algorithm and BP Neural Network in Supply Chain Finance under Information Sharing. *Journal of Computational and Applied Mathematics*, **384**, Article ID: 113170. <https://doi.org/10.1016/j.cam.2020.113170>
- [10] Cheng, D., Tu, Y., et al. (2019) Risk Assessment for Networked-Guarantee Loans Using High-Order Graph Attention Representation. *Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence AI for Improving Human Well-Being*, Macao, 2020, 5822-5828. <https://doi.org/10.24963/ijcai.2019/807>
- [11] Xu, B., Shen, H., et al. (2021) Towards Consumer Loan Fraud Detection: Graph Neural Networks with Role-Constrained Conditional Random Field. *Proceedings of the AAAI Conference on Artificial Intelligence*, **35**, 4537-4545. <https://doi.org/10.1609/aaai.v35i5.16582>
- [12] Zhang, C., Chen, J., Shu, T., et al. (2022) Enterprise Event Risk Detection Based on Supply Chain Contagion. *Proceedings of 2022 IEEE 9th International Conference on Data Science and Advanced Analytics (DSAA)*, Shenzhen, China, 13-16 October 2022, 1-10. <https://doi.org/10.1109/DSAA54385.2022.10032453>
- [13] Wu, D., Wang, Q. and Olson, D.L. (2023) Industry Classification Based on Supply Chain Network Information Using Graph Neural Networks. *Applied Soft Computing*, **132**, Article ID: 109849. <https://doi.org/10.1016/j.asoc.2022.109849>
- [14] 张发明, 李艾珉, 韩媛媛. 基于改进动态组合评价方法的小微企业信用评价研究[J]. 管理学报, 2019, 16(2): 286-296.
- [15] 匡海波, 杜浩, 丰昊月. 供应链金融下中小企业信用风险指标体系构建[J]. 科研管理, 2020, 41(4): 209-219.
- [16] Kipf, T.N. and Welling, M. (2016) Semi-Supervised Classification with Graph Convolutional Networks. <https://arxiv.org/abs/1609.02907>
- [17] Chawla, N.V., Bowyer, K.W., et al. (2002) SMOTE: Synthetic Minority Over-Sampling Technique. *Journal of Artificial Intelligence Research*, **16**, 321-357. <https://doi.org/10.1613/jair.953>
- [18] Lessmann, S., Baesens, B., et al. (2015) Benchmarking State-of-the-Art Classification Algorithms for Credit Scoring: An Update of Research. *European Journal of Operational Research*, **247**, 124-136. <https://doi.org/10.1016/j.ejor.2015.05.030>