

基于模糊神经网络的小微企业信用评级研究^①

肖斌卿¹, 杨 旻^{2*}, 李心丹¹, 李昊骅¹

(1. 南京大学工程管理学院, 南京 210093; 2. 南京大学商学院, 南京 210093)

摘要: 当前小微企业贷款需求日益增加, 建立行之有效的小微企业信用评级模型已成为学术界和实务界关注的焦点. 本文在阐述模型和构建指标体系的基础上, 提出基于模糊神经网络开展小微企业信用评级的研究步骤, 以某农村商业银行小微企业信贷微观数据为实证样本, 分别进行小型企业和微型企业信用评级检测. 实证结果表明, 模糊神经网络模型在小微企业信用评级研究中具有较BP神经网络模型更高的检测精度. 模型能够实现评级主观性与客观性结合, 可对数据进行定性调节和批量处理, 且具有明确的计算过程和决策规则, 故适用于信用评级研究且具有稳健性.

关键词: 模糊理论; 神经网络; 小微企业; 信用评级

中图分类号: F832.59 **文献标识码:** A **文章编号:** 1007-9807(2016)11-0114-13

0 引言

我国经济结构和产业结构当前正处于深度调整和优化阶段, 经济向内生增长转变要求更多的人力资本和技术创新参与社会分工, 并最终转化为增长产出, 这促使种类多、覆盖广的小微企业在国家经济结构调整升级的过程中扮演更重要角色. 小微企业的经营发展和技术创新离不开资金的支持, 特别是在当前信贷资本紧缩投放的时期, 小微企业的融资困难的问题日益凸显, 一方面, 小微企业受其经营时间、经营业绩、公司治理等因素的制约, 普遍不能提供类似大型企业财务报表的详细业务信息、财务信息以及融资担保证明; 另一方面, 商业银行在开展小微企业贷款业务时, 对其的资信审查愈加趋于严格, 自身财务信息不完备、缺乏抵质押品的小微企业普遍难以从银行获得贷款融资, 并且此类问题还将长期存在. 因此, 如何构建一套行之有效的小微企业信用评级模型, 帮助解决小微企业融资难的问题, 正成为亟待解决

的难题^[1].

商业银行开展小微企业信贷业务时, 首先会对借款企业开展贷前审查工作^[2], 信用评级环节发生在贷前审查流程的前端, 是预测小微企业信贷违约概率的重要一环^[3]. 依实务操作的需要, 国内外学者针对小微企业贷款业务的信贷模式、评级方法以及违约概率估计开展了广泛的研究和讨论, 汇总出丰富的研究成果. 这其中包括: 运用融资理论分析信贷过程中存在的问题, 并提出解决方案; 分析大型企业贷款审批流程为何不能适应小微企业实际贷款业务的原因; 借鉴新巴塞尔协议提出的内部评级法, 以及国外小额信贷业务信用风险管理经验; 探究参数统计和非参数统计这两种类型的信用评级方法, 并将其运用于小微企业信用评级研究中; 分析和讨论以人工神经网络为代表的机器学习方法应用于企业信用评级建模中的有效性和稳健性等.

随着建模方法研究的不断深入, 理论界发现

^① 收稿日期: 2016-09-14; 修订日期: 2016-09-21.

基金项目: 国家自然科学基金资助重点项目(70932003); 国家自然科学基金资助项目(71271109; 71201074; 70901037; 71271110); 教育部科技创新工程重大项目培育资金资助项目(708044); 教育部人文社会科学资助青年项目(13YJC790174).

通讯作者: 杨 旻(1990), 男, 江苏南京人, 博士生. Email: yangyang68nj@163.com

传统神经网络中的一些问题需要被改进,如 BP 神经网络具有初始权重随机、过度拟合、易陷入局部极小值等问题,于是针对传统神经网络的优化研究得到广泛开展。例如运用遗传算法优化 BP 神经网络初始权值,运用模糊理论对输入变量数据进行模糊处理等。在此过程中,模糊理论与神经网络理论相结合得到学界越来越多的认可。原因在于:1) 模糊逻辑的推理形式是启发式搜索,推理速度较慢,而神经网络是并行计算,推理速度较快;2) 模糊推理规则是可见的,而神经网络是黑箱式;3) 模糊逻辑在自适应方面表现较低的容错能力,而神经网络通过不断调整权值的方法进行学习,容错性非常高;4) 模糊系统在推理过程中会增加模糊性,而神经网络能够通过联想记忆降低模糊性。两者的优缺点呈现出明显的互补状态,使得模糊理论和神经网络相结合成为一种可能。

基于此,本文采用模糊神经网络模型开展小微企业信用评级研究,在阐述模型和构建指标体系的基础上,以江苏省某农村商业银行 2013 年贷款台账中的小微企业为样本开展实证研究,结果显示,相比于 BP 神经网络,模糊神经网络具有更加确定的建模过程和具有更好的检测效果,适用于小微企业信用评级建模。本文对小微企业信用评级模型研究的贡献在于 3 个方面:1) 在保证评级主观性与客观性结合方面,通过模糊化处理数据来体现人脑对数据分类的思维,基于模糊子集分割反映长期积累的专家经验和判断,延续使用神经网络以充分反映数据及其变化的客观性;2) 在对数据进行批量处理和定性调节方面,模糊神经网络模型既能够处理定量数据和批量处理数据,又能够通过隶属度函数和模糊子集划分处理定性数据和对数据的定性分类进行调节;3) 在建模过程与结果解释的方面,模糊神经网络模型既能够呈现明确的分析流程和计算过程,又能够通过输出训练后的模糊规则对分析出的结果进行逐条解释和说明。本研究为商业银行提供开展信用评级、规避信用风险的工具,以期提高其信息搜寻和信息处理能力,降低因大量贷款违约而造成的商业银行经营损失,并为缓解金融机构与小微企业信息不对称问题提供决策依据。

1 文献回顾

1.1 影响小微企业信用评级的因素

相比于金融机构对大中型企业信贷评级研究的投入,小微企业信贷信用评分模型的发展只取得了小幅进展^[4]。学者们主要从两个方面展开研究,一是小微企业信用评级的影响因子;二是小微企业信用评价方法。小微企业融资存在困难主要源于以下几个因素:小微企业自身的经营风险、财务信息不完整、企业信用担保制度不健全以及银行惜贷现象较为严重。在贷款实施过程中,企业对资金的利用不按照贷款合同中的要求,或投资获利后不按时偿还本息,由此引发道德风险并带来不利影响^[5]。信息不对称问题对商业银行贷款业务的开展带来诸多不确定的因素^[6]。小微企业信贷业务中的信息不对称问题亦影响业务的开展。也正是因为小微企业更加显著的信息不对称,Altman^[7]和 Kim^[8]以及其他众多学者的研究发现,小微企业在与大型企业信贷质量相比时,其信贷质量相对较低。

