

基于 ADASYN-BPNN 的农户小额贷款信用评价研究^①

石宝峰，杨莲，柴娜娜

(西北农林科技大学 经济管理学院，杨凌 712100)

摘要：针对农户贷款数据具有“违约农户多、非违约农户少”不均衡特点、传统信用评价方法难以有效识别违约客户的不足的问题，本文利用过采样自适应综合过采样（Adaptive Synthetic Sampling, ADASYN）算法，对农户违约样本进行扩充；进而通过将反向传播神经网络（Back Propagation Neural Network, BPNN）中交叉熵（Cross Entropy）函数替换为含有调节因子 $(1-y')^{\gamma}$ 的焦点损失（Focal Loss）函数，构建 ADASYN-BPNN 评价模型。利用中国某农村金融服务机构农户小额贷款数据、两个公开数据集，将 ADASYN-BPNN 与传统 Cross Entropy 模型进行对比，发现 ADASYN-BPNN 识别精度优于传统 Cross Entropy 方法，模型表现稳健，可供金融机构实践使用参考。

关键词：信用评价；违约预测；小额贷款；神经网络

中图分类号：F832.4 **文献标识码：**A **文章编号：**(2020) 01-0064-13

0 引言

农业兴则基础牢，农村稳则天下安，农民富则国家盛。然而，涉农主体“贷款难、贷款贵”一直是制约我国农村经济社会发展的最大掣肘。为切实缓解涉农主体资金困难，中国人民银行、中国银行保险监督管理委员会、中国证券监督管理委员会、财政部、农业农村部五部委联合发文，要求推进农村信用体系建设，改善涉农贷款客户融资增信机制，提高涉农信贷风险的识别、监控、预警和处置水平，创新信用评价模式，在有效做好风险防范的前提下，逐步提升发放涉农贷款的比例^[1]。究其原因，由于农户小额贷款业务量大、额度小、风险分散、财务信息不健全、缺乏抵质押担保物，金融机构出于风险管理要求，很难对缺乏信用历史的借款农户进行信用画像^[2,3]。与此同时，随着大数据、机器学习等技术的发展，金融科技应运而生。通过增加数据维度，借鉴机器学习方法构建信用风险评价模型，可有效提升贷款客户的违约预测准确率^[4-8]。

为了测算贷款客户的信用风险，学者们开展了大量研究。在农户信用风险影响因素研究方面，姚淑琼和强俊宏^[9]选取用户主年龄、家庭人口数、家庭劳动力数、耕地面积、农业收入、非农收入、房屋价值等 15 个指标，构建 BPNN 模型测算农户信用风险，结果表明模型违约预测准确率达 84.09%。陈暮紫等^[10]从还款意愿和还款能力两个维度，遴选债务人学历、与信用社关系是否密切、家庭收入等 16 个指标，评价农户的违约状况。魏岚^[11]选用农户耕地总面积、自有居住房屋价值、家庭经营纯收入、家庭人均收入与人均 GDP 之比、家庭纯收入、家庭日常支出、支出收入比例、家庭总财产、务农收入、家庭农业生产性支出等指标，构建 Logit 回归模型，测算贷款农户的信用风险。迟国泰等^[12]建立了由农户年龄、贷款记录、恩格尔系数等 16 个指标组成的农户信用评价指标体系。Mollmann 等^[13]利用有序 Logit 和分位数回归测度农户信用风险，发现遥感植被指数保险可以增加农户获得信贷的机会。

① 基金项目：国家自然科学基金资助项目（71873103, 71731003）。

作者简介：石宝峰（1984—），男，山西武乡人，博士，西北农林科技大学经济管理学院教授，博士生导师，研究方向：金融风险管理，E-mail：shibaofeng@nwsuaf.edu.cn，通讯作者；杨莲（1988—），女，山西长治人，博士研究生，西北农林科技大学经济管理学院，研究方向：农村金融；柴娜娜（1992—），女，山西临汾人，博士研究生，西北农林科技大学经济管理学院，研究方向：信用风险管理。

在信用风险建模分析方面,主要有计量统计方法和机器学习方法两类。计量统计模型的原理是找到解释输入变量的最优线性组合,从而对客户违约风险进行预测^[14]。吕德宏和朱莹^[15]利用 Logit-ISM 模型,研究影响不同类型农户小额信贷风险的主要因素,进而分析了影响因素之间的层次结构差异性。牟刚和袁先智^[16]依据精度高、变量少、数据可获取原则,分析了结构模型、生存分析模型和 Logit 模型在信用评价中的适用性,得出二元 Logit 选择模型更加现实和可行的结论。上述方法对低维信用数据建模具有明显优势,但对高维、非线性数据分析带来一定的挑战。为此,越来越多学者将支持向量机^[17-19]、决策树^[20,21]、多分类器系统和集成模型^[22-24]引入信用评价,取得了良好的分类效果。随着研究的深入,学者们发现信用评价数据具有“违约客户多、非违约客户少”典型不均衡性。银行等金融机构更关注判别模型对违约样本的识别能力^[25-27],改善模型预测性能的关键在于提升模型对违约样本的识别性能^[28]。

针对上述问题,本文从反映农户基本情况、家庭特征、偿债能力、所在地宏观经济环境四方面遴选指标,构建农户小额贷款信用评价指标体系;在此基础上,利用 ADASYN 对违约样本进行扩充,进而利用 BPNN 构建信用评价模型。最后,利用中国某小额贷款机构 472 笔农户小额贷款数据以及美国加州大学欧文分校 (UCI) 公开的德国、澳大利亚数据集进行实证分析,通过将本文所建 BPNN-Focal Loss 模型与 BPNN-Cross Entropy 模型对比,发现本文模型违约判别性能更优,所建模型表现稳健。

论文后续部分结构如下:第 1 部分是农户小额贷款信用风险评价方法;第 2 部分是实证分析;第 3 部分是稳健性检验;第 4 部分是结论。

1 农户小额贷款信用风险评价方法

1.1 科学问题难点和突破难点的思路

科学问题难点:农户小额贷款财务信息不健全、缺乏必要的抵质押担保物,加之信用数据具有违约客户少、非违约客户多的不均衡数据特性,加大了信用风险评价模型对违约样本的识别难度。如何借鉴机器学习算法,提高信用风险评价模型对农户小额贷款不均衡数据中违约样本的识别能力是急需解决的一个难题。

