

供应链金融的信用风险识别及预警模型研究*

李 健 张金林

(中南财经政法大学金融学院,湖北 武汉 430073)



内容提要:供应链金融作为一种高效便捷的新型融资模式,在解决上下游企业融资、协调供应链管理方面都发挥了积极的作用。信息不对称会导致融资企业信用风险的产生。供应链具有链上传导作用,使企业信用风险更容易传递到整条供应链,从而冲击宏观经济。因此,深入探究影响融资企业发生信用风险的关键因素,构建行之有效的预警模型,对促进供应链金融的稳定发展具有一定的现实意义。本文借助供应链金融的信用风险引发机制,以汽车供应链作为研究样本,依据随机森林模型与盲数理论的变量筛选结果,运用回归分析法探究影响供应链金融的信用风险关键影响因素,并以此为基础,构建 PSO-SVM 供应链金融预警模型,并提出相关建议,以降低信用风险发生的概率。

关键词:供应链金融 信用风险引发机制 关键影响因素 预警模型

中图分类号:F830.56 **文献标志码:**A **文章编号:**1002—5766(2019)08—0178—19

一、引言及文献综述

供应链金融作为一种新的金融业务形态,在解决上下游企业融资、协调供应链管理方面都发挥了积极的作用。由于信息不对称的问题会导致融资企业发生信用风险,并有可能传递到整条供应链,进而引发系统性风险。因此深入探究影响融资企业发生信用风险的关键因素,构建行之有效的预警模型,降低融资企业发生信用违约事件的概率,对促进供应链金融的稳定发展具有一定的现实意义。据此,本文将在描绘供应链金融的信用风险引发机制的基础上,选取相关指标,并依据随机森林与盲数理论的变量筛选结果进行回归分析,以探究影响供应链金融信用风险的关键因素,并以此为基础,构建 PSO-SVM 供应链金融预警模型,以降低信用风险发生的概率,促进供应链金融的稳定发展。

近年来针对供应链金融的研究成为学术界的热点。研究的重点主要包括有关供应链金融的界定、信用风险影响因素以及预警模型的构建等方面。

起初,国内外学者主要聚焦于供应链金融的概念界定。从目前已有文献来看,可以将其分为两类不同的角度:一类从供应链角度出发,如 Hofmann(2005)^[1]、Guillen 等(2007)^[2]认为供应链金融是将企业生产与融资纳入供应链的管理框架中,从而进行整合管理;Gomm(2010)^[3]、Gelsomino 和 Mangiaracina(2016)^[4]认为供应链金融是使用最优化的策略来计划、管理和控制供应链中的现金流,以帮助提高供应链的运作效率;Wuttke 等(2013)^[5]、wandfluh 等(2016)^[6]认为供应链金融能够加强上下游企业与核心企业之间的关系,优化供应链中的融资结构。另一类是从金融角度出发,如

收稿日期:2019-01-06

* 基金项目:国家自然科学基金项目“内生性风险可控视角下信用债 CDS 违约风险缓释效用目标跟踪实现的鲁棒优化研究”(71761029);内蒙古自然科学基金项目“基于复杂网络的内蒙古对外投资企业风险识别与预警模型研究”(2017MS717);中南财经政法大学研究生科研创新项目“基于关联关系的上市公司信用事件风险传染研究”(201810508)。

作者简介:李健,男,博士研究生,研究领域是金融风险,电子邮箱:lj1718ahl@163.com;张金林,男,教授,博士生导师,研究领域是货币银行学,电子邮箱:zjlib@163.com。通讯作者:李健。

Atkinson(2008)^[7]、Gobbi 和 Sette(2014)^[8]认为供应链金融是通过第三方交易平台开展的融资业务,能够有效减少企业融资成本,提高供应链现金流周转速度;Jing 等(2013)^[9]、Caniato 和 Gelsomino(2016)^[10]认为供应链金融是以核心企业与融资机构为中心,优化供应链财务管理的过程。

随后,学者们通过引入不同的变量来探讨供应链金融的影响因素。Hu 和 Ansell(2007)^[11]首次引入宏观环境变量与企业内部财务指标,运用专家评分法评估供应链金融的信用风险影响因素;黄静思等(2014)^[12]将企业的外部环境与供应链的影响因素考虑在内运用层次分析法,认为信用风险应注意整个供应链的系统风险;Su 和 Lu(2017)^[13]将供应链上的银行、融资企业与物流企业等参与主体考虑在内,运用仿真技术评估信用风险;范方志等(2017)^[14]运用核心企业财务数据、融资企业财务数据等变量建立指标体系,利用多目标决策层次分析法进行分析;顾治程和蒋艳(2017)^[15]利用融资企业及核心企业的财务数据,建立基于 Logistic 回归模型的信用风险预警模型。与此同时,Hamadi 和 Abdelmoula(2010)^[16]在利用融资企业财务数据的基础上,建立三层 BP 神经网络预警模型;胡海清等(2012)^[17]利用宏观环境变量与融资企业财务指标,建立支持向量机预警模型;叶晓枫和鲁亚会(2017)^[18]运用融资企业财务指标建立随机森林结合朴素贝叶斯的信用风险预警模型;蒋曼曼(2017)^[19]通过对企业的财务指标进行主成分分析,建立 Logistic 预警模型;戴昕琦(2018)^[20]选取融资企业财务指标,并结合线上供应链金融融资模式特点,建立基于随机森林与 SMOTE 算法的信用风险预警模型。

此外,部分学者对供应链金融的信用风险影响因素进行了定性分析。Walton 和 Gupta(1999)^[21]认为信息化水平的高低是影响供应链金融的信用风险核心因素;Chih(2008)^[22]认为供应链金融的信用风险主要来源于抵押资产减值的风险;Demica(2009)^[23]的报告中指出供应链金融的信用风险取决于供应链的一体化程度以及企业管理状态;Dyckman(2011)^[24]认为融资企业质押物所产生的风险与融资结算周期的长短具有密切关系;Martin(2017)^[25]认为上下游企业与核心企业之间的关系是影响信用风险的主要因素;储雪俭和高博(2018)^[26]认为供应链金融的研究应将核心企业和上下游企业的交易过程进行联系,以防止信用风险的产生。

综上所述,虽然国内外学者对供应链金融的信用风险影响因素及预警模型进行了多方面的研究,但仍存在以下几方面的不足:一是多数研究是以传统信贷业务为视角,并未考虑供应链金融的特点,导致相关变量选取不全面;二是从已有文献的变量筛选来看,未能根据变量的特点选择对应的筛选方法;三是针对预警模型的构建普遍停留在模型的使用阶段,未提供实际有效的模型改进技术及模型稳定性检测,进而无法降低供应链金融的信用风险发生概率。基于此,本文将围绕“降低供应链金融的信用风险发生概率”的核心出发,分析影响供应链金融信用风险的关键因素,并以关键影响因素作为输入变量构建 PSO-SVM 供应链金融预警模型,以降低融资企业信用风险发生的概率,帮助融资企业提高融资能力。

二、信用风险引发机制及指标体系构建

供应链金融的基本架构如图 1 所示。其运作模式可以描述为“4 + 1 + 4”,即四大参与主体、一个外部监管者与四大信息流。从图 1 中可看出供应链金融是以整个产业为角度,通过资金流、物流、商流与信息流对整条产业链进行综合授信与监管。这种新型的融资方式不单改变了传统的融资模式,同时也改变了传统的风险管理方式。

以图 1 所示的供应链金融基本架构为核心,在 Caniato 和 Gelsomino(2016)^[10]的研究成果基础上,本文认为供应链金融可以描述为在产业发展与融资机构所组成的复杂网络中,以核心企业与融资机构作为供应链金融的中心节点,在逐步发展的过程中形成信任与托付关系,从而形成供应链金融的信用体系。

宋远方和黄千贯(2018)^[27]认为,供应链金融作为一种新的金融业务形态,除考虑传统信用风险来源外,还应当结合供应链金融的特点。因此,本文以供应链金融的信用风险引发机制为框架,依据 Demica(2009)^[23]、Wandfluh 等(2016)^[6]及 Martin(2017)^[25]的研究成果,结合供应链金融的特点,构建影响供应链金融的信用风险指标体系,如图 3 所示。