在对小微企业评价指标的选择上,学者们主要从财务和非财务指标影响加以探讨。李志赞^[9]认为,小微企业的非均质性、贷款抵押和交易成本是三个影响其是否能从商业银行获取贷款的主要因素。庞素琳^[10]在信用风险的识别因子研究中,将贷款金额、利率、有无担保抵押以及与企业主有关的指标作为研究变量。Edmister^[11]在其研究中引入了 19 个财务指标作为小微企业违约判别的研究变量,认为信用评级需考虑的因素包括借款企业经营环境、所有制与经营权、管理水平、营运价值、盈利能力、风险程度等因素。Hajek^[12]对企业信用评级预测中的财务状况、经营状况等建模指标进行了研究。Doumpos^[13]在其研究中构建了一个包含财务数据和结构化模型的信用评级预测系统。同时,现有文献亦强调加入定性指标对研究小微企业信贷业务的重要性^[1]。白重恩^[14]在其研究中提出,私营企业主对财产权的自我保护有利于从商业银行获取贷款。李毅^[15]认为小微企业在融资过程中若能够拥有信用担保,将有益于其获取贷款。Meyer^[16]指出银行可以通过“软信息”对小企业信用状况进行评估,这些软信息

包括银行对借款企业资质的初步判断等。Lusser^[17]在其模型中加入了企业管理水平、所处经济周期、产品生命周期等因素。由此可见,小微企业信用评级指标体系需要涵盖财务性指标、非财务性指标和主观评价指标等。

1.2 小微企业信用评级方法

现有与信用评级相关的研究成果包括:王春峰^[18]在其研究中将判别分析与Logit方法应用于商业银行信用风险评估研究中,对两种方法的有效性进行判别比较,并讨论传统建模工具的优缺点。陈建华^[19]从商业银行风险管理的角度出发,运用《新巴塞尔资本协议》中的内部评级法要求,对商业银行信用风险管理提出改造和完善意见。石晓军^[20]在其研究中开展基于Logistic回归分析的违约概率研究,通过抽样分布性质的研究从理论上说明了为何边界Logistic违约率模型在企业信用评估研究中更优越。彭建刚^[21]在其研究中建立聚合信用风险模型探讨我国商业银行计量非预期损失的方法,并进行了论证。庞素琳^[22]在银行个人信用评级中建立C5.0分类算法,在该算法内嵌入Boosting算法技术,并构造了成本矩阵和参数调整后的决策树。高丽君^[23]基于贝叶斯模型平均生存模型研究了中小企业信用风险估计。迟国泰等^[1]运用Probit回归研究小企业债信用评级模型。Che^[24]运用层次分析法(AHP)和包络分析法(DEA)对台湾地区商业银行小微企业信贷决策进行研究,并得到有效的建模结果。An-gilella^[25]建立了小微企业SMAA-TRI多准则信用评级模型,并对模型有效性进行了验证。

同时,非参数统计的研究方法也逐步应用于信用评级建模。王春峰^[26]在其研究中对人工神经网络在银行信用风险评价中的应用展开对比讨论,结果表明,与传统统计方法相比,神经网络技术具有较高的稳定性和判别准确度。West^[27]认为非参数统计的方法在信用评级的研究中优于经典统计模型。Yu^[28]运用多层神经网络和模糊聚类分析等人工智能方法研究信用评分模型,并对效果良好的建模结果进行叙述。Kim^[29]建立基于多层支持向量机的企业信用评级模型,并与传统评级模型的建模效果进行对比。Zhong^[30]在企业信用评级中,对BP、ELM、I-ELM和SVM的学习训练效果进行对比分析,其中ELM和BP神经网络

的建模效果较优。现有的这些建模方法所研究的对象并没有专门针对我国小微企业。

以往文献将传统神经网络应用于小微企业信用评级的研究仍有不足之处,例如BP神经网络具有初始权值随机、过度拟合、易陷入局部极小值等问题,于是针对传统神经网络的优化研究得到广泛开展。Malhotra^[31]运用模糊神经网络对信用评分较好和较差的企业进行区分。Piramuthu^[32]在对企业信用风险评估时,运用模糊神经推理系统进行对比试验研究,并对模型在信用风险评估中的优点进行阐述,认为基于模糊神经网络的研究方法能够对输入变量进行模糊化处理,并在模糊子集确定、训练步数确定的情况下,建立的评级模型能够给出模型训练的规则。本文通过对国内文献展开分析,发现模糊神经网络在我国信用风险评估研究中有一定运用,吴冲^[33]较早运用模糊神经网络于制造业企业短期贷款风险评估中,张洪祥^[34]研究表明灰色模糊神经网络评价上市公司信用风险具有较高的准确性和稳定性,但以往研究缺乏针对全行业小微企业信贷数据的实证研究。此外,模糊神经网络模型在其他学科领域也有着丰富的应用,例如人力资源风险评估、电力负荷预测、信息安全风险评估等,因此运用该模型开展信用评级研究具有较好的理论基础。

2 模糊神经网络理论

本文将模糊理论与神经网络进行结合,运用模糊神经网络(fuzzy neural network, FNN)模型作为小微企业信用评级研究方法,以下对模糊集合和隶属度原理、模糊推理方法和模糊神经网络结果进行阐述。

2.1 模糊集合和隶属度

模糊概念区别于经典集合的概念,它不同于绝对地用“属于”或者“不属于”某个集合来表示,也即概念的表述不是绝对的0或1,而是介于0和1之间的某个数^[35]。模糊集合的定义是:假定有集合 U , U 在 $[0, 1]$ 上的任意一个映射 $\mu_A: U \rightarrow [0, 1]$,都映射 U 的模糊集合 A ,则 μ_A 是其隶属度函数,若 A 中的元素用 x 表示,则 $\mu_A(x)$ 称为 x 属于 A 的隶属度。

隶属度函数是对模糊概念的定量化处理, 确定出研究中各个输入变量合适的隶属度是运用模糊理论解决现实问题的前提. 高斯型是最主要也最常见的一种隶属度函数分布, 即

$$\mu(x) = e^{-\left(\frac{x-a}{b}\right)^2} \quad b > 0 \quad (1)$$

其中 a 是函数中心, b 是函数宽度.

2.2 模糊推理方法

常用的模糊推理方法包括 Mamdani 型(简称 M 型)推理方法和 Tagagi-Sugeno 型(简称 TS 型)推理方法^[35]. 本文基于 ANFIS 采用的模糊推理方法为 TS 型. TS 型模糊推理具有利于计算、与控制优化和自适应方法容易结合的优点, 能够实现建模过程的自适应和优化处理. TS 型推理的过程是运用一个多项式来替代通常的模糊量以表示推理后件, 其输出是以输出数据的函数, 即 $z = f(x, y)$ 的形式展现. 其形式为

$$\text{若 } x \text{ 是 } A \text{ and } y \text{ 是 } B \text{ 则 } z = f(x, y).$$

其中 A, B 是前提中的模糊集合, $z = f(x, y)$ 是结论. 在推理的过程中, 每一条规则都产生一个精确输出, 集结这些输出后通过加权平均, 进而得到整体系统的输出, 其加权因子是通过各条规则中的模糊集合运算过程产生^[36].