突破难点思路如下。

1) 利用 ADASYN 算法,通过计算农户贷款数据训练集违约样本 K 近邻中非违约样本占比,结合训练集总样本中违约、非违约样本比例,确定该违约样本需新生成的违约样本数目;进而,利用合成少数过采样技术 (SMOTE) 数据扩充算法生成新样本,使违约、非违约农户达到均衡。为便于理解,不妨设违约客户数为 $Q_{\text{违约}}$ 、非违约客户数为 $Q_{\text{非违约}}$,则 ADASYN 信用评价数据均衡化处理过程为:①计算需新生成的违约样本个数 Q_{new} , $Q_{\text{new}} = Q_{\text{非违约}} - Q_{\text{违约}}$ 。②计算每个违约样本的 K 近邻中非违约样本的占比 r_i 。设违约样本 x_i 的 K 近邻中违约样本数为 P_i 、非违约样本数为 $\Delta_i = K - P_i$,则 $r_i = \Delta_i / K$ 。据此,可计算 $Q_{\text{违约}}$ 个违约样本 K 近邻中非违约样本的占比 $r_i = \Delta_i / K$, $i = 1, 2, \dots, Q_{\text{违约}}$ 。③对 r_i 进行归一化处理,可得 $\Gamma_i = \frac{r_i}{\sum_{i=1}^{Q_{\text{违约}}} r_i}$, $i = 1, 2, \dots, Q_{\text{违约}}$ 。④计算每个违约样本需新生成的违约样本数,即 $h_i = Q_{\text{new}} \Gamma_i$, $i = 1, 2, \dots, Q_{\text{违约}}$ 。⑤利用 SMOTE 算法,对每一个违约样本生成与其对应的新违约样本,实现对信用评价数据的均衡化处理。

2) 借助机器学习中的 BPNN 方法,通过将 BPNN 中交叉熵损失函数替换为 Focal Loss 损失函数,增大模型对违约样本中难以识别困难样本的判别力,提升模型的预测准确性,解决上述难题。

1.2 信用评价海选指标集建立

以标准普尔公司、穆迪公司、中国银行保险监督管理委员会、中国农业银行等机构农户信贷管理评价指标为基础^[29-33],结合数据的可获取性,筛选出贷款目的、供养学生人数、农村居民家庭恩格尔系数等 33 个指标组成的农户小额贷款信用风险评价指标集,如表 1 所示。

表 1 农户信用评价指标及原始数据
Table 1 Credit assessment indicators and their original data of farmers

(1) 序号	(2) 准则层	(3) 指标	(4) 类型	(5) 原始数据 u_{ij}					
				非违约客户			违约客户		
				(1)	...	(354)	(355)	...	(472)
1	I_1 农户基本情况	X_1 教育程度	定性	大专及以上	...	高中	高中	...	高中
...	
13		X_{13} 贷款目的	定性	社会服务业	...	批发和零售贸易	生产加工业	...	批发和零售贸易
14	I_2 农户家庭特征	X_{14} 供养学生人数	定性	1	...	1	1	...	1
...	
19		X_{19} 劳动力占比	正向	0.382	...	0.468	0.525	...	0.525
20	I_3 偿债能力	X_{20} 总资产	正向	数据缺失	...	800000	380000	...	800000
...	
23		X_{23} 月可支配收入	正向	数据缺失	...	7667	10800	...	6000
24	I_4 所在地外部宏观条件	X_{24} 人均地区生产总值	正向	38083.84	...	49514	31585	...	23018
...	
33		X_{33} 农村居民家庭恩格尔系数	负向	166.6	...	225.66	179.78	...	278.78
34	—	违约状态 y_i ($y_i=0$, 表示非违约客户; $y_i=1$, 表示违约客户)	—	0	...	0	1	...	1

1.3 指标数据预处理

由于不同类型信用评价指标单位量纲存在差异，在信用风险评价建模之前，需要对原始指标数据进行预处理，将其转化为 $[0, 1]$ 之间的标准化数值。评价指标数据通常可分数值型定量指标和文本型定性指标两类，定量指标由正向指标、负向指标、区间指标和适中值四类组成^[34,35]。

正向指标指数值越大、信用状况越好的指标，如“人均地区生产总值”等指标。设 x_{ij} 为第 i 个农户第 j 个指标的标准化值； u_{ij} 为第 i 个农户第 j 个指标原始数据，则

$$x_{ij} = \frac{u_{ij} - \min(u_{ij})}{\max(u_{ij}) - \min(u_{ij})} \quad (1)$$

负向指标指数值越小、信用状况越好的指标，如资产负债率，其标准化公式为

$$x_{ij} = \frac{\max(u_{ij}) - u_{ij}}{\max(u_{ij}) - \min(u_{ij})} \quad (2)$$

区间型指标指取值在某一个特定区间内，信用情况均取最大值的指标。例如，“年龄”的最佳区间为 $[31, 45]$ ，它表示年龄位于该区间的借贷农户还款能力和还款意愿最强^[36]；指标“居民消费价格指数”的最佳区间为 $[101, 105]$ 。设 q_1 为最佳区间的左端点； q_2 为最佳区间的右端点，则

$$x_{ij} = \begin{cases} 1 - \frac{q_1 - u_{ij}}{\max(q_1 - \min(u_{ij}), \max(u_{ij}) - q_2)}, & u_{ij} < q_1 \\ 1 - \frac{u_{ij} - q_2}{\max(q_1 - \min(u_{ij}), \max(u_{ij}) - q_2)}, & u_{ij} > q_2 \\ 1, & q_1 \leq u_{ij} \leq q_2 \end{cases} \quad (3)$$

式(3) 中其余字母含义同式(1)。

对于文本型定性指标, 数据标准化通常结合数据源所在金融机构、业界信贷审批专家、高校科研人员的知识经验进行。本文在征求相关专家意见的基础上, 制定了农户小额贷款信用风险评价文本型指标打分标准。按照指标文本选项与农户信用风险的贴近程度, 采用等距、非等距和 0~1 分类三种打分方式对 17 个定性指标进行标准化打分。婚姻状态、职业、贷款目的等指标, 采用等距打分法; 性别、教育程度等指标, 采用非等距打分法; 贫困类型、民族、户口类型、有无房产证等指标, 采用 0~1 打分法, 如表 2 所示。

表 2 农户信用评价定性指标打分标准

Table 2 Credit assessment qualitative indicator scoring standard for farmers

(1) 序号	(2) 准则层	(3) 指标	(4) 选项标号	(5) 文本选项内容	(6) 打分	
1	贷款人基本情况	性别	1	男	1	
			0	女	0.8	
...		
12		贷款目的	1	交通运输业	1	
			2	批发和零售贸易	0.8	
			3	社会服务业	0.6	
			4	生产加工业	0.6	
			5	农、林、牧、渔业	0.4	
			6	养殖业	0.4	
			7	种植业	0.4	
			8	农房改建	0.2	
			9	消费	0.2	
			10	其他行业	0	
...	
17	贷款人家庭特征	劳动力人口数	1	≥4	1	
			2	3	0.75	
			3	2	0.5	
			4	1	0.25	
			5	0	0	

1.4 基于 ADASYN 的农户信用评价违约数据扩充

为了解决不均衡数据对评价结果的影响, 本文借鉴 ADASYN-SMOTE 方法^[37], 通过生成新的违约样本来平衡农户贷款数据, 从而提高评价模型对信用风险的判别能力。农户信用评价数据均衡化处理过程如下。