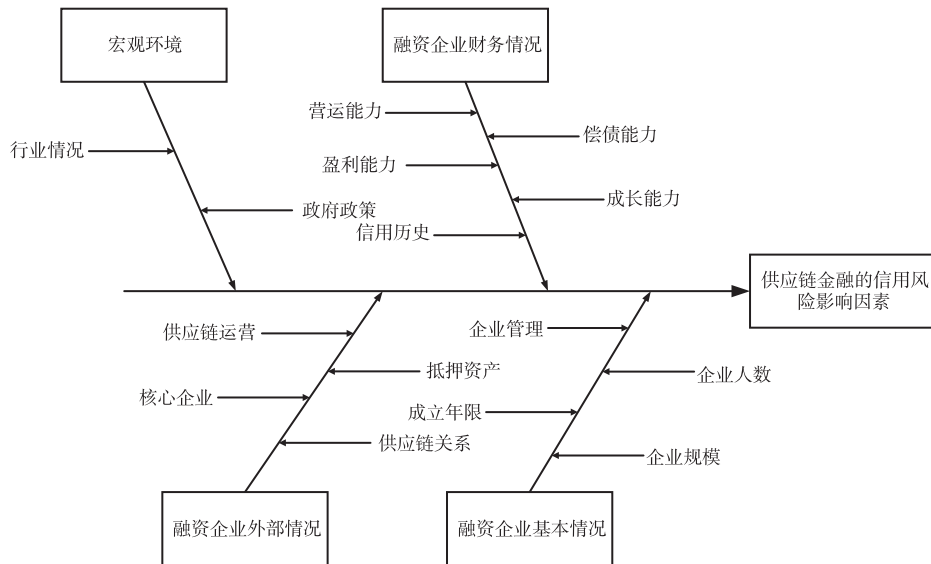


图 3 供应链金融信用风险影响因素鱼骨图

资料来源:本文绘制

三、数据来源及预处理

1. 数据来源及指标说明

目前为止国内供应链金融业务主要中在于计算机通信、汽车、化工、医药等制造行业,其中汽车行业的供应链金融业务在国内发展相对比较成熟。本文考虑到供应链的完整性与数据的可获得性,将选取汽车行业供应链作为样本分析对象。样本数据主要来源于 Wind、CSMAR、中国汽车供应商网以及企业财务报表及披露等多方面信息,并以中国证监会最新发布的行业分类标准为基础,选出上游供应商与下游经销商,共 142 家上下游企业以及 24 家核心企业,其中上下游企业中有 26 家企业出现违约事件,占比 18.3%,核心企业中有 2 家企业出现违约事件,占比 8.3%。

本文选取的数据期限为三年(2015—2017 年)。基于前文所构建的供应链金融信用风险影响因素鱼骨图,并依据戴昕琦(2018)^[20]、Martin(2017)^[25]等的研究基础,将指标体系进行详细分类(如表 1 所示)。其中第一类为融资企业基本情况,包含企业规模,企业成立年限等基本情况;第二类为融资企业财务情况,包含盈利能力指标、营运能力指标、成长能力与信用历史;第三类为宏观环境与政策,包含行业环境与宏观政策;第四类为融资企业外部状况,包含供应链关系、核心企业情况、资产特质及供应链运营情况。

表 1 变量选取及说明

一级变量	二级变量	三级变量	变量简称及说明
融资企业基本情况	企业规模	主营业务收入	X_1 , 企业主营业务收入
	企业成立年限	企业成立年限	X_2 , 企业成立时间
	企业从业人数	企业从业人数	X_3 , 企业从业人数

续表 1

一级变量	二级变量	三级变量	变量简称及说明
融资企业基本情况	企业管理状况	董监高变动情况或是否受过行政处罚等	D_1 , 是否因管理原因受到过行政部门或监管部门的处分以及是否因高级管理人员个人原因对公司造成过重大损失等方面
	企业财务报表质量	财务报表的及时性与真实性等	D_2 , 衡量企业财务报表质量的指标主要有真实性、准确性、及时性、重要性、完整性与合规性等
	内部控制情况	内部控制稳定性、严谨性等	D_3 , 衡量企业内部控制是否存在缺陷
融资企业财务状况	盈利能力	净资产收益率	X_4 , 净利润/净资产总额
		总资产报酬率	X_5 , 净利润/(期初资产总额+期末资产总额)*2
		销售净利率	X_6 , 净利润/营业收入
	偿债能力	资产负债率	X_7 , 总负债/总资产
		流动比率	X_8 , 流动资产/流动负债
		速动比率	X_9 , 速冻资产/流动负债
		利息保障倍数	X_{10} , 经营活动现金流量净额/应付利息
		现金比率	X_{11} , 现金/流动负债
	营运能力	存货周转天数	X_{12} , 360/(销售成本/存货平均金额)
		应收账款周转天数	X_{13} , 应收账款/销售收入*360
		存货周转率	X_{14} , 营业收入/存货余额
		应收账款周转率	X_{15} , 营业收入/应收账款平均余额
		流动资产周转率	X_{16} , 营业收入/流动资产总额
		固定资产周转率	X_{17} , 营业收入/固定资产净值
		总资产周转率	X_{18} , 营业收入/资产总额
	成长能力	收入增长率	X_{19} , 本年营业收入增加额/上年营业收入
		新产品开发能力	X_{20} , 研发费用/营业收入
	信用历史	对外担保情况	X_{21} , 对外担保占净资产的比重
违约情况		Y , 违约情况	
宏观环境及政策	行业环境	供应链总利润率	X_{22} , 供应链利润/供应链销售额
		行业前景	X_{23} , 行业增长率
	宏观政策	宏观经济政策、政策支持力度	D_4 , 政府政策对融资企业所在行业的支持力度
融资企业外部状况	供应链关系	供应链的强度与久度	D_5 , 融资企业与核心企业的供应链的关系
		上游下游的依赖程度	D_6 , 核心企业对供应链中上下游企业的依赖程度
	核心企业情况	核心企业信用等级	D_7 , 核心企业在银行的信用评级
		资产负债率	X_{24} , 总负债/总资产
		销售利润率	X_{25} , 净利润/营业收入
		速动比率	X_{26} , 速冻资产/流动负债
		核心企业违约情况	D_8 , 核心企业是否有违约现象
		核心企业经营稳定性	D_9 , 核心企业是否管理问题或财务报表情况被处罚
	资产特质	核心企业的行业地位	X_{27} , 核心企业市场占有率
		质押模式	D_{10} , 融资企业的质押模式分类
	供应链运营情况	质押物的变现能力	D_{11} , 融资企业的质押物的流动性、变现能力
信息化水平		D_{12} , 融资企业所在供应链的信息获取能力	
协同处理能力		D_{13} , 融资企业业务协同处理能力和水平	

资料来源:本文整理

2. 数据预处理

由于涵盖的财务指标过多,并且财务指标之间相关性较强,因此,对融资企业财务数据进行相关性检验,将相关性绝对值大于0.75的变量剔除,由此总资产报酬率(X_5)、流动比率(X_8)、速动比率(X_9)、存货周转率(X_{14})、总资产周转率(X_{18})剔除。

针对离散型变量,将依据表1所述的变量说明,将其划分为0、1变量,如企业管理状况(D_1)将通过阅读上市公司财务报表披露信息,以查看企业董监高变动情况或是否受到中国证监会行政处罚等,其他离散型变量以此类推。由于不同连续型变量之间量纲单位往往不同,为使模型更具准确性与可行性,针对连续性变量,即企业规模(X_1)、企业成立年限(X_2)、企业从业人数(X_3)等16个变量,进行标准化处理。

四、变量特征筛选

由于本文所选取变量较多,直接用于模型分析将会导致模型过拟合现象,从而降低模型准确性。其中融资企业基本情况与融资企业财务状况两大类中连续型变量较多,适用于机器学习算法,因此利用随机森林特征筛选方法;融资企业外部状况和宏观环境及政策两大类指标中离散型变量较多,且属于一种复杂的“信息混沌”,包含随机性、模糊性以及灰性等多种不确定性信息,并且其外部信息很难以单一值计算结果,因此选用盲数理论进行变量筛选具有更好的可信度,并能有效地减少因取值主观性因素对结果的影响。

1. 随机森林变量特征筛选

随机森林变量筛选方法,不仅能在不做特征选择时处理高维数据,而且能将变量间的内在联系考虑在内,相对其他变量筛选方法有着很大优势。

本文将融资企业基本情况与融资企业财务状况两大类指标24个变量利用随机森林变量筛选法。为使变量筛选更客观,本文将142家样本企业随机均分为5组,并依据5组变量的重要性得分均值来选择变量。随机森林模型中ntree选取为默认值,mtry由变量的平方根来确定(李杰,2018)^[28],随机森林算法建立的特征重要性评分如表2所示^①。

