

# 企业信用评估指标体系及信用评估模型研究

朱菁婕, 吴怀岗

(南京师范大学计算机科学与技术学院, 江苏 南京 210023)

[摘要] 针对企业的信用评估, 基于已有研究, 引入企业财务指标和非财务指标, 使用机器学习分类方法构建信用评估模型, 并对几种方法的分类准确率进行了比较分析. 实验结果表明, 该信用评估指标体系可行, 随机森林方法在该指标体系上的分类效果最好. 同时, 优化了分类效果较差的多层感知器, 提升了分类准确率.

[关键词] 企业信用评估, 信用指标体系, 信用评估模型

[中图分类号] F832.4 [文献标志码] A [文章编号] 1672-1292(2020)03-0081-06

## Research on the Index System and Evaluation Model of Enterprise Credit Evaluation

Zhu Jingjie, Wu Huaigang

(School of Computer Science and Technology, Nanjing Normal University, Nanjing 210023, China)

**Abstract:** As for enterprise credit evaluation, this paper introduces financial indexes and non-financial indexes based on previous research. Machine learning classification methods are used to build credit evaluation models, and the classification accuracy rates of several methods are compared and analyzed. The experimental results show that the credit evaluation index system is feasible, and that the random forest method has the best classification effect on the index system. At the same time, the multi-layer perceptron with poor classification effect is optimized, and the classification accuracy is improved.

**Key words:** enterprise credit evaluation, credit index system, credit evaluation model

企业信用评估一直是金融领域的热点问题, 备受学术界和社会的关注. 对企业信用进行有效评估可缓解企业与银行之间的信息不对称问题, 使银行更好地了解企业状况, 降低银行的借贷风险和信贷成本, 增强银行的贷款意愿. 同时, 信用评估也有利于加强企业自身的信用管理, 改善经营状况, 树立更良好的信誉形象, 为自身带来更多的融资机会, 缓解融资难的问题.

对企业信用进行评估通常从两方面入手, 一是企业指标体系, 二是信用评估模型. 在指标体系上, 学者们一直在探索如何引入更有效的评估指标. 最初, 大多数研究只着重考虑财务指标, 如偿债能力、盈利能力等<sup>[1-5]</sup>, 后来学者们发现引入非财务指标能更有效地评估企业信用, 如企业管理水平、管理者个人信用<sup>[6]</sup>、宏观经济因素<sup>[7-8]</sup>、对外担保<sup>[9-10]</sup>等. 在周全考虑诸多影响因素的同时, 为了消除指标之间的多重共线性, 学者们运用逐步回归<sup>[11]</sup>、主成分分析<sup>[12]</sup>、聚类分析<sup>[13]</sup>等方法对指标进行筛选.

在评估模型上, 不少学者运用层次分析法<sup>[14-16]</sup>、熵权法<sup>[17]</sup>、模糊数学<sup>[18]</sup>等方法对评估指标的权重进行设计. 近些年来, 随着人工智能的飞速发展, 神经网络、支持向量机<sup>[19]</sup>、决策树<sup>[20]</sup>、随机森林<sup>[21]</sup>等方法被用于信用评估中. Odom 等<sup>[22]</sup>最先将神经网络应用于银行信用评估. 接着, 学者们不断对神经网络算法进行优化, 如叶夏菁<sup>[23]</sup>将 BP 神经网络与半监督学习结合, 用于信用评估模型. 然而神经网络模型也存在一些缺点, 如网络结构难以确定、模型属于黑箱操作, 其科学性常遭质疑<sup>[24]</sup>. Baesens 等<sup>[25]</sup>在 2003 年将支持向量机方法运用到信用评价中. 支持向量机从结构风险最小原理出发, 克服了人工神经网络的过拟合问题<sup>[26]</sup>. 肖斌卿等<sup>[27]</sup>认为在企业信用评估上, 支持向量机具有明显的优势. 赵亚等<sup>[28]</sup>认为单个模型存在

过拟合问题,而随机森林能有效地改善此缺点,适合解决信用评估问题. 还有一些学者采用多分类器集成,即将多个单一分类模型的结果集成,取得了较好的评估效果<sup>[29-31]</sup>.

本文在构建企业信用指标体系时,基于已有的研究,初步选取偿债能力、发展能力、经营能力、盈利能力、风险水平、现金流等财务指标,同时引入企业对外担保情况、企业主受教育水平、企业主政治背景等非财务情况进行分析,构建初步的企业信用评估指标体系,如表 1 所示,并采用相关性分析和因子分析法对指标进行筛选,消除指标之间的多重共线性.

表 1 初步的企业信用评估指标体系  
Table 1 Initial enterprise credit evaluation index system

指标	一级指标	二级指标
财务指标	偿债能力	流动比率、速动比率、现金比率、利息保障倍数、资产负债率、长期资本负债率、有形资产负债率
	发展能力	资本保值增值率、资本积累率、固定资产增长率、总资产增长率、净利润增长率、可持续增长率、营业总成本增长率
	盈利能力	资产报酬率、流动资产净利润率、固定资产净利润率、净资产收益率、营业净利率、总营业成本率
	经营能力	应收账款周转率、存货周转率、营运资金周转率、流动资产周转率、固定资产周转率、总资产周转率
	风险水平	财务杠杆、经营杠杆
非财务指标	现金流分析	净利润现金净含量、营业收入现金含量、营业利润现金净含量
	对外担保情况	担保期限、实际担保金额
	企业高管学历 政府相关部门任职情况	1=中专及中专以下,2=大专,3=本科,4=硕士研究生,5=博士研究生,6=其他 1=有任职,2=无任职

本文采用机器学习方法构建企业信用评估模型,并对几种不同的分类方法进行比较.