首先, 计算需新生成的违约样本数 Q_{new} 。设 S_{train} 为农户信用风险评价模型的训练集, 其中非违约样本集为 S_{large} , 违约样本集为 S_{small} ; Q_{large} 为非违约样本集 S_{large} 中农户个数, Q_{small} 为违约样本集 S_{small} 中违约农户数, x_i 为 S_{small} 中第 i 个农户。则

$$Q_{\text{new}} = Q_{\text{large}} - Q_{\text{small}} \quad (4)$$

其次, 计算违约样本 x_i 的 K 近邻中非违约样本占比 $r_i = \Delta_i / K$, 其中 Δ_i 为 x_i 的 K 近邻中非违约样本数。对 r_i 进行归一化处理, 得到分布函数 Γ_i ; 根据分布函数 Γ_i , 计算违约农户 x_i 邻域新合成的违约样本数 $h_i = \Gamma_i \cdot Q_{\text{new}}$, 其中

$$\Gamma_i = \frac{r_i}{\sum_{i=1}^{Q_{\text{small}}} r_i} \quad (5)$$

最后, 利用 SMOTE 生成 h_i 个新违约样本 $s_i = x_i + (x_{z_i} - x_i) \lambda$, 其中 x_{z_i} 为农户 x_i 的 K 近邻中随机选取的一

个违约样本， λ 为随机数。

1.5 基于 BPNN 的农户违约风险预测建模

BPNN 的本质是通过梯度下降法，寻找可以最小化结构风险的网络参数^[38]。由于该方法具有较强的非线性处理、指标学习和预测能力，郭英见和吴冲^[39]将其引入了商业银行信用风险评估建模分析。BPNN 违约风险预测建模由农户信用风险评价信息的正向传递和误差反向传播两部分组成。农户信用风险评价信息正向传递指从输入层的评价指标 x_i 入手，利用隐藏层的非线性激活函数 f_l 逐层处理，求解输出层农户违约状态 y'_i 的过程。农户信用风险评价误差反向传播是指在计算输出层违约状态 y_i 与预测值 y'_i 误差 $|y_i - y'_i|$ 的基础上，通过逐层反向测算各隐藏层神经元对最终误差 $|y_i - y'_i|$ 的影响，利用梯度下降法调整各网络层的权重矩阵与偏置，以找出使模型预测误差 $|y_i - y'_i|$ 最小的最优参数组合的过程。

(1) 农户信用风险评价信息的正向传递

设 $x_i = \{x_i^1, x_i^2, \dots, x_i^M\}$ 为农户 i 信用风险评价指标向量； $W^{(l)}$ 为第 $l-1$ 层到 l 层的权重矩阵； $\Sigma_l(j)$ 为 l 层加权单元； $v_j^{(l)}$ 为第 l 层第 j 个神经元的“激活水平”； f_l 为第 l 层神经元的激活函数； g_L 为第 L 层（输出层）违约判别函数； y_i 为农户的违约状态（其中 $y_i=0$ 表示非违约农户， $y_i=1$ 表示违约农户）； L 为神经网络的层数； C_l 为第 l 层神经元的个数； $\Sigma_l(j)$ 为第 l 层第 j 个神经元的输入； M 为指标数； y'_i 为农户违约状态的预测值。农户信用风险评价信息正向传递结构如图 1 所示。

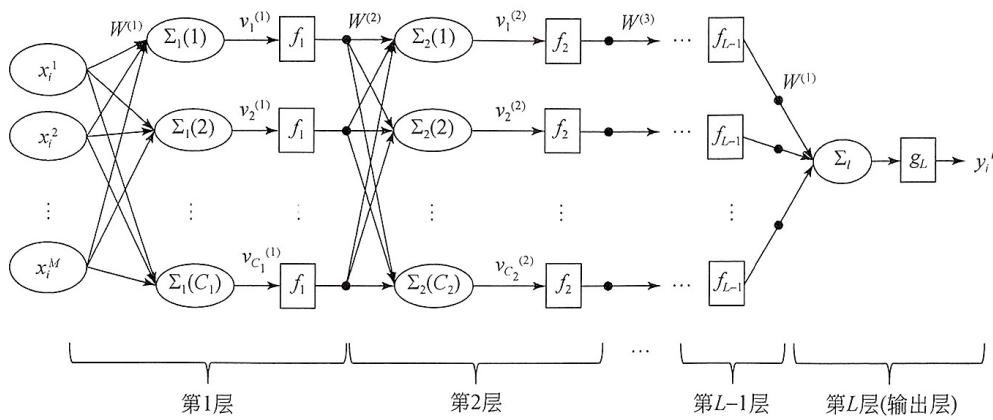


图 1 农户信用风险评价 BPNN 违约预测（正向）

Fig. 1 Default prediction of loan farmers based on BPNN method (Positive)

对于第 1 层隐藏层神经元，假设 $W^{(1)}$ 为输入层到第 1 层隐藏层神经元的权重矩阵， $b^{(1)}$ 为输入层到第 1 层隐藏层神经元的偏置，以评价指标向量 $x_i = \{x_i^1, x_i^2, \dots, x_i^M\}$ 为输入层，利用 $W^{(1)}$ 加权后的加权单元为

$$\Sigma_1(j) = W^{(1)} x_i + b^{(1)} \quad (6)$$

将神经元激活水平 $v_j^{(1)}$ 和激活函数 f_1 作用于 $\Sigma_1(j)$ ，得到第 1 层隐藏层神经元输出 $a^{(1)}$ ：

$$a^{(1)} = f_1(\Sigma_1(j), v_j^{(1)}) \quad (7)$$

以此类推，依次求解第 2 层，第 3 层，…，第 $L-1$ 层神经元的输出值 $a^{(L-1)}$ 。结合第 L 层（输出层）违约判别函数 g_L 可求得农户违约状态的预测值 y'_i 。给定判别阈值 β ，当农户违约状态预测值 $y'_i < \beta$ 时，表示该农户为非违约农户；当 $y'_i > \beta$ 时，表示该农户为违约客户^[40]。至此，实现农户信用评价指标至违约状态的预测。

(2) 基于违约预测误差的反向参数调整

通过将正向传递求得的违约状态预测值 y'_i 与农户真实违约状态 y_i 进行对比，求解模型的预测误差 $|y_i - y'_i|$ 。若 $|y_i - y'_i| \neq 0$ ，则进入反向传播调整模型参数。参数调整基本思路：给定反向传播神经网络的目标损失函数 $F(y_i, y'_i)$ ，根据梯度下降法，求解目标损失函数 $F(y_i, y'_i)$ 对网络各层权重矩阵 $W^{(l)}$ 和偏置 $b^{(l)}$ 的偏导。通过对参数值进行迭代更新，找出使目标损失函数最小的 $W^{(l)}$ 与 $b^{(l)}$ ，即为最优参数组合。建模分析过程如下：

设 $F(y_i, y'_i)$ 为目标损失函数, $\Sigma_l = (\Sigma_l(1), \Sigma_l(2), \dots, \Sigma_l(C_l))$ 为第 l 层神经元的输入向量, $f_l'(\Sigma_l)$ 为第 l 层神经元输入对输出的贡献度, $W^{(l+1)}$ 为第 l 层到第 $l+1$ 层的权矩阵, 则第 l 层神经元误差 $\delta^{(l)}$ 为

$$\delta^{(l)} = \frac{\partial F(y_i, y'_i)}{\partial \Sigma_l} = f_l'(\Sigma_l) \cdot ((W^{(l+1)})^T \delta^{(l+1)}) \quad (8)$$