2.3 模糊神经网络及其结构

模糊理论与神经网络各具有优点, 前者是以模糊逻辑为基础, 借鉴了思维过程中的模糊性特点, 从而运用模糊推理来处理一些常规方法难以解决的模糊信息问题; 后者能够在模拟推理、自动学习等方面为模式识别、聚类分析和专家系统的建立提供更多支持. 两者结合具有一定的优势: 模糊技术擅长逻辑推理, 可以对高阶的信息进行处理, 因而将它引入神经网络中可以拓宽神经网络信息处理的能力; 运用神经网络进行模糊信息处理, 可以有助于隶属函数的生成. 定义由 2 个和 2 个以上的模糊神经元相互连接而构成的复杂信息分析系统称为模糊神经网络^[37]. 其一般系统结构包括五层, 分别是输入层、模糊化层、规则层、反模糊化层和输出层. TS 型由前件网络 (L) 和后件网络 (SL) 两部分组成. 模糊神经网络模型结构^[36]如下.

首先, 在前件网络中, L_1 是输入层, 其各个节点直接与各个输入变量 x_i 相连接, 作用是将输入值 $x = [x_1, x_2, \dots, x_n]^T$ 传递到下一层节点, 该层的节

点总数 $N_1 = n$. L_2 中用节点表示语言变量, 作用是计算各变量的隶属度函数 μ_j^i

$$\mu_j^i = \mu_{A_j}(x_i) \quad (2)$$

其中 $i = 1, 2, 3, \dots, n; j = 1, 2, 3, \dots, m_j$. n 是输入量的个数, m_j 是 x_i 的模糊子集数. 该层的节点总数 $N_2 = \sum_{i=1}^n m_i$.

L_3 中节点代表模糊规则, 用于与模糊规则的前件进行匹配, 并且对每条规则的适用度进行计算, 即

$$\alpha_j = \min\{\mu_{i_1}^{j_1}, \mu_{i_2}^{j_2}, \dots, \mu_{i_n}^{j_n}\} \quad (3)$$

其中 $i_1 \in \{1, 2, \dots, m_1\}; i_2 \in \{1, 2, \dots, m_2\}; \dots; i_n \in \{1, 2, \dots, m_n\}; j = 1, 2, \dots, m; m = \prod_{i=1}^n m_i$. 该层节点的总数 $N_3 = m$. L_4 的节点数与第三层相等, 该层实现归一化, 即

$$\bar{\alpha}_j = \frac{\alpha_j}{\sum_{i=1}^m \alpha_i}, \quad j = 1, 2, \dots, m \quad (4)$$

其次, 后件网络由 r 个并列子网络组成, 各层子网络用 $SL_1 - SL_3$ 表示. 每个子网络生成一个输出量, 其系统结构为: SL_1 是输入层, 并传递到第二层. 输入层中节点输入值的作用是提供模糊规则的后件. SL_2 包含 m 个节点, 每个节点表示一条规则, 实现计算每条规则的后件, 即

$$y_{ij} = p_{j_0}^i + p_{j_1}^i x_1 + \dots + p_{j_n}^i x_n = \sum_{l=0}^n p_{j_l}^i x_l \times (j = 1, 2, \dots, m; i = 1, 2, \dots, r)$$

SL_3 对输出量进行计算, 即

$$y_i = \sum_{j=1}^m \bar{\alpha}_j y_{ij} \quad (5)$$

由上可知, y_i 是各条规则的加权之和, 加权系数既是前件的输出量, 又是后件 SL_3 的连接权值. 根据上述结构, 本研究在将 n 个输入变量导入模型输入层后, 经过模型运算将输出值收敛至稳定状态, 即得到本模型对于小微企业信用等级的评定结论.

3 实证分析

3.1 指标与样本

指标选取既要考虑指标内涵的完整性, 又需

要适合所采用的建模方法。首先,国内商业银行各自都有符合自身经营需要的信用风险评级指标体系,其中的指标包含定性和定量两类指标。其次,本文所采用的模糊神经网络在样本处理和训练次数方面要求参与建模的指标能够反映指标体系内容中典型的内涵并且数量精简,一方面对每个指标进行模糊子集分割后,增加了训练的规则;另一方面,较多的规则将极大增加训练时间,因此需确定适当的研究指标和指标数量。故基于以上分析,在江苏省某农商行 2013 年贷款台账,即该银行信贷业务 2013 年历史数据的基础上,通过

Delphi 专家决策,对拟用于建模的信贷评级指标进行筛选和分析,从 19 个待用于建模的信贷评级指标中筛选出 7 个指标作为输出变量,在输入变量中,有 4 个变量属于定性变量,分别是 A3 贷款方式、A4 控股性质、A5 行业门类和 A6 客户资信等级,故在模型建立前对定性变量进行虚拟变量赋值;输出指标 B1 设为贷款二级分类,即将贷款台账样本分为良性贷款和不良贷款,其中良性贷款代表正常和关注这两类贷款,不良贷款代表次级、可疑和损失这三类贷款,如表 1 所示。

表 1 模型的输入变量和输出变量

Table 1 Input and output variables of the model

编号	变量名称	变量解释	所属范畴
A1	发放金额	指银行向借款人发放的金额	贷款基本信息
A2	年利率	指该笔贷款的年化利率	贷款基本信息
A3	贷款方式	贷款方式包含个人信用、自然人担保、企业联保、融资平台互保、担保公司保证、抵押、质押、银行承兑汇票	贷款基本信息
A4	控股性质	指借款人控股主体性质,包含国有绝/相对控股、集体绝/相对控股、港澳台绝/相对控股商、外商绝/相对控股、私人绝/相对控股	企业经营信息
A5	行业门类	指借款人所处的行业分类,包含农林牧渔、能源供应、制造与零售、交通运输、信息服务、地产金融、餐饮文娱、科教卫生及其他	企业所属门类
A6	客户资信状况调查结果	指客户经理对借款企业当前经济效益、履约能力和商业信誉等要素的判断,包含优秀、较好、一般、不佳、恶化、关停	企业资信状况
A7	人均资产总额	指公司总资产与总员工数之比	企业财务信息
B1	贷款二级分类	指模型输出结果,包括良性贷款和不良贷款	企业信用评级

研究数据来源于江苏省某农商行 2013 年企业贷款台账历史数据库。在参考 2007 年中国银监会发布小企业授信被界定标准基础上,本文同时借鉴江苏省某农村商业银行企业授信条例,确定本文的研究对象分类界定标准,即小企业单户授信 500 万以上和 3 000 万以下,微型企业单户授信 500 万以下。本文分别获取小型企业贷款样本数据 1 493 组,微型企业贷款样本数据 1 681 组。样本数据若出现缺失值现象和重复样本现象,对其整组样本数据进行删除,剩余小型企业贷款样本数据 1 264 组,微型企业贷款样本数据 1 323 组。为控制研究建模训练时间,并保证样本数据的典型性,通过分层抽样,采集小型企业贷款样本数据 300 组,采集微型企业贷款数据 300 组,并再次通过分层抽样的方法,采集小型企业训练样本数据 270 组,检测样本 30 组,采集微型企业训

练样本数据 270 组,检测样本 30 组。在训练样本中,良性贷款与不良贷款的比例均设定为 20:1;检测样本中,良性贷款与不良贷款的比例设定为 15:1。

3.2 模型建立

以 MATLAB R2012a 软件为本文建模的载体,并运用其中的模糊逻辑(fuzzy logic)工具箱开展模糊神经网络建模工作。函数 genfis1 可以为训练自适应神经模糊推理系统(adaptive neuro-fuzzy inference system,即 ANFIS)产生 TS 型模糊推理系统(fuzzy inference system,即 FIS)结构中隶属度函数参数的初值。本文的建模操作是运用自适应神经网络模糊推理系统中的图形界面编辑器(ANFIS editor)所开展的,其调用函数为 anfisedit,该编辑器有交互式的图形界面,能够完成模糊神经网络建立、训练和测试等功能。模型训练的基本情况和参数设置如下:模型输入变量为

7 个、输出变量为 1 个,对三个定量变量 A1 发放金额、A2 年利率和 A7 人均资产总额进行归一化处理;隶属度函数采用高斯型,训练误差设为 0.000 1,训练步数设为 20 步. 本节单独讨论小型企业训练样本,样本数量为 270 组,并以该训练样本进行建模仿真的分析说明.