表2 随机森林指标特征重要性得分

变量名称	第一组	第二组	第三组	第四组	第五组	得分均值
X_2	1.311	0.335	0.229	0.653	0.656	0.637
X_3	0.359	0.338	0.662	0.256	0.335	0.39
D_1	0.167	1.376	0.018	0.055	0.053	0.334
D_2	0.095	0.806	0.026	0.309	0.01	0.249
D_3	0.053	0.085	0.018	0.544	0.395	0.219
X_4	0.54	1.16	0.142	1.33	0.324	0.699
X_6	0.777	0.489	0.294	1.109	0.419	0.617
X_7	0.435	0.438	0.402	0.3	0.286	0.372
X_{10}	0.2	0.543	0.104	0.244	0.295	0.277
X_{11}	0.286	0.386	0.073	0.242	0.393	0.276
X_{12}	0.202	0.202	0.607	0.36	0.275	0.329
X_{13}	0.391	0.292	0.888	0.196	0.289	0.411
X_{15}	0.312	0.24	0.752	0.155	0.234	0.339
X_{16}	0.272	0.961	0.198	0.47	0.38	0.456
X_{17}	0.428	0.696	0.286	0.306	0.263	0.396
X_{19}	0.522	0.493	0.605	0.794	0.291	0.541
X_{20}	0.924	0.517	0.096	0.754	0.585	0.575
X_{21}	0.396	0.567	0.513	0.202	0.864	0.509

资料来源:R语言计算,本文整理

① 由于篇幅所限,随机森林特征选取基尼系数图并未展示,备案。

随机森林特征重要度得分,能够有效说明解释变量对被解释变量的重要程度。因此,将表2的变量重要性得分由高到低排序后,选取净资产收益率(X_4)、企业成立年限(X_2)、销售净利率(X_6)、新产品开发能力(X_{20})、收入增长率(X_{19})、对外担保情况(X_{21})、流动资产周转率(X_{16})、企业规模(X_1)共八个变量,本文将利用以上八个变量进行实证分析。

2. 盲数理论变量特征筛选

将融资企业外部状况与宏观环境及政策两大类指标16个变量利用盲数理论进行变量筛选。

(1)盲数理论。盲数理论是由吴和琴教授所提出,该方法作为一种处理不确定信息的工具,在处理随机性、模糊性以及灰性等多种不确定性信息中能够更确切地反映其外部信息的实际状况,并且具有较好的变量筛选特征。

设 G 为有理灰集,则 $\alpha \in G, f(x)$ 定义为在 G 上的灰函数,若 $\alpha_i \in [0, 1], i = 1, 2, \dots, n$,且:

$$f(x) = \begin{cases} \alpha_i, X = X_i (i = 1, 2, \dots, n) \\ 0, \text{其它} \end{cases} \quad (1)$$

当 $i \neq j$ 时, $X_i \neq X_j$ 且 $\sum_{i=1}^n \alpha_i = \alpha \leq 1$,则将函数 $f(x)$ 称之为盲数。其中, α_i 称为函数 $f(x)$ 在 X 取值 X_j 时的可信度,则 α 为总可信度, n 为函数 $f(x)$ 的阶数。由其定义可以看出,盲数的实质为具有区间分布的可信度函数。

设 a, b 为实数,且 $a \leq b$,则有区间 $[a, b]$ 的有理灰数的心为 $(a+b)/2$,将其记为: $\odot[a, b] = (a+b)/2$,则 n 阶 $f(x)$ 盲数的期望值可以表示为:

$$E(f(x)) = \begin{cases} \alpha, X = \frac{1}{\alpha} (\odot \sum_{i=1}^n \alpha_i X_i) \\ 0, \text{其它} \end{cases} \quad (2)$$

依据统计学理论,可将盲数的方差表示为:

$$D(f(x)) = \sum_{i=1}^n [\alpha_i (\odot X_i - E(f(x)))^2] / \alpha \quad (3)$$

同时,通过式(3)则可得其标准差为:

$$S(f(x)) = \sqrt{D(f(x))} \quad (4)$$

(2)专家可信度与综合度。通常,专家的个人可信度越高,则其权威性也越大。为体现参与本项目测评的专家个人可信度的真实性,本文将按照专家职称、学历与资历三个方面进行可信度量化^①。

$$A_i = \sum_{i=1}^3 \omega_i S_i / 100 \quad (5)$$

其中, A_i 代表专家个人可信度, ω_i 代表项目对应的权重, S_i 代表相应的分值。假设一组专家 E_1, E_2, \dots, E_n 的个人可信度分别为 A_1, A_2, \dots, A_n ,则专家 E_i 关于专家组的个人综合可信度为:

$$A_i = \frac{A_i}{(A_1 + A_2 + \dots + A_n)}, i = 1, 2, \dots, n \quad (6)$$

专家组的综合可信度则有:

$$A = \frac{(A_1 + A_2 + \dots + A_n)}{n} \quad (7)$$

(3)变量盲数评价矩阵。假设有 n 名专家对评价变量 $u_i (i = 1, 2, \dots, n)$ 进行百分制打分,其中专家 $E_i (i = 1, 2, \dots, n)$ 针对变量 u_i 评分为 $a_i \in G, a_i$ 为有理灰。那么针对变量 u_i 的 n 名专家评分分别为: a_1, a_2, \dots, a_n ,每个评分对应的专家个人综合可信度分别为: $\theta_1, \theta_2, \dots, \theta_n$ 。将 n 名专家针对变量 u_i 的评分进行无交叉排序,遇到相同值时仅取一个,同时对应的专家可信度将其求和,则将得

① 专家可信度量化参考标准表并未列出,备索。

到新的排列组合 $\eta_1, \eta_2, \dots, \eta_k (k \leq n)$, 那么对变量 u_i 的盲数评价为:

$$U_i(X) = \begin{cases} \theta_{i1}, X = \eta_1 \\ \theta_{i2}, X = \eta_2 \\ \vdots \\ \theta_{ik}, X = \eta_k \\ 0, X \notin \{\eta_1, \eta_2, \dots, \eta_k\} (k \leq n) \end{cases} \quad (8)$$

(4) 变量结果分析。根据本文研究的实际情况, 遵循客观性与权威性的原则, 本文将选取 2 名在供应链金融领域中具有代表性的学者以及 4 名具有 10 年以上工作经验的银行从业人员, 共 6 位专家参与此次问卷调查。依专家可信度量化参考标准与式(5), 得到 6 名专家的个人可信度分别为 0.9、0.86、0.74、0.78、0.82、0.66, 应用式(6) 计算专家组的个人综合可信度分别为 0.19、0.14、0.16、0.17、0.18、0.16, 同时应用式(7) 计算专家组的综合可信度为 0.79。

将本文中融资企业外部状况与宏观环境两大类指标分别发给 6 位专家, 经过不断反馈与调整后, 将专家打分情况进行分析。并依据式(2) 与式(4) 构造变量可靠度公式, 以评价变量的可靠程度, 具体公式如下:

$$R(f(X)) = 1 - \frac{S(f(X))}{E(f(X))} \quad (9)$$

依据 6 位专家的打分情况, 首先应用式(8) 计算变量盲数评价矩阵, 其次应用式(2)、式(3) 与式(4) 分别计算变量均值、方差以及标准差, 最后利用式(10) 计算变量可靠度, 并通过式(10) 计算变量得分(式(10) 中 U 对应指标评分向量 $U = (U_1, U_2, \dots, U_n)$), 具体结果如表 3 所示。

$$D = R(f(X)) \times U \quad (10)$$

表 3 指标得分表

指标名称	均值	方差	标准差	可靠度	得分
X_{22}	64.0126	13.7329	3.7058	0.9421	60.3068
X_{23}	65.5672	34.1524	5.8440	0.9109	59.7232
D_4	65.8193	14.6453	3.8269	0.9419	61.9924
D_5	74.5588	25.8386	5.0832	0.9318	69.4757
D_6	76.1134	38.5563	6.2094	0.9184	69.9041
D_7	66.9958	81.7050	9.0391	0.8651	57.9567
X_{24}	69.2647	15.8692	3.9836	0.9425	65.2811
X_{25}	65.1261	43.6739	6.6086	0.8985	58.5174
X_{26}	64.1807	24.9730	4.9973	0.9221	59.1834
D_8	76.7647	29.4408	5.4259	0.9293	71.3388
D_9	75.7773	25.8520	5.0845	0.9329	70.6928
X_{27}	60.6933	3.7636	1.9400	0.9680	58.7533
D_{10}	63.4454	18.6681	4.3207	0.9319	59.1247
D_{11}	67.3739	26.9246	5.1889	0.9230	62.1851
D_{12}	71.6387	6.9430	2.6350	0.9632	69.0037
D_{13}	70.6513	13.8976	3.7280	0.9472	66.9233