进一步, 通过计算目标损失函数 $F(y_i, y'_i)$ 对 $W^{(l)}$ 、 $b^{(l)}$ 的偏导, 测算权重矩阵 $W^{(l)}$ 对目标损失影响程度。设 $a^{(l-1)}$ 为第 $l-1$ 层神经元的输出, 则 $F(y_i, y'_i)$ 对 $W^{(l)}$ 与 $b^{(l)}$ 的偏导为

$$\frac{\partial F(y_i, y'_i)}{\partial W^{(l)}} = \delta^{(l)} (a^{(l-1)})^T \quad (9)$$

$$\frac{\partial F(y_i, y'_i)}{\partial b^{(l)}} = \delta^{(l)} \quad (10)$$

在求解偏导基础上, 通过对参数矩阵 $W^{(l)}$ 与 $b^{(l)}$ 进行迭代更新, 找出使目标损失函数最小时对应的一组参数矩阵 $W_0^{(l)}$ 和 $b_0^{(l)}$, 即为模型对应的最优参数组合。

(3) 基于 Focal Loss 测算违约预测误差的农户小额贷款信用评价方法

BPNN 常以交叉熵作为目标损失函数 $F(y_i, y'_i)$ 进行建模学习。随着研究的深入, 人们发现以交叉熵为目标损失函数 $F(y_i, y'_i)$ 的 BPNN 模型, 存在无法有效识别贷款客户违约样本中难以识别困难样本的问题^[40]。为此, 本文借鉴杨莲和石宝峰^[40]做法, 将交叉熵损失函数替换为 Focal Loss 函数, 来提升模型的违约识别能力。

设 γ 为 Focal Loss 函数的聚焦参数 ($\gamma \geq 0$), $(1-y')^\gamma$ 为调节因子, 则

$$\text{FocalLoss}(y_i, y'_i) = \begin{cases} -(1-y_i)^\gamma \ln(y'_i), & y_i=1 \\ -(y'_i)^\gamma \ln(1-y_i), & y_i=0 \end{cases} \quad (11)$$

式 (11) 的经济学含义如下。

1) 当农户为违约客户 ($y_i=1$) 时, 式 (11) 等价于:

$$\text{FocalLoss}(y'_i, y_i) = -(1-y'_i)^\gamma \ln(y'_i) \quad (12)$$

由于农户违约状态预测值 $y'_i \in [0, 1]$, 分三种情况讨论其取值:

第一, 当 $y'_i=0$ 时, 表示评价模型将违约农户判别为非违约农户, 模型预测错误。此时 $\text{FocalLoss} = -(1-0)^\gamma \ln(0) = +\infty$, 损失为无穷大。

第二, 当 $y'_i=1$ 时, 表示评价模型将违约农户判别为违约农户, 模型预测正确。此时 $\text{FocalLoss} = -(1-1)^\gamma \ln(1) = 0$, 损失为 0。

第三, 当 $y'_i \in (0, 1)$ 时, 不妨取 $y'_i=0.8$, 大于分类阈值 0.5, 分类正确。此时 $\text{FocalLoss} = -(1-0.8)^\gamma \log(0.8) = (0.2)^\gamma \times 0.097$, 损失为 $(0.2)^\gamma \times 0.097$ 。

2) 当农户为非违约客户 ($y_i=0$) 时, 式 (11) 等价于

$$\text{FocalLoss}(y'_i, y_i) = -(y'_i)^\gamma \ln(1-y'_i) \quad (13)$$

第一, 当 $y'_i=0$ 时, 表示评价模型将非违约农户判别为非违约农户, 模型预测正确。此时 $\text{FocalLoss} = -(0)^\gamma \ln(1) = 0$, 损失为 0。

第二, 当 $y'_i=1$ 时, 表示评价模型将非违约农户判别为违约农户, 模型预测错误。此时 $\text{FocalLoss} = -(1)^\gamma \ln(0) = +\infty$, 损失为无穷大。

第三, 当 $y'_i \in (0, 1)$ 时, 不妨取 $y'_i=0.2$, 小于分类阈值 0.5, 分类正确。此时 $\text{FocalLoss} = -(0.2)^\gamma \log(1-0.2) = (0.2)^\gamma \times 0.097$, 损失为 $(0.2)^\gamma \times 0.097$ 。

不难看出, 式 (11) 通过引入聚焦参数 γ , 构造调节因子项 $(1-y'_i)^\gamma$, 用以调整难以预测的困难样本所造成的损失在目标损失中的占比, 以实现模型对困难样本的有效识别。例如, 对于违约样本 ($y_i=1$) 而言, 不妨取 $\gamma=3$, 当预测值 y'_i 为 0.9 时, 模型预测正确, 该样本为简单样本, 受调节因子 $(1-y'_i)^\gamma = (1-0.9)^3 = 0.001$ 的影响, 式 (11) 将交叉熵损失函数 $-\log(y'_i)$ 变为 $-(1-y'_i)^\gamma \log(y'_i) = 0.001 \times \log(y'_i)$, 也就是说调节因子 $(1-y'_i)^\gamma$ 降低了简单样本所造成的损失在目标损失中的权重。同理, 对于违约样本 ($y_i=1$),

当 y'_j 为 0.1 时, 模型预测错误, 该样本为困难样本; 此时调节因子 $(1-y'_j)^\gamma = (1-0.1)^3 = 0.729$ 可将交叉熵损失函数 $-\log(y'_j)$ 变为 $-(1-y'_j)^\gamma \log(y'_j) = 0.729 \times \log(y'_j)$, 对比 $0.001 \times \log(y'_j)$ 可知, 调节因子 $(1-y')^\gamma$ 增大了困难样本在目标损失中的权重。

综上, 调节因子项 $(1-y')^\gamma$ 在减少简单样本对总损失贡献的同时, 增加了困难样本损失占总损失的比例, 可以有效实现对信用评价数据中困难样本的挖掘。

1.6 农户违约风险预测模型的评价

首先, 在 1.2 节确定农户信用评价海选指标集的基础上, 依据 1.3 节定量、定性打分方法对原始数据进行标准化处理; 其次, 将标准化数据按一定比例分为训练集 S_{train} 和测试集 S_{test} , S_{train} 用于农户信用风险评价模型的构建, S_{test} 用于农户信用风险评价模型违约判别的有效性检验。进一步, 根据 1.4 节中 ADASYN 算法对训练集 S_{train} 中的违约样本进行合成, 使训练集 S_{train} 中违约、非违约样本比例达到 1:1。最后, 利用训练集 S_{train} 对 ADASYN-BPNN 模型进行训练, 可得农户信用风险评价模型。将农户测试集 S_{test} 数据代入信用风险评价模型, 求解测试集上每个农户违约状态的预测结果。通过对比预测结果和农户真实的违约状态, 得出模型的预测精度。

为了判定违约风险预测模型的判别能力, 现有文献采用诸如 ROC 曲线下面积 (AUC)、第一类错误率 (Type1-error)、第二类错误率 (Type2-error)、准确度 (Accuracy) 等标准进行判定, 其计算公式参见文献 [40], 此处不再赘述。