第一步 对各个变量的频数分布进行统计,以对模糊子集的确定有直观的认识. 运用 SPSS 软件对训练样本中各个变量数据进行频度分析,得到定量变量 A1 发放金额、A2 年利率和 A7 人均资产总额的样本频数分布较为分散,其中 A1 和 A7 这两个变量更为明显;定性变量中 A4 控股性质和 A5 行业门类这两个变量的样本频数分布较为分散,因此考虑在参数设置时增加上述变量的模糊子集数. 限于篇幅,各个指标样本频数统计结果介绍从略.

第二步 进行模型训练中模糊子集数的初始设置,首先将 7 个输入变量的模糊子集数依次设为 2、2、2、2、2、2、2,这样方便在后续调整各变量模糊子集数时有原始模型进行参考对比,以确定各个变量较为合适的模糊子集数. 开始训练网络 1. 20 步训练之后,训练误差为 0.061 652,下面逐步调整各个指标的模糊子集数,先对两个分布区间交大的定性指标增大模糊子集数,模糊子集的个数依次设为 3、2、2、2、2、2、3,再次训练,生成网络 2. 训练误差为 0.059 348,比较网络 1 训练误差,本次训练的误差有所下降,说明对两个分布区间较大的定性变量增大模糊子集数,能够取得较优的训练误差. 在此基础上,本文再对分布宽度较大的变量 5 行业门类增大模糊子集数,模糊子集的个数依次设为 3、2、2、2、3、2、3,再次训练,生成网络 3. 训练误差为 0.059 816,比较网络 1 训练误差,本次训练的误差稍微有所增加,说明在对 A5 行业门类变量增大模糊子集数后,训练误差没有出现明显降低. 因此,本文仍将模糊子集的个数依次设为 3、2、2、2、2、2、3. 网络 3 的训练误差曲线如图 1 所示.

第三步 通过观察以上训练误差曲线,发现训练误差曲线没有出现完全收敛,因此本研究继续增加训练步数. 首先,将训练步数增加至 100

步,设定确认后的各变量模糊子集数,再次训练,生成网络 4. 当设定为 100 步训练步数时,训练误差曲线收敛效果明显,进一步观察网络 4 的训练误差曲线,可以发现在 30 步~40 步之间,训练误差曲线实际已经收敛,因此本研究将训练步数确定为 40 步. 各变量模糊子集数不变,再次训练,生成网络 5,本文将该网络作为基于模糊神经网络的小型企业信用评级模型. 网络 5 的训练误差曲线如图 2 所示.

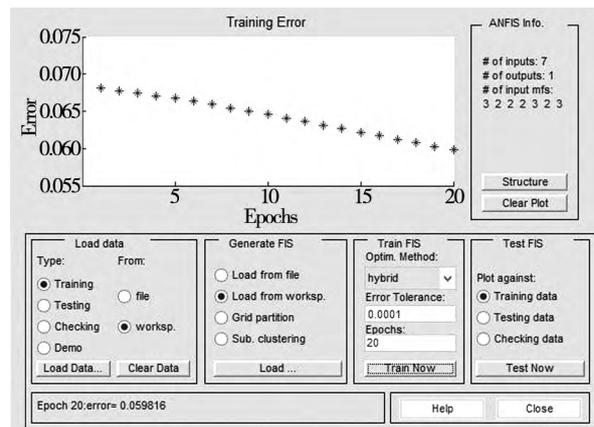


图 1 网络 3 训练误差曲线

Fig. 1 Training error curve of network 3

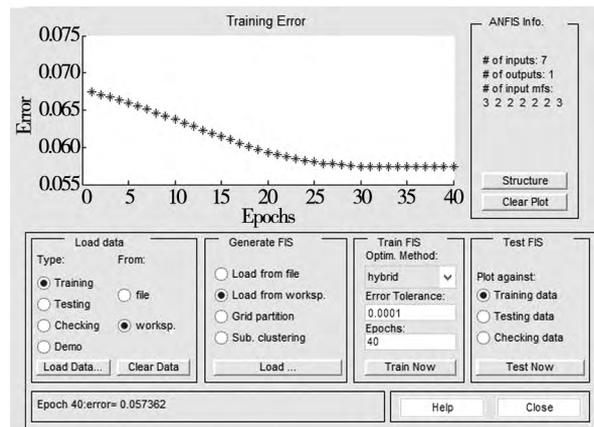


图 2 网络 5 训练误差曲线

Fig. 2 Training error curve of network 5

训练后的模型共产生 $3 \times 2 \times 2 \times 2 \times 2 \times 2 \times 3 = 288$ 条规则,运用自适应神经模糊系统的图形窗口界面的 Edit-Rules 选项功能,进入模糊规则编辑器 (Ruleedit),可以查看该模型的模糊规则. 以第 1 条规则进行规则的举例说明,其内容是 “1. If (input1 is in1mf1) and (input2 is in2mf1) and (input3 is in3mf1) and (input4 is in4mf1) and

(input5 is in5mf1) and (input6 is in6mf1) and (input7 is in7mf1) then (output is out1mf1) (1)”。该规则的前提条件是 if 部分,包含 7 个输入向量的模糊集合 input 后的数字代表着输入变量的编号 in 后面的数字代表着第几个隶属度函数, mf 后面的数字代表着该隶属度函数中的第几个模糊子集. 该规则的结论是 then 部分 (output is out1mf1) 表示输出变量 B1 对应的其隶属度函数中的第 1 个模糊子集.

运用 ANFIS 的图形窗口界面中的选项依次点选 Edit-Membership Function, 进入隶属度函数编辑器(Mfedit), 查看模型训练后的隶属度函数分布情况. 限于篇幅, 以输入变量 A1 的隶属度函数为例, 其原始图像如图 3 所示, 模型训练后的函数发生变化, 其函数图像如图 4 所示.

由图 3 和图 4 可知, 输入变量 A1 的高斯隶属度函数参数值初始值为{0.212 3, 0}, 模型训练完成后, 高斯隶属度函数参数值变为{0.167 1, -0.021 75}, 因该变量数据区分度较大, 参数值发生较为明显的变化. 各变量隶属度函数初始值与训练后变化的参数值如表 2 所示.