资料来源: 本文整理

从表 3 中可以看出变量可靠度均大于 0.85, 说明变量盲数选取可靠程度高。将表 3 中各变量得分由高到低排序, 从中选取得分较高的八个变量, 即核心企业违约情况(D_8)、核心企业经营稳定性(D_9)、上游下游的依赖程度(D_6)、与供应链的强度与久度(D_5)、信息化水平(D_{12})、协同处理能力(D_{13})、资产负债率(X_{24})、质押物的变现能力(D_{11})。

五、关键影响因素实证分析

基于随机森林变量筛选以及盲数理论变量筛选, 将经过筛选的变量进行整合将得到: 净资产收

益率、企业成立年限、销售净利率、新产品开发能力等,共计 16 个变量。

1. 二分类回归模型

由于 Logistic 模型数据要求比较灵活,模型适用性好以及稳定性强等方面具有独特优势,成为学者们研究信用风险影响因素的主要方法。该模型是引入概率的概念,将因变量的值域 $(-\infty, +\infty)$ 映射到 $(0,1)$ 之间。具体而言,假设事件 A 发生的概率为 P ,则 $1-P$ 为事件 A 未发生的概率。设影响事件 A 的因素有 $(x_1, x_2, \dots, x_n) \in X$,因变量为 y 。当 $y=1$,表示事件 A 会发生; $y=0$ 表示事件 A 未发生。因此,基于事件 A 建立的 Logistic 模型表示为:

$$P = \frac{1}{1 + \exp(-\beta_0 - \beta \times X)} \quad (11)$$

其中, $(\beta_1, \beta_2, \dots, \beta_n) \in \beta$,由于式(11)为非线性函数,因此将其进行对数变换,得:

$$\ln\left(\frac{P}{1-P}\right) = \beta_0 + \beta \times X \quad (12)$$

通过模型运算,可以得出当因变量取值大于 0.5,则认为因变量属于 1 类(事件 A 发生),反之属于 0 类(事件 A 未发生),并通过极大似然估计(MLE)估计系数 β ,进而分析各变量对事件 A 的影响程度。

2. 变量设置及分析

本文将经过筛选的 16 个变量重新进行编排,为构建供应链金融的信用风险影响因素及预警模型奠定基础。具体变量设置及说明如表 4 所示。

表 4 变量设置及说明

变量	变量符号	变量说明
企业规模	X_1	$X_1 \in (-\infty, +\infty)$, 企业营业收入来衡量企业规模
企业成立年限	X_2	$X_2 \in (0, +\infty)$, $X_2 \in N$ 表示企业成立的年限
净资产收益率	X_3	$X_3 \in (-\infty, +\infty)$, $X_3 = \frac{a_1}{b_1}$, a_1 代表净利润, b_1 代表净资产总额
销售净利率	X_4	$X_4 \in (-\infty, +\infty)$, $X_4 = \frac{a_2}{b_2}$, a_2 代表净利润, b_2 代表营业收入
流动资产周转率	X_5	$X_5 \in (-\infty, +\infty)$, $X_5 = \frac{a_3}{b_3}$, a_3 代表营业收入, b_3 代表平均流动资产
收入增长率	X_6	$X_6 \in (-\infty, +\infty)$, $X_6 = \frac{a_4}{b_4}$, a_4 代表本年营业收入增加额, b_4 代表上年度营业收入
新产品开发能力	X_7	$X_7 \in (0, +\infty)$, $X_7 = \frac{a_5}{b_5}$, a_5 代表研发支出, b_5 代表营业收入
对外担保情况	X_8	$X_8 \in (0, +\infty)$, $X_8 = \frac{a_6}{b_6}$, a_6 代表对外担保总额, b_6 代表净资产总额
供应链的强度与久度	D_1	$D_1 = (1, 2, 3)$, 其中 $D_1 = 1$ 代表融资企业与核心企业之间的关系较差; $D_1 = 2$ 代表融资企业与核心企业之间的关系较好; $D_1 = 3$ 代表融资企业与核心企业之间的关系好
上游下游的依赖程度	D_2	$D_2 = (1, 2, 3)$, 其中 $D_2 = 1$ 代表核心企业对融资企业的依赖程度弱; $D_2 = 2$ 代表核心企业对融资企业的依赖程度中; $D_2 = 3$ 代表核心企业对融资企业的依赖程度强
核心企业资产负债率	X_9	$X_9 \in (0, +\infty)$, $X_9 = \frac{a_7}{b_7} \times 100\%$, a_7 代表核心企业负债总额, b_7 代表核心企业资产总额

续表 4

变量	变量符号	变量说明
核心企业违约情况	D_3	$D_3 = 1$ 表示核心企业存在违约, $D_3 = 0$ 表示核心企业无违约
核心企业经营稳定性	D_4	$D_4 = (1, 2, 3)$, 其中 $D_4 = 1$ 代表核心企业经营稳定性较差; $D_4 = 2$ 代表核心企业经营较稳定; $D_4 = 3$ 代表核心企业经营稳定性强
质押物的变现能力	D_5	$D_5 = (1, 2, 3, 4)$, 其中 $D_5 = 1$ 代表融资企业质押物为无; $D_5 = 2$ 代表融资企业质押物变现能力弱; $D_5 = 3$ 代表融资企业质押物变现能力一般; $D_5 = 4$ 代表融资企业质押物变现能力强
信息化水平	X_{10}	$X_{10} \in (0, +\infty)$, $X_{10} = (a_9 + b_9) \times 50\%$, $a_9 = \frac{\text{融资企业存货占用资金}}{\text{融资企业流动资金}}$, $b_9 = \frac{\text{核心企业存货占用资金}}{\text{核心企业流动资金}}$
协同处理能力	X_{11}	$X_{11} \in (0, +\infty)$, $X_{11} = (a_9 + b_9) \times 50\%$, a_9 代表融资企业存货周转率, b_9 代表核心企业存货周转率
融资企业违约情况	Y	$Y = 1$ 代表融资企业为违约客户, $Y = 0$ 代表融资企业为非违约客户

资料来源: 本文整理

部分变量进行解释说明: (1) 供应链的强度与久度。通过衡量融资企业与核心企业之间合作的年限以及合作金额等将该变量划分为三类, 若融资企业与核心企业合作时间越长、合作金额越大, 则该变量划分等级越高; (2) 上游下游的依赖程度。通过衡量核心企业的供应商或经销商的数量进行划分, 若核心企业所需的供应材料或销售仅有一家或很少的企业才能提供, 则核心企业对该企业的依赖性强, 那么变量划分等级越高; (3) 核心企业经营稳定性。通过阅读上市公司公告了解核心企业董监高变动情况或是否受到行政部门或监管部门的处罚、财务报表状况以及对外担保等信息, 以衡量核心企业经营稳定情况, 并将指标划分为三类, 即稳定、较稳定与不稳定; (4) 质押物的变现能力。通过查阅上市公司公告了解企业融资金额以及质押物等相关信息, 依据质押物以及融资金额等信息将其指标分为三类, 即强、中、弱, 若融资金额高且质押物属于不动产或股权质押则将指标定义为强, 以此类推; (5) 信息化水平。依据国家信息化测评中心发布的《信息化基本指标构成方案(试行)》办法中关于企业信息化水平衡量指标信息, 将企业信息化水平定义为: 存货占用资金与流动资金的比值, 由于这里衡量的是供应链整体信息化水平, 故指标取核心企业与融资企业的均值; (6) 协同处理能力。依据戴昕琦(2018)^[20]对供应链金融中融资企业信息协同程度变量的解释, 即协同程度高的企业通常表现为存货周转率较高。因此将协同处理能力变量定义为融资企业与核心企业存货周转率的平均值。

表 5 列示了经过编排后的变量描述性统计。从表 5 可看出, 融资企业的收入增长率、净资产收益率处于较高水平, 均在 10% 以上, 说明融资企业经营状况较好。企业成立年限、净资产收益率等变量变异系数较小, 说明融资企业的成立年限、净资产收益率以及流动资产周转率等变量差异较小, 与此相反, 融资企业规模、融资企业收入增长率等变量变异系数较大, 说明融资企业的规模与融资企业收入增长状况差异较为明显。