2 实证分析

2.1 样本选取和数据来源

本文利用中国某农村金融服务机构 472 笔农户小额贷款数据和 UCI 公开的德国、澳大利亚数据集, 对上文所建模型进行验证, 表 3 为三个数据集的基本信息。将表 1 中原始数据, 利用表 2 中定性指标打分方法和 1.3 节所示指标预处理方法对其进行标准化处理, 所得结果如表 4 所示。

表 3 样本数据基本信息
Table 3 Basic information of sample data

数据集	样本总数/个	非违约/违约	非违约:违约	指标数/个
德国	1000	700/300	2.3:1	24
澳大利亚	690	307/383	1:1.2	14
农户小额贷款	472	354/118	3:1	33

表 4 农户信用风险评价指标标准化数据
Table 4 The standardized data of farmers' credit evaluation

(1) 序号	(2) 准则层	(3) 指标	(4) 类型	(5) 标准化数据 x_{ij}						
				非违约农户			违约农户			
				(1)	...	(354)	(355)	...	(472)	
1	I_1 农户基本情况	X_1 教育程度	定性	1.000	...	0.600	0.600	...	0.600	
...		
13		X_{13} 贷款目的	定性	0.600	...	0.400	0.600	...	0.800	
14	I_2 农户家庭特征	X_{14} 供养学生人数	定性	0.500	...	0.000	0.500	...	0.500	
...		
19		X_{19} 劳动力占比	正向	0.382	...	0.468	0.525	...	0.525	

续表

(1) 序号	(2) 准则层	(3) 指标	(4) 类型	(5) 标准化数据 x_{ij}					
				非违约农户			违约农户		
				(1)	...	(354)	(355)	...	(472)
20	I_3 偿债能力	X_{20} 总资产	正向	0.101	...	0.065	0.078	...	0.164
...	
23		X_{23} 月可支配收入	正向	0.140	...	0.214	0.210	...	0.107
24	I_4 所在地 外部宏观条件	X_{24} 人均地区生产总值	正向	0.510	...	0.502	0.264	...	0.150
...	
33		X_{33} 农村居民家庭恩格尔系数	负向	0	...	0	0	...	0.007
34	—	违约状态 y_i	—	0	...	0	1	...	1

2.2 农户违约风险预测结果分析

通过多次实验, 针对农户小额贷款数据选出本文所建模型 BPNN-FocalLoss 的最优参数, L 为 7、输入层节点为 33、隐藏层节点为 64、输出层节点为 2、神经元丢弃率 $\text{Dropout}_l=0.2$ 、 $\gamma=3$ 、迭代次数 Epochs = 500、批处理样本量 batch-size = 50, 如表 5 表示。将表 4 标准化数据和表 5 参数代入上文所建模型, 求得 Accuracy、AUC、Type-1 error 和 Type-2 error 如表 6 第 1 行前 5 列所示。

为了将本文模型所求结果与经典交叉熵函数所求结果进行对比分析, 将表 4 标准化数据代入 BPNN-CrossEntropy 模型, 结果如表 6 第 1 行后 4 列所示。对于农户小额贷款数据, BPNN-CrossEntropy 模型的 Accuracy 为 95.7%, 而本文所建模型 BPNN-FocalLoss 的 Accuracy 为 96.3%, 比 BPNN-CrossEntropy 模型提高了 0.6%; BPNN-CrossEntropy 模型的 AUC 为 93.7%, 而本文所建模型的 AUC 为 94.7%, 比 BPNN-CrossEntropy 模型提高了 1.0%; 与此同时, 本文所建模型对非违约农户判别的错误率 Type-1 error 低于 BPNN-CrossEntropy 模型, BPNN-CrossEntropy 模型对违约农户判别的错误率 Type-2 error 略低于本文所建模型。由此不难发现, BPNN-FocalLoss 模型在农户小额贷款信用评价数据集的分类精度多优于传统 BPNN-CrossEntropy 模型。因此, 本文提出的模型比传统的 BPNN-CrossEntropy 模型更能有效地预测农户小额贷款的信用风险。

表 5 农户小额贷款信用评价模型参数设置

Table 5 Parameter setting of farmers' microfinance credit assessment

数据集	L	输入层节点	隐藏层节点	输出层节点	Dropout_l	Epochs	batch-size	γ
农户小额贷款	7	33	64	2	0.2	500	50	3
德国	3	24	10	2	0.2	500	50	3
澳大利亚	2	14	10	2	0.2	500	50	3

表 6 BPNN-FocalLoss 模型和 BPNN-CrossEntropy 模型预测精度比较 (%)

Table 6 Comparison of prediction accuracy between BPNN-FocalLoss and BPNN-CrossEntropy (%)

数据集	BPNN-FocalLoss 模型				BPNN-CrossEntropy 模型			
	Accuracy	AUC	Type-1error	Type-2error	Accuracy	AUC	Type-1error	Type-2error
农户小额贷款	96.3	94.7	1.7	8.8	95.7	93.7	1.9	6.4
德国	88.6	89.1	15.8	6.2	87.2	87.5	16.1	8.9
澳大利亚	91.0	91.4	12.9	3.9	88.6	88.6	13.2	8.3

3 稳健性检验

为了评价本文所建农户信用风险 BPNN-FocalLoss 模型测度模型的判别性能，本文从两方面着手进行稳健性分析：一是将上文农户数据换为 UCI 公开的德国、澳大利亚数据集；二是利用评价模型的 Loss 收敛曲线进行对比。

利用表 5 所示的德国、澳大利亚数据集模型参数，结合表 3 所示数据，可得德国、澳大利亚数据集在 BPNN-FocalLoss 模型和 BPNN-CrossEntropy 模型下的预测结果，如表 6 最后 2 行所示。对于德国数据，BPNN-CrossEntropy 模型的 Accuracy 为 87.2%，而 BPNN-FocalLoss 模型的 Accuracy 为 88.6%，比 BPNN-CrossEntropy 模型提高 1.4%；BPNN-CrossEntropy 模型的 AUC 为 87.5%，而 BPNN-FocalLoss 模型的 AUC 为 89.1%，比 BPNN-CrossEntropy 模型提高 1.6%；BPNN-CrossEntropy 模型的错误率 Type-1 error 为 16.1%，而 BPNN-FocalLoss 模型的错误率模型为 15.8%，比 BPNN-CrossEntropy 模型低 0.3%；BPNN-CrossEntropy 模型的错误率 Type-2 error 为 8.9%，而 BPNN-FocalLoss 模型的错误率 Type-2 error 为 6.2%，比 BPNN-CrossEntropy 模型低 2.7%。由此可知，对于德国数据，本文所建 BPNN-FocalLoss 模型优于 BPNN-CrossEntropy 模型。进一步，对于澳大利亚数据也可得到类似结论：BPNN-CrossEntropy 模型的 Accuracy 为 88.6%，而 BPNN-FocalLoss 模型的 Accuracy 为 91.0%，比 BPNN-CrossEntropy 模型提高 2.4%；BPNN-CrossEntropy 模型的 AUC 为 88.6%，而 BPNN-FocalLoss 模型的 AUC 为 91.4%，比 BPNN-CrossEntropy 模型提高 2.8%；BPNN-CrossEntropy 模型的错误率 Type-1 error 为 13.2%，而 BPNN-FocalLoss 模型的错误率模型为 12.9%，比 BPNN-CrossEntropy 模型低 0.3%；BPNN-CrossEntropy 模型的错误率 Type-2 error 为 8.3%，而 BPNN-FocalLoss 模型的错误率 Type-2 error 为 3.9%，比 BPNN-CrossEntropy 低 4.4%。