表 2 各变量隶属度函数训练前后参数值变化

Table 2 Change of parameter values before and after the membership function training of each variable

输入变量	隶属度参数值(训练前)	隶属度参数值(训练后)
A1	{0.212 3, 0}	{0.167 1, -0.021 75}
A2	{0.424 7, 0}	{0.366 7, 0.035 05}
A3	{2.123, 0}	{2.116, 0.000 421 6}
A4	{2.548, 0}	{2.54, -0.004 975}
A5	{2.973, 0}	{2.973, 0.001 044}
A6	{0.849 3, 0}	{0.808 7, -0.032 78}
A7	{0.212 3, 0}	{0.212 3, -0.000 334 1}

3.3 模型检测

3.3.1 小型企业信用评级检测

运用网络 5 训练后的模型对小型企业信用评级检测样本进行检测, 检测样本包含 30 组样本数据, 其中良性贷款样本 28 组, 不良贷款样本 2 组. 在软件中导入检测样本数据, 并且运用 evalfis 函数进行样本检测, 检测结果如图 5 所示(横坐标代表的是检测样本编号, 纵坐标代表的是输出变量值; 红色星号代表的是检测样本的实际输出, 蓝

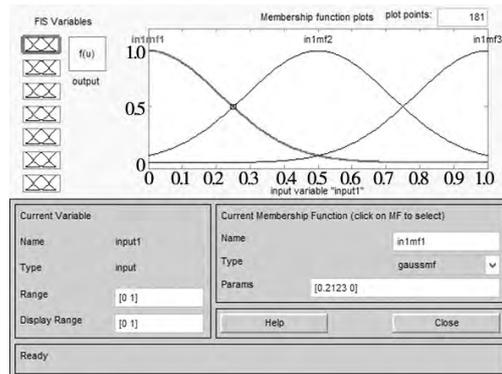


图 3 A1 隶属度函数原始图像

Fig. 3 A1 membership function original image

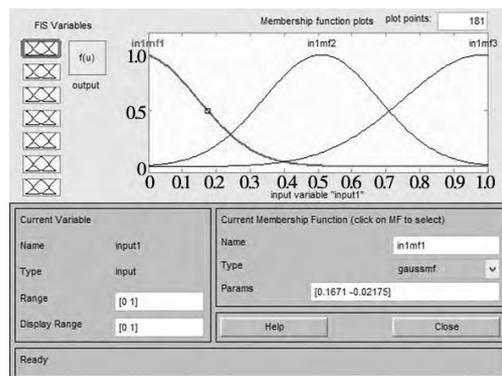


图 4 A1 隶属度函数训练后图像

Fig. 4 A1 membership function image after training

色加号代表的是检测样本的期望输出). 30 组检测样本数据的期望输出与实际输出对比情况如表 3 所示.

表 3 中, 期望输出 1 代表检测样本为不良贷款, 期望输出 0 代表检测样本为良性贷款. 用训练好的模型对检测样本进行检测, 本文对判定条件做规定: 若实际输出大于 0.5, 则认为样本属于不良贷款; 若实际输出小于 0.5, 则认为样本属于良性贷款. 从表 3 中实际输出值来看, 第一组检

测样本实际输出为 1.933 2, 略向上远离预期输出 1, 但根据判定条件, 仍可判定为不良贷款; 第 28 组检测样本实际输出为 -1.184 5, 略向下远离预期输出 0, 但仍可以判定为良性贷款, 其余

29 组样本的实际输出分类均与期望分类相同, 检测正确率为 100.00%, 说明基于模糊神经网络的小企业信用评级模型具有较强的可靠性和有效性。

表 3 小型企业检测样本期望输出与实际输出对比

Table 3 Comparison between expected output and actual output of small business test samples

样本编号	1	2	3	4	5	6	7	8	9	10
期望输出	1	1	0	0	0	0	0	0	0	0
实际输出	1.933	1.154	0.026	-0.004	0.027	0.077	-0.157	0.027	0.077	0.012
样本编号	11	12	13	14	15	16	17	18	19	20
期望输出	0	0	0	0	0	0	0	0	0	0
实际输出	-0.100	0.033	0.033	0.011	-0.004	-0.006	-0.172	-0.286	0.016	0.010
样本编号	21	22	23	24	25	26	27	28	29	30
期望输出	0	0	0	0	0	0	0	0	0	0
实际输出	-0.001	0.002	-0.900	-0.235	-0.143	0.067	-0.017	-1.185	-0.119	-0.138

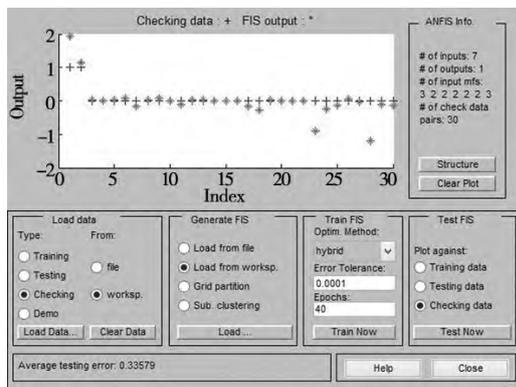


图 5 网络 5 检测结果

Fig. 5 Network 5 detection results

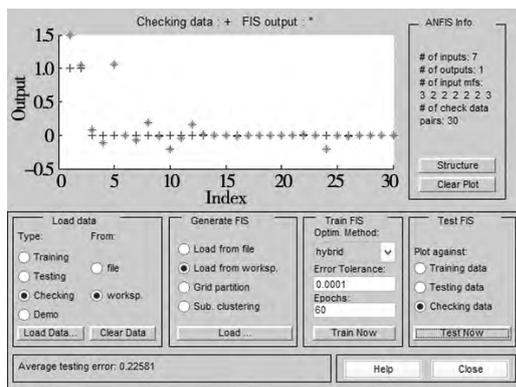


图 6 网络 6 检测结果

Fig. 6 Network 6 detection results

3.3.2 微型企业信用评级检测

运用相同的方法, 建立模糊神经网络微型企业信用评级模型。限于篇幅, 建模和仿真的过程在文中不赘述, 建模参数环境及关键设置的说明如下: 构建 TS 型模糊推理系统, 选择使用高斯型隶属度函数, 7 个输入变量的模糊子集数依次设为 3、2、2、2、2、2、3, 训练样本数据为 270 组, 其中良性贷款样本 259 组, 不良贷款样本 11 组, 训练步数为 60 步, 训练建立网络 6, 建模结果在附录中以图形呈现。检测样本数据为 30 组, 其中良性贷款样本 28 组, 不良贷款样本 2 组, 检测结果如图 6 所示。30 组检测样本数据的期望输出与实际输出对比情况如表 4 所示。

在表 4 中, 第 5 组检测样本实际输出为 1.052 1, 超出规定范围, 因而不能判定为良性贷款, 其余 28 组样本的实际输出分类均与期望分类相同, 检测正确率为 96.67%, 说明本小节建立的微型企业信用评级模型同样具有可靠性和有效性。