表 5 指标描述性统计

指标名称	最小值	平均值	变异系数	标准差	最大值
企业规模(X_1)	58733082	7052818268	3.2298	22779539750	160711522503
企业成立年限(X_2)	6	19.62	0.2641	5.183	32
净资产收益率(X_3)	-0.0357	0.1031	0.5487	0.0558	0.2044

续表 5

指标名称	最小值	平均值	变异系数	标准差	最大值
销售净利率(X_4)	-0.0625	0.061	0.0431	0.707	0.1696
流动资产周转率(X_5)	0.0988	0.3658	0.4441	0.412	1.9949
收入增长率(X_6)	-0.4374	0.1521	1.6146	0.2455	0.5341
新产品开发能力(X_7)	0.0004	0.0387	0.4268	0.0165	0.0875
对外担保情况(X_8)	0.0012	0.1428	0.1313	0.9194	0.4822
供应链的强度与久度(D_1)	1	—	—	0.741	3
上游下游的依赖程度(D_2)	1	—	—	0.784	3
核心企业资产负债率(X_9)	0.3904	0.6184	0.2128	0.1316	0.882
核心企业违约情况(D_3)	0	—	—	0.3	1
核心企业经营稳定性(D_4)	1	—	—	0.7477	3
质押物的变现能力(D_5)	1	—	—	1.045	4
信息化水平(X_{10})	0.0838	0.9817	0.5792	0.5686	2.5735
协同处理能力(X_{11})	1.0585	7.7745	0.4183	3.2521	15.724
融资企业违约情况(Y)	0	—	—	0.389	1

资料来源:R语言计算,本文整理

3. 回归结果分析

在进行回归检验前,针对重新编排的连续性变量,既企业规模、企业成立年限、净资产收益率、销售净利率等 11 个连续型变量,运用 Z-score 进行标准化处理;针对多值离散型变量,即供应链的强度与久度、上游下游的依赖程度及核心企业经营稳定性等 4 个变量,利用独热编码(one-hot encoding)方法对其进行编码处理,使其符合二元特征,以消除指标间的多重共线性,提高模型分析质量。

将融资企业违约情况(Y)作为被解释变量,企业规模(X_1)、企业成立年限(X_2)、净资产收益率(X_3)等作为解释变量,运用逐步回归、AIC 信息判断等分析供应链金融的信用风险影响因素,并依据回归模型结果,建立供应链金融的信用风险影响因素回归方程。Logistic 模型回归结果如表 6 所示。

表 6 Logistic 模型结果

指标	估计结果	标准误差	Z 值	P 值
截距项	-3.6488	0.6571	-5.553	2.82e-08***
企业成立年限(X_2)	0.6757	0.3093	2.184	0.02893**
销售净利率(X_4)	-0.8496	0.3710	-2.290	0.02201**
流动资产周转率(X_5)	-0.7601	0.3771	-2.015	0.004385***
供应链的强度与久度(D_1)	-2.0692	0.6903	-2.998	0.00272***
核心企业资产负债率(X_9)	0.6054	0.3726	1.625	0.00426***
核心企业违约情况(D_3)	4.0612	0.9662	4.203	2.63e-05***

注:***、**、* 分别表示在 1%、5%、10% 水平上显著

资料来源:R语言计算,本文整理

表 6 为经过 18 次逐步回归迭代后的结果,从中可以看出在 5% 的显著水平下显著的变量主要有企业成立年限、销售净利率、流动资产周转率、供应链的强度与久度、核心企业资产负债率以及核心企业违约情况。其中,销售净利率、流动资产周转率以及供应链的强度与久度对融资企业的违约概率具有负效应,即融资企业销售净利率等变量越高,融资企业的违约概率越低;对融资企业违约概率有正效应的指标有融资企业成立年限、核心企业资产负债率与核心企业违约情况,说明融资企业年限越长、核心企业资产负债率越大或核心企业存在违约,则融资企业的违约概率越高。同时,依据表 6 建立式(13)的回归方程。

$$P(Y = 1) = \frac{1}{1 + \exp(3.6488 - 0.6757X_2 + 0.8496X_4 + 0.7601X_5 + 2.0692D_1 - 0.6054X_9 - 4.0612D_3)} \quad (13)$$

值得注意的是,从本文供应链金融的信用风险影响因素实证结果来看,融资企业的相关变量、供应链关系的强度、核心企业资产负债率以及核心企业历史违约情况都会显著影响融资企业的违约概率,这与前文第三节论述的供应链金融的信用风险引发机制相一致,并验证 Demica (2009)^[23]、Martin(2017)^[25]等所提出的研究结论。上述变量从基本上展现出供应链金融的信用风险关键影响因素,因而融资机构在对供应链中上游供应商或下游经销商进行信用风险评估时,可重点关注这些变量。

为进一步保证模型结果的可靠性,本文针对所建立的模型进行 Omnibus 检验。表 7 列示了模型系数的综合检验结果,从中可以看出三个 p 值均小于 0.05 临界值。因此本文模型参数结果可靠,模型在统计学上具有意义。

表 7 模型系数的 Omnibus 检验

		卡方	自由度	P 值
步骤 1	步骤	22.043	3.000	.000
	块	22.043	3.000	.000
	模型	22.043	3.000	.000

资料来源:R 语言计算,本文整理

六、信用风险预警模型

为深化供应链金融的信用风险影响因素研究,本文在上述回归分析的基础上,建立供应链金融的信用风险预警模型,以降低供应链金融的信用风险发生概率。由于供应链金融的信用风险违约问题的判别属于近似线性可分问题,因此本文利用粒子群算法(PSO)优化非线性软间隔支持向量机(SVM)构建供应链金融的信用风险预警模型。

1. SVM 模型

支持向量机(SVM)作为一种有监督学习算法的新型分类器,通常用来进行模式识别、分类预警以及回归分析等多领域的广泛应用。支持向量机在引入核方法后一般分为三类:线性可分支持向量机、软间隔支持向量机与非线性支持向量机。

支持向量机算法解决的核心问题是如何寻找最佳超平面问题。因此在给定样本训练集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \in (X \times Y)^n$, 其中对于第 i 个样本的 $y_i \in Y = [1, -1], i = 1, 2, \dots, n$, 可将其转化为如下优化方程进行求解:

$$\begin{cases} \min \Phi(\omega) = \frac{\omega^2 + C \sum_{i=1}^n \omega_i \varepsilon_i}{2} \\ s. t. y_i(\omega^T x_i + b) \geq 1 - \varepsilon_i \\ \varepsilon_i, 0, i = 1, 2, \dots, n \end{cases} \quad (14)$$

其中,主要求解权重向量 ω 与偏移向量 b , 其中训练样本为 (x_i, y_i) , ε_i 代表松弛变量, C 为可调节参数, 又称惩罚系数, n 代表训练样本的个数。为求解式(15)将选取对非线性数据有较好分析能力且参数较少的径向基核函数式(15)与可调节参数 C , 将式(14)转为二次规划最优问题, 见式(15)。

$$K(x_i, y_i) = \exp\left(\frac{\| -x_i - x_j \|^2}{\sigma^2}\right) \quad (15)$$

$$\begin{cases} \min \Phi(\alpha) = \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i y_i \alpha_j y_j K(x_i, y_j) - \sum_{j=1}^n \alpha_j \\ s. t. \sum_{i=1}^n \alpha_i y_i = 0 \\ 0 \leq \alpha_i \leq C, i = 1, 2, \dots, n \end{cases} \quad (16)$$

式(16)具有较强的外推能力,可应用于高维的特征空间,适用于信用风险预警模型。其中 α_i 代表样本 i 对应的式(16)最优解,并以此计算 $\omega = \sum_{i=1}^n \alpha_i y_i x_i$ 与阈值 $b = y_i - \sum_{i=1}^n \alpha_i y_i K(x_i, y_i)$ 。同时,通过超平面 $f(x) = \omega x + b = 0$,得到对应的决策函数:

$$f(x) = \text{sign}\left(\sum_{i=1}^n \alpha_i y_i K(x_i, y_i) + b\right) \quad (17)$$

支持向量机模型主要应用于解决二分类甚至可以转化为多分类问题,其中,不同的参数 C 与核参数 σ 的构造对支持向量机的性能有很大差异,并且目前针对参数 C 与核参数 σ 的选择没有明确的定义。因此,针对支持向量机的参数优化问题便成为研究的热点。