图 2~图 4 分别为农户小额贷款数据、澳大利亚和德国数据集的 Loss 收敛曲线。从图中可以看出，利用 Focal Loss 函数对神经网络参数优化后，可以在较短的时间内找到正确的寻优方向，具有较好的全局收敛性，而且在迭代后期依然能够保持收敛的平稳性；利用 Cross Entropy 进行参数优化时，Loss 值虽然也在下降，但是达到收敛状态的时间相对较长，尤其是对于德国数据集，在迭代后期仍有轻微震荡。对于农户小额贷款数据，BPNN-FocalLoss 模型与 BPNN-CrossEntropy 模型 Loss 曲线的收敛趋势接近。由此发现，Focal Loss 相比 Cross Entropy，收敛速度更快且更稳定，因此本文所建模型有效。

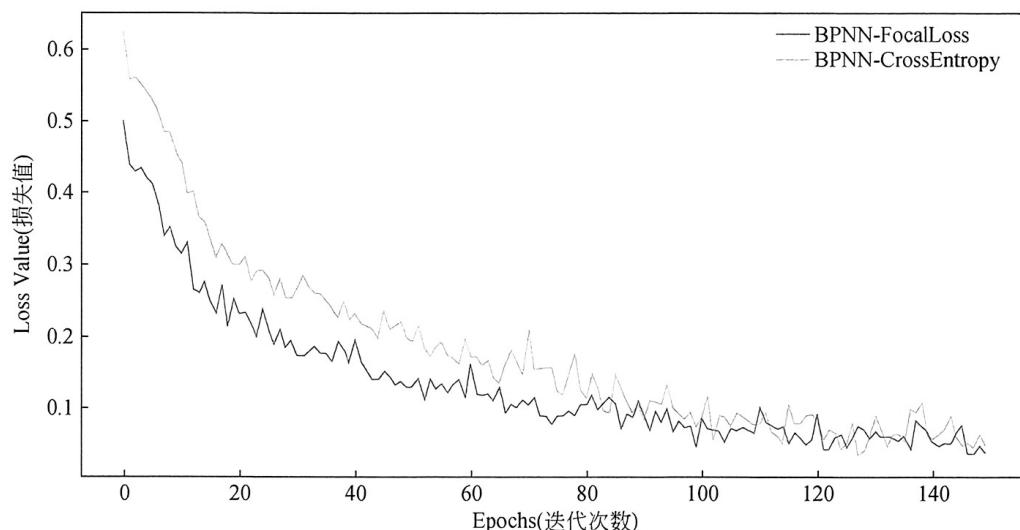


图 2 农户小额贷款数据 Loss 收敛曲线

Fig. 2 Loss convergence curve of farmers' microfinance loan

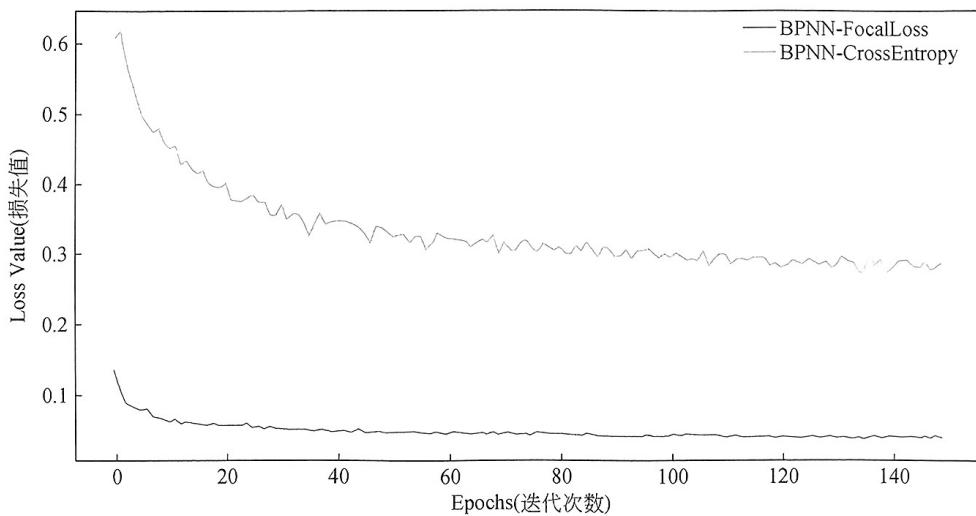


图3 澳大利亚数据集 Loss 收敛曲线

Fig. 3 Loss convergence curve of Australian data set

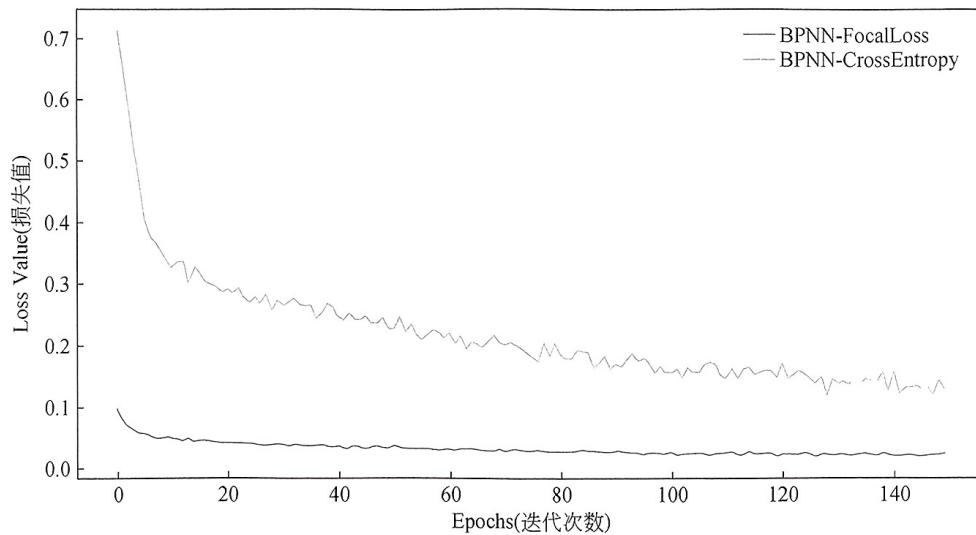


图4 德国数据集 Loss 收敛曲线

Fig. 4 Loss convergence curve of German data set

4 结论

作为金融支持脱贫攻坚的重要举措，小额贷款在缓解涉农贷款难、贷款贵方面发挥了重要作用。但由于其业务量大、额度小、风险分散、财务信息不健全，商业银行等金融机构无法准确评估贷款农户的信用风险，导致其放贷动力不足。因此，完善农户信用风险评价体系，对农户信用风险进行合理评估，不仅有利于“三农”问题的解决，还有利于激发商业银行等金融机构的放贷积极性。本文将 Focal Loss 函数引入信用评价领域，构建了 BPNN-FocalLoss 农户小额贷款信用评价模型，并对中国某农村金融服务机构 472 笔农户小额贷款数据和 UCI 公开数据集（德国和澳大利亚）分别进行实证，得出：分类精度方面，与 BPNN-CrossEntropy 模型相比，BPNN-FocalLoss 模型提高了贷款客户信用的预测精度、降低了第一类错误率；在 Loss 曲线收敛速度、收敛稳定性方面，BPNN-FocalLoss 模型在德国、澳大利亚数据集的表现明显优于 BPNN-CrossEntropy 模型，对农户小额贷款数据，二者表现相近。综上可知，本文所建 BPNN-FocalLoss 模型具有较强的违约预测能力，可供商业银行等金融机构实践参考。