表4 微型企业检测样本期望输出与实际输出对比

Table 4 The comparison between the expected output and the actual output of the micro enterprise

样本编号	1	2	3	4	5	6	7	8	9	10
期望输出	1	1	0	0	0	0	0	0	0	0
实际输出	1.497	1.039	0.074	-0.111	1.052	-0.006	-0.067	0.184	-0.023	-0.214
样本编号	11	12	13	14	15	16	17	18	19	20
期望输出	0	0	0	0	0	0	0	0	0	0
实际输出	-0.040	0.161	0.004	0.001	0.001	-0.011	-0.001	0.003	-0.003	0.001
样本编号	21	22	23	24	25	26	27	28	29	30
期望输出	0	0	0	0	0	0	0	0	0	0
实际输出	0.001	0.006	0.001	-0.210	0.000	-0.011	0.000	-0.001	0.003	0.001

3.3.3 与BP神经网络模型对比

将模糊神经网络模型检测效果与运用BP神经网络模型对检测样本检测的效果进行对比. 参数环境和关键设置说明如下: 共7个输入变量和1个输出变量, 隐含层设为6层, 训练步数设为100步, 训练误差设为0.0001, 分别对小型企业和微型企业训练样本进行训练, 分别建立网络7和网络8. 再用训练好的网络7和网络8分别对小型企业和微型企业检测样本进行检测, 检测结果小型企业检测结果如图7所示, 微型企业检测结果如图8所示. 由检测结果可知, 网络7中, BP神经网络检测正确率为93.34%, 其中不良贷款的检测正确率为50.00%; 网络8中, BP神经网络检测正确率为90.00%, 其中不良贷款样本没有被检测出.

定义总体正确率指30组检验样本的检验结果较真实贷款分类结果的正确比率; 第一类错误率指良性贷款错评为不良贷款的比率; 第二类错误率指不良贷款错评为良性贷款的比率; 不良贷款甄别正确率指在不良贷款中, 检验结果较真实不良贷款分类结果的正确比率. ROC曲线面积(AUC值)是常用的用于评价分类模型有效性的方法. ROC曲线是根据一系列不同的二分类方式, 以真阳性率(敏感度, 不良贷款样本被判正确)为纵坐标, 假阳性率(1-特异性, 良性贷款被判错误)为横坐标绘制的曲线. 运用SPSS软件对模型的检验结果绘制ROC曲线, 并比较AUC值, AUC值越大, 表明模型判别水平

越高. 模糊神经网络和BP神经网络对两类样本的检测正确率对比如表5所示. 小企业模糊神经网络与小企业BP的ROC曲线对比如图9所示. 微型模糊神经网络与微型BP的ROC曲线对比如图10所示.

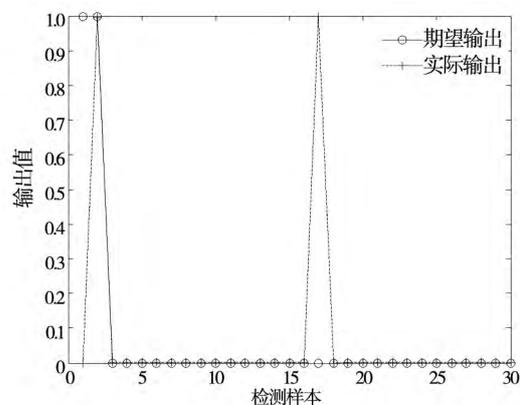


图7 网络7检测结果

Fig. 7 Network 7 detection results

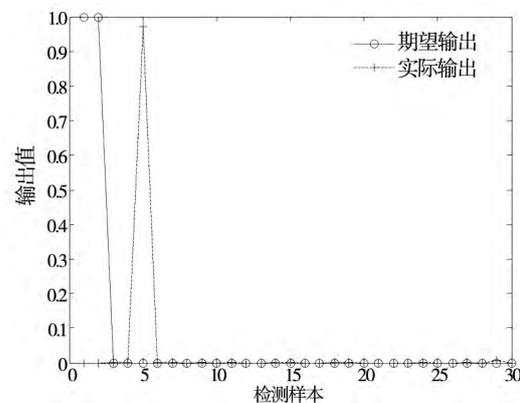


图8 网络8检测结果

Fig. 8 Network 8 detection results

表 5 模糊神经网络和 BP 神经网络的检测正确率对比

Table 5 Comparison of detection accuracy of fuzzy neural network and BP neural network

建模网络	AUC	总体正确率(%)	第一类错误率(%)	第二类错误率(%)	不良检测率(%)
小型 FNN	1.000	100.00	0.00	0.00	100.00
小型 BP	0.732	93.34	3.57	50.00	50.00
微型 FNN	0.982	96.67	3.57	0.00	100.00
微型 BP	0.482	90.00	3.57	100.00	0.00

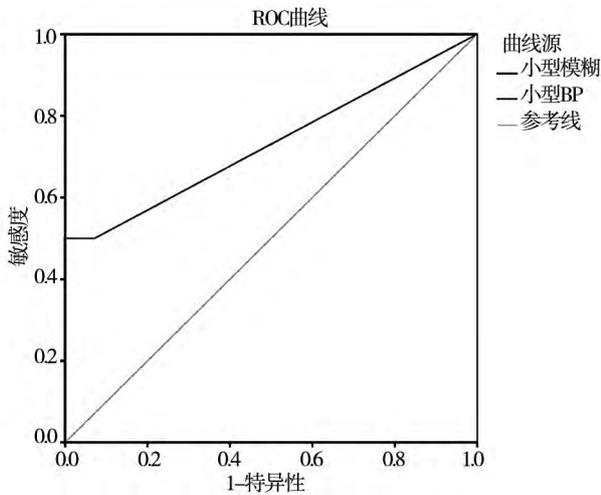


图 9 小型 FNN 与小型 BP 的 ROC 曲线
Fig. 9 ROC curves of small FNN and small BP

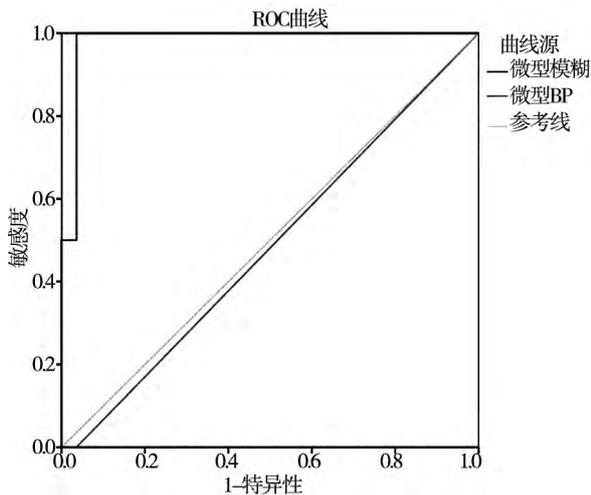


图 10 微型 FNN 与微型 BP 的 ROC 曲线
Fig. 10 ROC curves of micro FNN and micro BP

从表 5 可以看出,1) 运用 BP 网络对样本进行建模后,小型 BP 模型 AUC 值为 0.732,微型 BP 模型 AUC 值为 0.482,分别低于小型 FNN 模型 AUC 值 1.000 和和微型 FNN 模型 AUC 值 0.982; 小型企业和微型企业检测样本的检测的总体正确率也均低于 FNN 的检测正确率;2) 一般认为,第二类错误比第一类错误的违约成本高得多^[4],即