2. PSO 算法

PSO 算法又称粒子群算法,是由 Kennedy 和 Everhart 在 1995 年所提出的一种基于群体的随机优化技术。PSO 算法与其他启发式优化算法一样,均初始化一组随机解,通过迭代搜寻最优解。但 PSO 算法与其他类型的遗传算法相比,具有较快的收敛速度、鲁棒性强、易于实现等多方面优点。

PSO 算法模拟社会原则,首先将种群初始化,其次将初始化的种群中每个个体视为无体积的粒子,并将可能解视为粒子,每个粒子都具有初始位置和初始速度,并依据目标函数来决定群体适应度;最后所有粒子在一个搜索空间中以一定速度飞行,并通过追随最优值来寻求群体最优解。

假设在初始化 N 维搜索空间中,由 m 个粒子构成一个种群,则将种群表示为: $P = (x_1, x_2, \dots, x_m)^T$;第 i 个粒子的位置为: $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})^T, i = 1, 2, \dots, m$;第 i 个粒子的速度为: $v_i = (v_{i1}, v_{i2}, \dots, v_{iN})^T, i = 1, 2, \dots, m$ 。粒子经过 t 次迭代后的位置信息与速度信息记为 x_i 与 v_i ,将其带入适应度函数,以评价粒子的位置与速度优劣,并将第 i 粒子的最优位置记为 p_{best} ,则整个种群的所有粒子最优位置记为 G_{pbest} 。其中位置与速度的更新依据式(18)与式(19)来进行:

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (18)$$

$$v_i^{t+1} = wv_i^t + C_1 \times \text{rand}() \times (P_i^t - x_i^t) + C_2 \times \text{rand}() \times (P_g^t - x_i^t) \quad (19)$$

其中, C_1 与 C_2 为学习因子, w 为惯性权重。其中为保证算法具有较高的搜索能力,将 w 设为递减函数,将其表示为:

$$w(t) = w_{\max} - \text{Iteration} \times [(w_{\max} - w_{\min}) / \text{Max_iteration}] \quad (20)$$

其中,迭代次数由 Iteration 表示, w_{\max} 和 w_{\min} 分别代表惯性权重 w 经过迭代 t 次数后的最大值与最小值。

3. 训练集与预测集的构建

基于的第五节回归结果,将回归分析中得到的关键变量,即企业成立年限、销售净利率以及流动资产周转率等变量作为预警模型的输入因子。将本文的融资企业样本数据按照 4:1 的比例分配训练集与测试集。通过预警模型对训练集的不断学习,拟合出最优预警模型,再通过对测试集进行预测,从而验证预警模型的有效性。具体分类情况如表 8 所示。

表 8 训练集与测试集样本分布情况

融资企业样本	非违约样本	违约样本	合计
训练集	93	21	114
测试集	22	5	27
合计	116	26	142

资料来源:本文整理

4. PSO-SVM 预警模型设计

本文建立供应链金融的信用风险预警模型目的是尽量实现准确的预测,其实质可以转化为二分类问题。由于供应链金融的信用风险影响因素较多,样本极不均衡,传统的预警模型效果不佳,而支持向量机适用于解决不均衡、非线性、高维度等问题,在分类问题上有着良好的应用。然而支

持向量机(SVM)模型在选择不同参数 C 与核参数 σ 时,会导致结果的差异,并从以往研究来看,如胡海清等(2012)^[17]都是以默认的参数 C 与核参数 σ 构建支持向量机(SVM)预警模型,但并没有达到预警模型的最优设置。因此,为实现预警模型更为准确的预测,尝试利用粒子群优化算法优化支持向量机中的参数 C 与核参数 σ ,以提高预测的准确性。

依据表 8 所划分的训练集与预测集,利用粒子群算法,同时采用交叉验证法寻求最优的参数 C 与核参数 σ ,作为 SVM 模型的参数。具体的 PSO-SVM 模型的构建步骤如下所示:

步骤 1:对种群进行随机初始化,确定粒子的初始速度与位置;

步骤 2:以模型预测准确率作为 PSO 算法中的适应度函数,适应度函数如下所示:

$$fit = \frac{x}{x + y} \times 100\% \tag{21}$$

其中, x 代表样本中分类正确的个数, y 代表样本中分类错误的个数。

步骤 3:评价种群中的所有粒子,并依据适应度函数对粒子适应度与个体位置进行更新,以存储在 $pbest$ 中,并对种群位置进行更新,如此反复迭代计算,将最优的粒子适应度与位置信息存储在 $gbest$ 中;

步骤 4:粒子的位置与速度依据式(18)与式(19)进行更新计算;

步骤 5:若粒子的适应度与位置信息以达到最优选择,则迭代计算终止,输出适应度与 $gbest$,否则返回步骤 2;

步骤 6:将寻求的最优参数 C 与核参数 σ ,建立 SVM 模型进行样本训练,重新预测,以获取最优决策函数。

5. PSO-SVM 预警模型分析及对比

对输入变量进行线性压缩处理,得到新的训练集样本与测试集样本,其中训练集样本作为 PSO-SVM 模型的输入因子,测试集样本用于测试 PSO-SVM 模型的准确度。针对 PSO 优化算法的参数 C 的取值范围设置为 $[0.01, 10]$,核参数 σ 的取值范围设置为 $[0.01, 10]$,惯性权重 $\lambda = 0.8$,学习因子 $C_1 = 1.6$ 与 $C_2 = 1.7$,初始化种群规模设为 20,最大迭代次数设为 200 次,并结合交叉验证法寻求最优的参数 C 与核参数 σ 以建立 SVM 模型。图 4 为 PSO 算法参数寻优适应度与进化代数图。

平均适应度曲线 (参数 $c_1=1.6, c_2=1.7$, 终止代数=200, 种群规模=20)




图 4 粒子群适应度曲线

资料来源: Matlab 绘制

将融资企业是否违约作为输出结果,将有违约的融资企业,记为“1”,无违约的融资企业,记为“0”。通过训练集样本进行算法学习,得到 PSO 算法输出的最优参数 $C = 3.124$ 与核参数 $\sigma = 0.991$,以此建立 PSO-SVM 供应链金融的信用风险预警模型,并对测试集样本进行预测以检验预警模型的有效性。具体测试结果与准确率如表 9 所示。

表 9 PSO-SVM 供应链金融信用风险预警模型结果测试表

样本观测结果			
样本集		0	1
训练集	0	92	1
	1	8	13
准确率		92.11%	
样本集		0	1
测试集	0	22	0
	1	1	4
准确率		96.3%	

资料来源:Matlab 计算,本文整理

从表 9 可以看出训练集样本的预测正确率为 92.11%,测试集样本的预测准确率为 96.3%,说明 PSO-SVM 供应链金融的信用风险预警模型判断准确率较高。为验证预警模型的稳定性,利用改变训练集样本个数的方法来验证。随机抽取 25% 的训练集样本个数放入测试集样本中,即 87 个训练集样本与 54 个测试集样本,其中训练集样本中共 11 个违约;测试集样本中共 15 个违约,PSO 优化算法的初始参数不变设置,通过训练集样本的学习,得到最优参数 $C = 4.4090$ 与核参数 $\sigma = 0.9325$ 。参数寻优适应度与进化代数如图 5 所示。

平均适应度曲线 (参数 $e1=1.6$, $c2=1.7$, 终止代数=200, 种群规模=20)

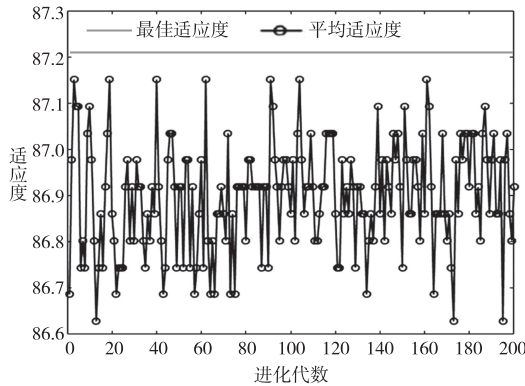


图 5 粒子群适应度曲线

资料来源:Matlab 绘制

依据输出的最优参数 C 与核参数 σ 建立 SVM 模型,以分析预警模型的稳定性。表 10 为模型稳定性结果测试表,从中可看出训练集的预测准确达到了 94.25%,相比之前测试结果有所上升,主要原因在于训练集样本的减少,而测试集预测准确率为 92.6% 与之前测试结果(96.3%)相差不多,说明预警模型鲁棒性较强,预警模型通过稳定性检验。