本文的边际贡献在于：将 Focal Loss 函数引入农户小额贷款信用风险评价模型，拓展了 Focal Loss 的使用边界，为农户信用评价提供了新的解决方案。同时，从 Loss 收敛曲线视角，验证了本文所建 BPNN-FocalLoss 模型较传统 BPNN-CrossEntropy 模型的稳健性。

参考文献：

- [1] 五部门联合发布《关于金融服务乡村振兴的指导意见》 [EB/OL]. 中国政府网站, http://www.gov.cn/xinwen/2019-02/11/content_5364842.htm. 2019-02-11.
The five departments jointly issued the 《Guidance on financial services and Rural Revitalization》 [EB/OL]. Chinese government website, http://www.gov.cn/xinwen/2019-02/11/content_5364842.htm. 2019-02-11. (in Chinese)
- [2] 迟国泰, 潘明道, 齐菲. 一个基于小样本的银行信用风险评级模型的设计及应用 [J]. 数量经济技术经济研究, 2014, 31 (6): 102-116.
Chi G T, Pan M D, Qi F. A credit rating model for analyzing bank customers based on small sample [J]. The Journal of Quantitative & Technical Economics, 2014, 31 (6): 102-116. (in Chinese)
- [3] 石宝峰, 王静. 基于 ELECTRE III 的农户小额贷款信用评级模型 [J]. 系统管理学报, 2018, 27 (5): 854-862.
Shi B F, Wang J. A credit rating model of microfinance for farmers based on ELECTRRE III [J]. Journal of System & Management, 2018, 27 (5): 854 -862. (in Chinese)
- [4] Frost J, Gambacorta L, Huang Y, et al. BigTech and the changing structure of financial intermediation [J]. Economic Policy, 2019, 34 (100): 761-799.
- [5] Gambacorta L, Huang Y, Qiu H, et al. How do machine learning and non-traditional data affect credit scoring? New evidence from a Chinese Fintech firm [J]. BIS Working Papers, 2019, No. 834.
- [6] Pierce H, Dev A, Statham E, et al. Credit data generators for data reuse [J]. Nature, 2019, 570 (7759): 30-32.
- [7] 王正位, 周从意, 廖理, 等. 消费行为在个人信用风险识别中的信息含量研究 [J]. 经济研究, 2020, 55 (1): 149-163.
Wang Z W, Zhou C Y, Liao L, et al. Informational content of consumption behavior in consumer credit risk evaluation [J]. Economic Research Journal, 2020, 55 (1): 149-163. (in Chinese)
- [8] 黄益平, 邱哈. 大科技信贷: 一个新的信用风险管理框架 [J]. 管理世界, 2021, 37 (2): 12-21.
Huang Y P, Qiu H. Big Tech Lending: A new credit risk management framework [J]. Management World, 2021, 37 (2): 12-21. (in Chinese)
- [9] 姚淑琼, 强俊宏. 基于 BP 神经网络的农户小额信贷信用风险评估研究 [J]. 西北农林科技大学学报 (社会科学版), 2012, 12 (2): 78-83.
Yao S J, Qiang J H. Research on assessment of credit risk of small-amount financing for farmer households based on BP neural network [J]. Journal of Northwest A&F University (Social Science Edition), 2012, 12 (2): 78-83. (in Chinese)
- [10] 陈暮紫, 樊鹏英, 李楠, 等. 农村信用社信贷违约识别模型及其应用 [J]. 数学的实践与认识, 2014, 44 (20): 47-56.
Chen M Z, Fan P Y, Li N, et al. Recognition model of credit default in rural credit cooperatives and application [J]. Journal of Mathematics in Practice and Theory, 2014, 44 (20): 47-56. (in Chinese)
- [11] 魏岚. 农户小额信贷风险评价体系研究 [J]. 财经问题研究, 2013, (8): 125-128.
Wei L. Research on risk evaluation system of farmers' microfinance [J]. Research on Financial and Economic Issues, 2013, (8): 125-128. (in Chinese)
- [12] 迟国泰, 潘明道, 程砚秋. 基于综合判别能力的农户小额贷款信用评价模型 [J]. 管理评论, 2015, 27 (6): 42-57.
Chi G T, Pan M D, Cheng Y Q. Credit rating model of small loans for farmers based on comprehensive discriminant capacity [J]. Management Review, 2015, 27 (6): 42-57. (in Chinese)
- [13] Mollmann J, Buchholz M, Kolle W, et al. Do remotely-sensed vegetation health indices explain credit risk in agricultural microfinance? [J]. World development, 2020, 127: 104771.
- [14] Chen N, Ribeiro B, Chen A. Financial credit risk assessment: A recent review [J]. Artificial Intelligence Review, 2016, 45 (1): 1-23.
- [15] 吕德宏, 朱莹. 农户小额信贷风险影响因素层次差异性研究 [J]. 管理评论, 2017, 29 (1): 33-41.
Lv D H, Zhu Y. Research on the factors and hierarchy difference of farmer household microfinance risk [J]. Management