相比于第一类错误,当银行将潜在不良贷款预判为良性贷款时对银行所造成的损失更大. 小型 BP 模型第二类错误率为 50%,微型 BP 模型第二类错误率为 100%,因此 FNN 模型在甄别不良贷款时的较好表现对银行贷前审查的帮助较 BP 模型更大;3) 小型 FNN 不良贷款检测正确率为 100%,微型 FNN 不良贷款检测正确率为 100%,FNN 模型的不良贷款检测正确率均高于 BP 模型的不良贷款检测正确率;4) BP 神经网络生成训练的初始权值具有相当的随机性,训练中易陷入局部极小值,因此其仿真和检测的结果具有很强的不确定性,多次试验也表明,BP 神经网络仿真和检测结果并不一致. 因此可认为,FNN 相比于 BP 神经网络而言,建模过程更加确定,具有更好的检测效果.

4 结束语

本文基于某农村商业银行小微企业信贷微观数据,构建包含财务性指标、非财务性指标和主观评价指标的小微企业信用评级指标体系,运用模糊神经网络模型分别对小型企业和微型企业开展信用评级模型建立与检测. 通过模糊神经网络模型对小型企业和微型企业进行信用评级,以及与 BP 模型的预测结果进行对比后发现,模糊神经网络模型的总体正确率高、第二类错误率低且不良贷款检测正确率高;相比于 BP 神经网络,模糊神经网络具有更加确定的建模过程和具有更好的检测效果,意味着通过模糊理论改进形成的模糊神经网络推理系统能够有效运用于小微企业的信用评级模型构建. 模型能够实现评级主观性与客观性结合,可对数据进行定性调节和批量处理,且具有明确的计算过程和决策规则,适用于信用评级

研究且具有稳健性。

面对与日俱增和多源异构的小微企业信用评价关联数据,商业银行急需借助机器学习技术对传统小微企业信用评级方法进行改进,并在有效整合小微企业信用评价各类资料基础上,实现对数据的分布信息存储、大规模并行处理、自学习、自组织和自适应,解决评级过程中存在的数据非正态分布、样本集大和非线性等问题。此外,考虑到商业银行面对的小微企业数量众多,数据结构化程度低,信息的整理、安排、分析相对

复杂,运用机器学习方法还有助于提高商业银行信息搜寻和信息处理能力,降低运营成本,对于解决金融机构与小微企业严重的信息不对称问题有重要的意义。因此,进一步深化神经网络在小微企业信用评级模型中的运用研究还有巨大空间值得探索。结合本文所采用的评级方法和建模效果,建议实务界运用模糊神经网络作为小微企业信用评级模型开发的一部分,建议理论界深入探索机器学习在信用评级研究中的应用。

参考文献:

- [1]迟国泰,张亚京,石宝峰. 基于 Probit 回归的小企业债信评级模型及实证[J]. 管理科学学报,2016,19(6): 136 - 156.
Chi Guotai, Zhang Yajing, Shi Baofeng. The debt rating for small enterprises based on probit regression[J]. Journal of Management Sciences in China, 2016, 19(6): 136 - 156. (in Chinese)
- [2]Altman E I, Gabriele S. Modelling credit risk for SMEs: Evidence from the US market[J]. Abacus, 2007, 43(3): 332 - 357.
- [3]Altman E I, Gabriele S, Nicholas W. The value of qualitative information in SME risk management[J]. Journal of Financial Services Research, 2008, 40(2): 15 - 55.
- [4]Blanco A, Rafael P, Juan L, et al. Credit scoring models for the microfinance industry using neural networks: Evidence from Peru[J]. Expert Systems with Applications, 2013, (40): 356 - 364.
- [5]屈文洲,谢雅璐,叶玉妹. 信息不对称、融资约束与投资—现金流敏感性: 基于市场微观结构理论的实证研究[J]. 经济研究, 2011, 6: 105 - 117.
Qü Wenzhou, Xie Yalu, Ye Yumei. Information asymmetry and investment-cash flow sensitivity: An empirical research based on market microstructure theory[J]. Economic Research Journal, 2011, 6: 105 - 117. (in Chinese)
- [6]Stiglitz J E, Weiss A. Credit rationing in markets with imperfect information[J]. The American Economic Review, 1981: 393 - 410.
- [7]Altman E, Andrea R, Andrea S. Default recovery rates in credit risk modelling: A review of the literature and empirical evidence[J]. Economic Notes, 2004, 33(2): 183 - 208.
- [8]Kim H S, Sohn S Y. Support vector machines for default prediction of SMEs based on technology credit[J]. European Journal of Operational Research, 2010, 201(3): 838 - 846.
- [9]李志赟. 银行结构与小微企业融资[J]. 经济研究, 2002, 6: 38 - 45, 94.
Li Zhiye. Banking structure and the small-medium-sized enterprise financing[J]. Economic Research Journal, 2002, 6: 38 - 45, 94. (in Chinese)
- [10]庞素琳. 基于贷款风险损失比的农户信贷模型与应用[J]. 管理科学学报, 2012, 15(11): 11 - 22.
Pang Sulin. Farmer credit loan decision model and application based on bank credit risk losing ratio[J]. Journal of Management Sciences in China, 2012, 15(11): 11 - 22. (in Chinese)
- [11]Edmister R. An empirical test of financial ratio analysis for small business failure prediction[J]. Journal of Financial and Quantitative Analysis, Vol. 2, 1972: 1477 - 1493.
- [12]Hajek P, Michalak K. Feature selection in corporate credit rating prediction[J]. Knowledge-Based Systems, 2013, 51: 72 - 84.