表 10 PSO-SVM 供应链金融信用风险预警模型稳定性结果测试表

样本观测结果			
样本集		0	1
训练集	0	75	1
	1	4	7
准确率		94.25%	
样本集		0	1
测试集	0	39	0
	1	4	11
准确率		92.6%	

资料来源:Matlab 计算,本文整理

为更好地检验 PSO-SVM 供应链金融的信用风险预警模型的效果,本文将其与目前所建立的主流预警模型进行对比分析,包括:决策树(CART)、逻辑回归(LR)、邻近算法(KNN)、BP神经网络(BP)、朴素贝叶斯(NB)与支持向量机(SVM),其中各模型均采用交叉验证法计算预测准确率。同时,为分析各模型的稳定性,本文利用前文所述的模型稳定性测试方法来检测各模型的稳定性。测试结果分别如表 11 和表 12 所示。

表 11 模型结果测试表

模型	训练集			测试集		
	正确数	误判数	准确率(%)	正确数	误判数	准确率(%)
PSO-SVM	105	9	92.11	26	1	96.3
SVM	103	11	90.35	24	3	88.9
CART	100	14	87.7	24	3	88.9
LR	103	11	90.35	25	2	92.6
KNN	103	11	90.35	25	2	92.6
BP	102	12	89.47	25	2	92.6
NB	98	16	85.96	24	3	88.9

资料来源:Matlab 计算,本文整理

表 12 模型稳定性结果测试表

模型	训练集			测试集		
	正确数	误判数	准确率(%)	正确数	误判数	准确率(%)
PSO-SVM	82	5	94.25	50	4	92.6
SVM	80	7	91.95	44	10	81.48
CART	80	7	91.95	46	8	85.19
LR	82	5	94.25	42	12	77.78
KNN	80	7	91.95	45	9	83.3
BP	81	6	93.1	39	15	72.22
NB	80	7	91.95	44	10	81.48

资料来源:Matlab 计算,本文整理

通过表 11 和表 12 的实证结果可发现:

(1)在模型预测方面。目前主流的预警模型中,除决策树与朴素贝叶斯模型预测结果不够准确外,各模型针对训练集与测试集样本的预测准确率相差不大。并从表 11 中可以看出 PSO-SVM 模型无论是对训练集还是测试集样本的预测准确率都高于目前的主流预警模型。

(2)在模型稳定性方面。从表 12 可以看出,当训练集样本减少后各模型的预测准确率都有所提高,且准确率均在 90% 以上。但是各模型针对测试集样本的预测准确率方面表现出较大的差异性,相比之下回归模型与 BP 神经网络的预测准确率最低,说明回归模型与 BP 神经网络模型稳定性较差,支持向量机、决策树、邻近算法以及朴素贝叶斯模型预测的准确率均 80% 以上,说明机器学习类模型的稳定性较好。

(3)结合表 11 和表 12 可以看出 PSO-SVM 模型不论是模型结果预测或模型稳定性方面都优于目前主流预警模型,达到了很好的预测效果。

为更直观地比较机器学习类模型的性能差异,选择表 12 中测试集样本准确率在 80% 以上的模型绘制 ROC 曲线以评价各模型的性能。ROC 曲线是以不同违约临界点作为阈值,从而计算曲线下方的 AUC 值来评价模型性能,其中 AUC 值分为四个区间来解释模型性能,当 AUC 值在 0 ~ 0.5 之间表示无效模型,当 AUC 值在 0.5 ~ 0.7 之间时表示模型具有一定的解释效果,当 AUC 值在 0.7 ~ 0.9 之间时表示模型性能较好,AUC 值在 0.9 以上时表示模型性能极好。图 7 展示了表 15 中测试集样本预测准确率在 80% 以上的模型 ROC 曲线。

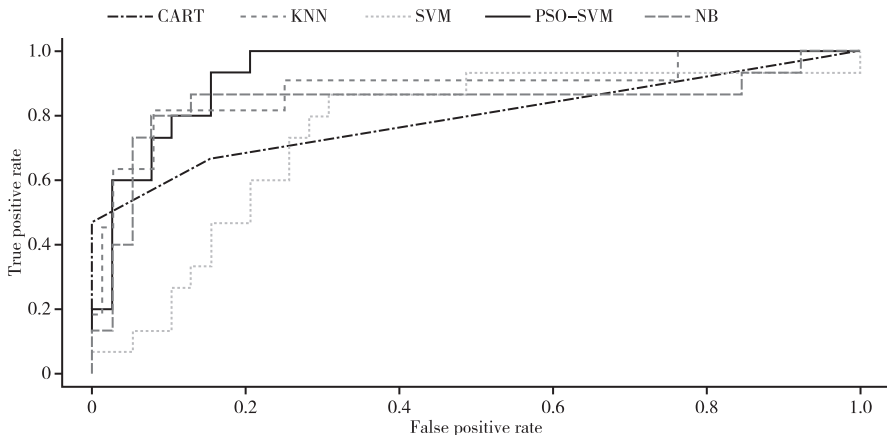


图6 模型稳定性 ROC 曲线图

资料来源:R 语言绘制

从图6中可以明显看出 PSO-SVM(黑色线)模型效果明显优于其他主流模型。同时,各模型的 AUC 值分别为:支持向量机模型为 0.65、决策树模型为 0.72、贝叶斯模型为 0.84、邻近算法模型为 0.85、PSO-SVM 模型为 0.92,说明支持向量机与决策树模型针对供应链金融的信用风险预警能够起到一定的效果,相比之下,贝叶斯模型与邻近算法模型的预警效果较好。通过 AUC 值可知,本文建立的 PSO-SVM 预警模型针对供应链金融的信用风险预警能够起到极好的效果,PSO-SVM 预警模型的性能明显优于其他主流预警模型。

七、结论和建议

本文依据随机森林模型与盲数理论进行变量筛选,运用 Logistic 模型对供应链金融的信用风险关键影响因素进行识别,并以此为基础构建 PSO-SVM 供应链金融的信用风险预警模型。通过研究本文得到如下结论:

(1)本研究将供应链金融的信用风险影响因素指标分为四大类共 40 个变量来识别,变量选取较为全面。根据随机森林与盲数理论的变量筛选结果,运用 Logistic 模型识别供应链金融的信用风险关键影响因素,主要包括:企业成立年限、销售净利率、流动资产周转率、供应链的强度与久度、核心企业资产负债率以及核心企业违约情况,这些指标对供应链金融的信用风险有显著性影响。其中,销售净利率、流动资产周转率以及供应链的强度与久度对融资企业的违约概率呈现出负相关,企业成立年限、核心企业资产负债率与核心企业违约情况对融资企业的违约概率呈现出正相关。

(2)本研究依据 Logistic 回归结果构建了 PSO-SVM 供应链金融的信用风险预警模型,此模型在结果预测以及稳定性方面表现出具有较强的优越性。此外,通过将 PSO-SVM 预警模型与目前研究文献中所建立的主流预警模型进行对比,发现本文所构建的 PSO-SVM 预警模型在结果预测以及稳定性检测时都优于其他主流预警模型,因此 PSO-SVM 预警模型具有较好的外推性。

与此同时,基于本文的研究结论,针对供应链金融的信用风险管理提出以下几点建议:

(1)推进供应链金融信用平台建设。供应链金融作为一种新兴金融业务,正逐步趋向于电子化、大数据化及模型化,因此融入上下游融资企业与核心企业的信用档案,建立一个稳定、权威以及多数据的供应链金融信用平台尤为重要。

(2)提高融资企业经营稳定性。融资企业作为供应链金融的信用风险管理核心,应当加强企业内部治理,提升企业的盈利能力及营运能力,合理规划短期与长期负债,以提升融资企业还款能力。