- Review, 2017, 29 (1): 33-41. (in Chinese)
- [16] 牟刚, 袁先智. 大数据架构下企业内部信用评级的实证研究 [J]. 系统工程学报, 2016, 31 (6): 808-815, 849.
Mu G, Yuan X Z. Empirical study for enterprise internal credit rating under big data framework [J]. Journal of Systems Engineering, 2016, 31 (6): 808-815, 849. (in Chinese)
- [17] Angilella S, Mazzù S. The financing of innovative SMEs: A multicriteria credit rating model [J]. European Journal of Operational Research, 2015, 244 (2): 540-554.
- [18] 程砚秋. 基于不均衡数据的小企业信用风险评价 [J]. 运筹与管理, 2016, 25 (6): 181-189.
Cheng Y Q. Credit rating of small enterprises based on unbalanced data [J]. OperationSresearch and Management Science, 2016, 25 (6): 181-189. (in Chinese)
- [19] 张卫国, 卢媛媛, 刘勇军. 基于非均衡模糊近似支持向量机的 P2P 网贷借款人信用风险评估及应用 [J]. 系统工程理论与实践, 2018, 38 (10): 2466-2478.
Zhang W G, Lu YY, Liu Y J. The borrowers' credit risk assessment in P2P platform based on fuzzy proximal support vector machine and its application [J]. System Engineering Theory and Practice, 2018, 38 (10): 2466-2478. (in Chinese)
- [20] Qi M, Zhao X L. Comparison of modeling methods for Loss Given Default [J]. Journal of Banking & Finance, 2011, 35 (11): 2842-2855.
- [21] 董路安, 叶鑫. 基于改进教学式方法的可解释信用风险评价模型构建 [J]. 中国管理科学, 2020, 28 (9): 45-53.
Dong L A, Ye X. Interpretable credit risk assessment modeling based on improved pedagogical method [J]. Chinese Journal of Management Science, 2020, 28 (9): 45-53. (in Chinese)
- [22] Nanni L, Lumini A. An experimental comparison of ensemble of classifiers for bankruptcy prediction and credit scoring [J]. Expert Systems with Applications, 2009, 36 (2), 3028-3033.
- [23] Xiao H S, Xiao Z, Wang Y. Ensemble classification based on supervised clustering for credit scoring [J]. Applied Soft Computing, 2016, 43: 73-86.
- [24] Xia Y F, Liu C Z, Li Y Y, et al. A boosted decision tree approach using Bayesian hyper-parameter optimization for credit scoring [J]. Expert Systems with Applications, 2017, 78 (15): 225-241.
- [25] 石宝峰, 刘锋, 王建军, 等. 基于 PROMETHEE-II 的商户小额贷款信用评级模型及实证 [J]. 运筹与管理, 2017, 26 (9): 137-147.
Shi B F, Liu F, Wang J J, et al. A credit rating model of microfinance loans for small private business based on PROMETHEE-II and its empirical study [J]. Operations Research and Management Science, 2017, 26 (9): 137-147. (in Chinese)
- [26] 程砚秋, 徐占东. 基于泰尔指数修正的 ELECTRE III 小企业信用评价模型 [J]. 中国管理科学, 2019, 27 (10): 22-33.
Cheng Y Q, Xu Z D. Credit risk evaluation of small enterprises based on revised ELECTRE III by theil index [J]. Chinese Journal of Management Science, 2019, 27 (10): 22-33. (in Chinese)
- [27] Lin T Y, Goyal P, Girshick R, et al. Focal Loss for Dense Object Detection [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, (99): 2999-3007.
- [28] Standard & Poor's Ratings Services. S&P's study of China's top corporates highlights their significant financial risks [R]. Standard & Poor's Ratings Services, September 13, 2012: 175-199.
- [29] Moody's Investors Service. Rating symbols and definitions [R]. Moody's Investors Services, 2016: 1-48.
- [30] 中国银监会. 农户贷款管理办法 (银监发〔2012〕50号) [R]. 中国银监会, 2012.
China Banking Regulatory Commission. Measures for the administration of farmers' loans (YJF〔2012〕No.50) [R]. China Banking Regulatory Commission, 2012. (in Chinese)
- [31] 中国农业银行. 中国农业银行“三农”客户信用等级评定管理办法 [R]. 中国农业银行, 2008.
Agricultural Bank of China. Administrative measures for credit rating of ‘agriculture, rural areas and farmers’ customers of Agricultural Bank of China [R]. Agricultural Bank of China, 2008. (in Chinese)
- [32] 中国邮政储蓄银行. 中国邮政储蓄银行农户信用评级表 [R]. 中国邮政储蓄银行, 2009.
Postal Savings Bank of China. Household credit rating table of Postal Savings Bank of China [R]. Postal Savings Bank of China, 2009. (in Chinese)
- [33] Chai N N, Wu B, Yang W W, et al. A multicriteria approach for modeling small enterprise credit rating: Evidence from China [J]. Emerging Markets Finance and Trade, 2019, 55 (11): 2523-2543.

- [34] 周颖, 沈隆. 基于 Brown-Mood 中位数检验的小企业债信评级体系 [J]. 系统管理学报, 2020, 29 (6): 1043-1055.
 Zhou Y, Shen L. A small enterprise facility rating system based on brown-mood test [J]. Journal of System & Management, 2020, 29 (6): 1043-1055. (in Chinese)
- [35] 赵志冲, 迟国泰, 白雪鹏. 基于最小显著差异法农户关键违约特征挖掘 [J]. 系统工程理论与实践, 2020, 40 (9): 2339-2351.
 Zhao Z C, Chi G T, Bai X P. Mining the key default characteristics of loan farmers based on the least significant difference method [J]. System Engineering Theory and Practice, 2020, 40 (9): 2339-2351. (in Chinese)
- [36] 迟国泰, 章彤, 张志鹏. 基于非平衡数据处理的上市公司 ST 预警混合模型 [J]. 管理评论, 2020, 32 (3): 3-20.
 Chi G T, Zhang T, Zhang Z P. Special treatment warning hybrid model dealing with imbalanced data ofchinese listed companies [J]. Management Science, 2020, 32 (3): 3-20. (in Chinese)
- [37] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors [J]. Nature, 1986, 323 (6088): 533-536.
- [38] 郭英见, 吴冲. 基于信息融合的商业银行信用风险评估模型研究 [J]. 金融研究, 2009, (1): 95-106.
 Guo Y J, Wu C. The assessment model of credit risk of commercial bank [J]. Financial Research, 2009, (1): 95-106. (in Chinese)
- [39] 肖斌卿, 杨旸, 李心丹, 等. 基于模糊神经网络的小微企业信用评级研究 [J]. 管理科学学报, 2016, 19 (11): 114-126.
 Xiao B Q, Yang Y, Li X D, et al. Research on the credit rating of small and micro enterprises based on fuzzy neural network [J]. Journal of Management Science, 2016, 19 (11): 114-126. (in Chinese)
- [40] 杨莲, 石宝峰. 基于 Focal Loss 修正交叉熵损失函数的信用风险评价模型及实证 [J]. 中国管理科学, 2021, 1-12. DOI: 10.16381/j.cnki.issn1003-207x.2020.2188. [2021-02-05 网络首发]
 Yang L, Shi B F. Credit Risk Evaluation Model and Empirical Research Based on Focal Loss Modified Cross-Entropy Loss Function [J]. Chinese Journal of Management Science, 2021, 1-12. DOI: 10.16381/j.cnki.issn1003-207x.2020.2188. [launched online on February 5, 2021] (in Chinese)

Study on Credit Assessment of Farmers' Microfinance Based on ADASYN-BPNN Method

Shi Baofeng, Yang Lian, Chai Nana

College of Economics and Management, Northwest A&F University, Yangling, 712100, China

Abstract: The imbalance characteristics of farmers' microfinance credit data makes it difficult for traditional credit risk assessment methods to effectively identify default customers. To address this problem, this paper uses ADASYN algorithm to generate the default samples of farmers, and replaces Cross Entropy function in BPNN with Focal Loss function which has the adjustment factor $(1 - y')^\gamma$, then constructs the ADASYN-BPNN credit risk evaluation model for farmers' microfinance. This paper uses farmers' microfinance credit data from a rural financial service institution in China and two real credit datasets of UCI databases to compare BPNN-FocalLoss and BPNN-CrossEntropy. The empirical results show that the model proposed in this study is better than BPNN-CrossEntropy in terms of Accuracy, AUC, type-1 error, type-2 error and Loss convergence curve. This research method has good robustness and can be directly applied to the credit risk assessment of financial institutions.

Key words: Credit Evaluation; Default Prediction; Microfinance; Neural Network