- [13] Doumplos M, Niklis D, Zopounidis C, et al. Combining accounting data and a structural model for predicting credit ratings: Empirical evidence from European listed firms [J]. *Journal of Banking & Finance*, 2015, 50: 599–607.
- [14] 白重恩, 路江涌, 陶志刚. 中国私营企业银行贷款的经验研究 [J]. *经济学(季刊)*, 2005, 2: 605–622.
Bai Chongen, Lu Jiangyong, Tao Zhigang. An empirical study on the access to bank loans by private enterprises in China [J]. *China Economic Quarterly*, 2005, 2: 605–622. (in Chinese)
- [15] 李毅, 向党. 中小企业信贷融资信用担保缺失研究 [J]. *金融研究*, 2008, 12: 179–192.
Li Yi, Xiang Dang. Research on credit guarantee of small and medium sized enterprises credit financing [J]. *Journal of Financial Research*, 2008, 12: 179–192. (in Chinese)
- [16] Meyer L H. The present and future roles of banks in small business finance [J]. *Journal of Banking & Finance*, 1998, 22(6–8): 1109–1116.
- [17] Lussier R N. A cross-national prediction model for business success [J]. *Journal of Small Business Management*, 2001, 3: 228–239.
- [18] 王春峰, 万海晖, 张维. 商业银行信用风险评估及其实证研究 [J]. *管理科学学报*, 1998, 1(1): 70–74.
Wang Chunfeng, Wan Haihui, Zhang Wei. Credit risk assessment in commercial banks and its test [J]. *Journal of Management Sciences in China*, 1998, 1(1): 70–74. (in Chinese)
- [19] 陈建华, 唐立波. 浅析我国银行内部评级体系的建立 [J]. *金融研究*, 2002, 9: 88–93.
Chen Jianhua, Tang Libo. Analysis on the establishment of internal rating system in China [J]. *Journal of Financial Research*, 2002, 9: 88–93. (in Chinese)
- [20] 石晓军, 任若恩, 肖远文. 边界 Logistic 违约率模型及实证研究 [J]. *管理科学学报*, 2007, 10(3): 44–51.
Shi Xiaojun, Ren Ruoen, Xiao Yuanwen. Bounded logistic default risk model and empirical evidences from China [J]. *Journal of Management Sciences in China*, 2007, 10(3): 44–51. (in Chinese)
- [21] 彭建刚, 张丽寒, 刘波, 等. 聚合信用风险模型在我国商业银行应用的方法论探讨 [J]. *金融研究*, 2008, 8: 72–85.
Peng Jiangan, Zhang Lihan, Liu Bo, et al. A methodology for the application of aggregate credit risk model in commercial banks in China [J]. *Journal of Financial Research*, 2008, 8: 72–85. (in Chinese)
- [22] 庞素琳, 巩吉璋. C5.0 分类算法及在银行个人信用评级中的应用 [J]. *系统工程理论与实践*, 2009, 12: 94–104.
Pang Sulin, Gong Jizhang. C5.0 classification algorithm and its application on individual credit score for banks [J]. *Systems Engineering: Theory & Practice*, 2009, 12: 94–104. (in Chinese)
- [23] 高丽君. 基于贝叶斯模型平均生存模型的中小企业信用风险估计 [J]. *中国管理科学*, 2012, S1: 327–331.
Gao Lijun. The estimation of credit risk of SMEs based on Bayesian model averaging survival model [J]. *Chinese Journal of Management Science*, 2012, S1: 327–331. (in Chinese)
- [24] Che Z H, Wang H S, Chuang C L. A fuzzy AHP and DEA approach for making bank loan decisions for small and medium enterprises in Taiwan [J]. *Expert Systems with Applications*, 2010, 37(10): 7189–7199.
- [25] Angilella S, Mazzù S. The financing of innovative SMEs: A multicriteria credit rating model [J]. *Quantitative Finance*, 2014, 244(2): 540–554.
- [26] 王春峰, 万海晖, 张维. 基于神经网络技术的商业银行信用风险评估 [J]. *系统工程理论与实践*, 1999, 9: 24–32.
Wang Chunfeng, Wan Haihui, Zhang Wei. Credit risk assessment of commercial banks based on neural network technology [J]. *Systems Engineering: Theory & Practice*, 1999, 9: 24–32. (in Chinese)
- [27] West D. Neural network credit scoring models [J]. *Computers and Operations Research*, 2000, 27(11–12): 1131–1152.
- [28] Yu L, Wang S, Lai K K. An intelligent-agent-based fuzzy group decision making model for financial multicriteria decision support: The case of credit scoring [J]. *European Journal of Operational Research*, 2009, 195(3): 942–959.
- [29] Kim K, Ahn H. A corporate credit rating model using multi-class support vector machines with an ordinal pairwise partitioning approach [J]. *Computers & Operations Research*, 2012, 39(8): 1800–1811.

- [30] Zhong H , Miao C , Shen Z , et al. Comparing the learning effectiveness of BP , ELM , I-ELM , and SVM for corporate credit ratings [J]. *Neurocomputing* , 2014 , 128: 285 – 295.
- [31] Malhotra R , Malhotra D K. Differentiating between good credits and bad credits using neuro-fuzzy systems [J]. *European Journal of Operational Research* , 2002 , 136(1) : 190 – 211.
- [32] Piramuthu S. Financial credit-risk evaluation with neural and neurofuzzy systems [J]. *European Journal of Operational Research* , 1999 , 112(2) : 310 – 321.
- [33] 吴 冲 , 吕静杰 , 潘启树 , 等. 基于模糊神经网络的商业银行信用风险评估模型研究 [J]. *系统工程理论与实践* , 2004 , 11: 1 – 8.
Wu Chong , Lv Jingjie , Pan Qishu , et al. Research on credit risk assessment model of commercial banks based on fuzzy neural network [J]. *Systems Engineering: Theory & Practice* , 2004 , 11: 1 – 8. (in Chinese)
- [34] 张洪祥 , 毛志忠. 基于多维时间序列的灰色模糊信用评价研究 [J]. *管理科学学报* , 2011 , 14(1) : 28 – 37.
Zhang Hongxiang , Mao Zhizhong. Research of multidimensional time series credit evaluation based on gray-fuzz analysis model [J]. *Journal of Management Sciences in China* , 2011 , 14(1) : 28 – 37. (in Chinese)
- [35] 李国勇. 神经网络控制理论及应用 [M]. 北京: 电子工业出版社 , 2009 , 211 – 232.
Li Guoyong. *Neural Network Control Theory and Application* [M]. Beijing: Publishing House of Electronics Industry. 2009 , 211 – 232. (in Chinese)
- [36] Sugeno M , Kang G T. Structure identification of fuzzy model [J]. *Fuzzy Sets and Systems* , 1988 , 28(1) : 15 – 33.
- [37] 李晓忠 , 王培庄 , 罗承忠. 模糊神经网络 [M]. 贵州: 贵州科技出版社. 1994 , 174 – 251.
Li Xiaozhong , Wang Peizhuang , Luo Chengzhong. *Fuzzy Neural Network* [M]. Guizhou: Guizhou Science and Technology Publishing House , 1994 , 174 – 251. (in Chinese)

Research on the credit rating of small and micro enterprises based on fuzzy neural network

XIAO Bin-qing¹ , YANG Yang^{2*} , LI Xin-dan¹ , LI Hao-hua¹

1. School of Engineering and Management , Nanjing University , Nanjing 210093 , China;

2. School of Business , Nanjing University , Nanjing 210093 , China

Abstract: Currently , the loan demand of small and micro enterprise is rapidly increasing , thus the establishment of an effective credit rating model for small and micro enterprises has become the focus of attention in the academic and practical fields. On the basis of the model and the index system , this paper puts forward the research steps of small and micro enterprises credit rating based on fuzzy neural network. This paper takes the micro data of the small and micro enterprises in a rural commercial bank as the empirical sample , and carry out the small enterprises and micro enterprises credit rating test separately. The empirical results show that the fuzzy neural network model in the small and micro enterprises credit rating research brought a higher detection accuracy than the BP neural network model. The model can realize the combination of subjective and objective ratings; can be used for qualitative adjustment and batch processing of data; and has explicit calculation process and decision rules. Therefore , it is suitable for the research of credit rating and has robustness.

Key words: fuzzy theory; neural network; small and micro-enterprises; credit rating