(3)及时掌握核心企业经营信息及供应链运营情况。核心企业及供应链运营对供应链金融中

的信用风险管理起到关键作用。作为融资机构应深入了解供应链中核心企业经营状况,全面掌握供应链运营情况,运用相关理论及模型,进行大数据化的管理,降低信用风险。

参考文献

- [1] Hofmann, E. Supply Chain Finance: Some Conceptual Insights[J]. Logistics Management, 2005, (1) :203 - 214.
- [2] Guillen, G., Badell, M., et al. A Holistic Framework for Short-Term Supply Chain Management Integrating Production and Corporate Financial Planning[J]. International Journal of Production Economics, 2007, 106, (1) :288 - 306.
- [3] Gomm, M. L. Supply Chain Finance: Applying Finance Theory to Supply Chain Management to Enhance Finance in Supply Chains [J]. International Journal of Logistics, 2010, 13, (2) :133 - 142.
- [4] Gelsomino, L. M., Mangiaracina R. Supply Chain Finance: A Literature Review[J]. International Journal of Physical Distribution & Logistics Management, 2016, 46, (4) :348 - 366.
- [5] Wuttke, D. A., Blome, C., et al. Managing the Innovation Adoption of Supply Chain Finance-Empirical Evidence from Six European Case Studies[J]. Journal of Business Logistics, 2013, 34, (2) :148 - 166.
- [6] Wandfluh, M., Hofmann, E., et al. Financing Buyer-Supplier Dyads: An Empirical Analysis on Financial Collaboration in the Supply Chain[J]. International Journal of Logistics Research and Applications, 2016, 19, (3) :200 - 217.
- [7] Atkinson, W. Supply Chain Finance: The Next Big Opportunity[J]. Supply Chain Management Review, 2008, (4) :14 - 17.
- [8] Gobbi, G., Sette, E. Do Firms Benefit from Concentrating Their Borrowing? Evidence from the Great Recession [J]. Review of Finance, 2014, 18, (2) :527 - 560.
- [9] Jing, B., Seidmann, A., et al. Finance Sourcing in A Supply Chain[J]. Decision Support Systems, 2014, 58, (4) :15 - 20.
- [10] Caniato, F., Gelsomino, L. M. Does Finance Solve the Supply Chain Financing Problem? [J]. Supply Chain Management, 2016, 21, (5) :534 - 549.
- [11] Hu, C. Y., Ansell, J. Measuring Retail Company Performance Using Credit Scoring Techniques [J]. European Journal of Operational Research, 2007, 183, (3) :1595 - 1606.
- [12] 黄静思, 宋河, 宋新红. 供应链金融贷款风险识别与评价方法研究[J]. 郑州: 金融理论与实践, 2014, (2) :46 - 49.
- [13] Su, Y. L., Lu, N. Supply Chain Finance Credit Risk Evaluation Method Based on Self-Adaption Weight[J]. Journal of Computer & Communications, 2017, 5, (6) :1355 - 1369.
- [14] 范方志, 苏国强, 王晓彦. 供应链金融模式下中小企业信用风险评价及其风险管理研究[J]. 北京: 中央财经大学学报, 2017, (12) :34 - 43.
- [15] 顾治程, 蒋艳. 基于供应链金融的汽车行业上市公司信用风险实证研究[J]. 哈尔滨: 物流科技, 2017, (2) :136 - 141.
- [16] Hamadi, M., Abdelmoula, K. Credit-Risk Evaluation of A Tunisian Commercial Bank: Logistic Regression VS Neural Network Modeling [J]. Accounting & Management Information Systems, 2010, 9, (1) :92 - 119.
- [17] 胡海青, 张琅, 张道宏. 供应链金融视角下的中小企业信用风险评估研究——基于 SVM 与 BP 神经网络的比较研究[J]. 北京: 管理评论, 2012, (11) :70 - 80.
- [18] 叶晓枫, 鲁亚会. 基于随机森林融合朴素贝叶斯的信用评估模型[J]. 北京: 数学的实践与认识, 2017, (2) :68 - 73.
- [19] 蒋曼曼. 供应链金融视角下企业信用风险评价研究[J]. 石家庄: 经济与管理, 2017, (2) :140 - 142.
- [20] 戴昕琦. 商业银行信用风险评估模型研究——基于线上供应链金融的实证[J]. 成都: 软科学, 2018, (5) :139 - 144.
- [21] Walton, S., Gupta, N. D. J. Electronic Data Interchange for Process Change in An Integrated Supply Chain[J]. International Journal of Operations & Production Management, 1999, 19, (4) :372 - 388.
- [22] Chih, Y. T. On Supply Chain Cash Flows Risk [J]. Decision Support Systems, 2008, 44, (4) :1031 - 1042.
- [23] Demica. Supply Chain Finance: A Third Report form Demica[R]. London, UK, 2009.
- [24] Dyckman, B. Supply Chain Finance: Risk Mitigation and Revenue Growth[J]. Journal of Corporate Treasury Management, 2011, 4, (2) :168 - 173.
- [25] Martin, J. Suppliers Participation in Supply Chain Finance Practices: Predictors and Outcomes [J]. International Journal of Integrated Supply Management, 2017, (11) :193 - 217.
- [26] 储雪俭, 高博. 区块链驱动下的供应链金融创新研究[J]. 济南: 金融发展研究, 2018, (8) :68 - 71.
- [27] 宋远方, 黄千员. 国内供应链金融研究进展——基于 2005—2017 年 CSSCI 文献分析[J]. 北京: 中国流通经济, 2018, (1) :47 - 54.
- [28] 李杰, 马士豪, 靳孟宇, Chao-hsien Chu. 基于 SA—SVM 的众筹违约风险预警模型[J]. 西安: 统计与信息论坛, 2018, (11) :70 - 77.

Research on Credit Risk Identification and Warning Model of Supply Chain Finance

LI Jian,ZHANG Jin-lin

(School of Finance,Zhongnan University of Economics and Law,Wuhan,Hubei,430073,China)

Abstract: As a new form of financial business, supply chain finance has played an active role in solving upstream and downstream corporate financing and coordinating supply chain management. As the problem of information asymmetry will lead to the credit risk of the financing enterprise, and through the transmission of the supply chain, it will be transmitted to the entire supply chain, which will lead to systemic risks. Therefore, it is of practical significance to deeply explore the key factors affecting the credit risk of financing enterprises, to construct an effective early warning model, and to reduce the probability of credit default events in financing enterprises, so as to promote the stable development of supply chain finance.

Although domestic and foreign scholars have carried out various researches on the credit risk influencing factors and early warning models of supply chain finance, there are still some shortcomings: First, most studies are based on traditional credit business, and do not consider supply chain finance. The characteristics of the related variables are not comprehensive, which affects the overall analysis. Secondly, from the screening of variables in the existing literature, the corresponding screening methods cannot be selected according to the characteristics of the variables, which in turn affects the analysis results. The third is for the early warning model. The construction generally stays in the use stage of the model, and does not provide practical and effective model improvement techniques and model stability testing, which in turn cannot reduce the probability of credit risk in supply chain finance. Based on this, this paper will focus on the key factors of “reducing the probability of credit risk in supply chain finance”, analyze the key factors affecting the financial credit risk of supply chain, and construct the PSO-SVM supply chain financial early warning model with key influencing factors as input variables. In order to reduce the probability of credit risk of financing enterprises, help financing enterprises improve their financing capabilities.

In this study, the credit risk influencing factors of supply chain finance are divided into four categories and a total of 40 variables to identify, and the variables are more comprehensive. According to the results of random forest and blind number theory, the Logistic model is used to identify the key influencing factors of credit risk in supply chain finance, including: establishment period, net sales rate, current asset turnover rate, strength and duration of supply chain, The core enterprise asset-liability ratio and core enterprise defaults, these indicators have a significant impact on the credit risk of supply chain finance. Among them, the net profit margin, the current asset turnover rate and the strength and duration of the supply chain are negatively correlated with the default probability of the financing enterprise. The default period of the enterprise, the core enterprise asset-liability ratio and the core enterprise default situation are presented to the financing company. Positive correlation. According to the logistic regression results, the credit risk early warning model of PSO-SVM supply chain finance is constructed. This model has strong superiority in result prediction and stability. In addition, by comparing the PSO-SVM early warning model with the mainstream early warning model established in the current research literature, it is found that the PSO-SVM early warning model constructed in this paper is superior to other mainstream early warning models in both the result prediction and stability detection. The PSO-SVM early warning model has better extrapolation.

At the same time, based on the research conclusions of this paper, the following suggestions are proposed for credit risk management of supply chain finance. As an emerging financial business, supply chain finance is gradually becoming electronic, big data and modeled. Therefore, it integrates the credit files of upstream and downstream financing companies and core enterprises to establish a stable, authoritative and multi-data supply chain financial credit. The platform is especially important. At the same time, improve the data processing capability of the supply chain credit information system and integrate the multi-industry supply chain and supply chain operation data to improve the credit risk identification capability of supply chain finance.

Key Words: supply chain finance; credit risk triggering mechanism; key influencing factors; warning model

JEL Classification: C19, G21, G32

DOI:10.19616/j.cnki.bmj.2019.08.011

(责任编辑:张任之)