## 1 企业信用评估模型

本文选取 Logistic 回归、多层感知器、支持向量机、决策树、随机森林和 AdaBoost 等机器学习方法构建企业信用评估模型,并比较其性能.

(1) Logistic 回归: Logistic 回归是一种广义的线性回归分析模型,其形式为  $w'x+b$ , 其中,  $w$  和  $b$  为待求参数. Logistic 回归通过函数  $L$  将  $w'x+b$  对应到一个隐状态  $p, p=L(w'x+b)$ , 然后根据  $p$  与  $1-p$  的大小决定因变量的值.

(2) 多层感知器: 多层感知器是一种前馈人工神经网络模型,其第一层为输入层,最后一层为输出层,中间层为隐藏层. 多层感知器未规定隐藏层的数量,可根据需求选择合适的隐藏层层数,且对输出层神经元的个数也无限制.

(3) 随机梯度下降法(SGD): 随机梯度下降法在计算下降最快的方向时随机选一个数据进行计算,无需训练所有的样本,加快了迭代速度.

(4) 序列最小优化算法(SMO): SMO 算法将原二次规划问题分解为只有两个变量的二次规划子问题,将一个复杂的优化算法转化为一个比较简单的两变量优化问题.

(5) 决策树: 决策树是一种树形结构,每个内部节点表示一个属性上的判断,每个分支代表一个判断结果的输出,每个叶节点代表一种分类结果.

(6) 随机森林: 随机森林利用多棵决策树对样本进行训练并预测.

(7) AdaBoost: AdaBoost 将多个弱分类器进行整合,构成一个更强的分类器.

## 2 实验设置

本文的样本数据来自国泰安数据库. 因公开数据库中可获取的非财务指标样本较为有限,相关数据存在较大程度的缺失,为保证实验数据的真实性,本文最终选取了 103 家企业 2018 年 12 月的财务和非财务数据及其违约情况,其中,违约企业 9 家,正常企业 94 家. 为了消除指标单位和量纲的影响,本文对指标进行均值-方差标准化处理,消除不同指标在单位、量纲上的差异影响.

### 2.1 信用评估指标体系构建

由于评估指标较多,指标间可能存在较大的相关性和共线性,因此,本文先对指标体系进行相关性检验,初步剔除相关性较强的指标,再进行因子分析,筛选出贡献率较大的指标,作为最终的评估指标.

本文采用 SPSS 22 软件检验指标之间的相关性,将显著相关且相关系数大于 0.5 的指标剔除,初步消除相关性较强的指标变量. 筛选后的指标体系如表 2 所示.

采用相关性检验初步剔除存在强相关的指标后,进一步采用因子分析法进行指标筛选,提取出特征值较大的指标,从而达到消除多重共线性的目的.

本文用 SPSS 22 软件对相关性分析后的指标数据进行因子分析,得到如表 3 所示的总方差解释和如图 1 所示的碎石图. 由表 3 可以看出,前 10 个因子的特征根值大于 1,包含了所有原始变量 72%的信息,本文选择这 10 个主成分作为公共因子. 从图 1 也可看出,前 10 个因子较大地保留了原有数据的主要信息.

表 2 相关性筛选后的指标体系

一级指标	二级指标
偿债能力	流动比率、利息保障倍数、资产负债率
发展能力	固定资产增长率、总资产增长率、可持续增长率、营业总成本增长率
盈利能力	资产报酬率、净资产收益率、营业净利率、营业成本率
经营能力	应收账款周转率、存货周转率、营运资金周转率、固定资产周转率、总资产周转率
风险水平	财务杠杆、经营杠杆
现金流分析	净利润现金净含量、营业收入现金含量、营业利润现金净含量
对外担保情况	担保期限、实际担保金额
企业高管学历	1=中专及中专以下,2=大专,3=本科,4=硕士研究生,5=博士研究生,6=其他
政府任职情况	1=有任职,2=无任职

表 3 总方差解释

Table 3 Total variance explanation

成分	起始特征值			提取平方和载入			循环平方和载入		
	总计	方差解释率/%	累加/%	总计	方差解释率/%	累加/%	总计	方差解释率/%	累加/%
1	3.873	15.490	15.490	3.873	15.490	15.490	3.579	14.317	14.317
2	2.529	10.118	25.608	2.529	10.118	25.608	2.281	9.126	23.443
3	2.084	8.338	33.946	2.084	8.338	33.946	1.777	7.109	30.552
4	1.702	6.807	40.753	1.702	6.807	40.753	1.732	6.928	37.480
5	1.598	6.393	47.146	1.598	6.393	47.146	1.641	6.565	44.045
6	1.524	6.098	53.244	1.524	6.098	53.244	1.588	6.350	50.395
7	1.341	5.365	58.609	1.341	5.365	58.609	1.463	5.853	56.248
8	1.214	4.855	63.463	1.214	4.855	63.463	1.457	5.829	62.077
9	1.103	4.413	67.876	1.103	4.413	67.876	1.271	5.085	67.162
10	1.022	4.088	71.964	1.022	4.088	71.964	1.200	4.802	71.964
11	0.986	3.945	75.909						
12	0.877	3.509	79.419						
13	0.805	3.222	82.640						
14	0.748	2.992	85.632						
15	0.631	2.525	88.157						
16	0.588	2.351	90.509						
17	0.490	1.959	92.467						
18	0.416	1.665	94.133						
19	0.389	1.558	95.690						
20	0.365	1.460	97.151						
21	0.294	1.176	98.327						
22	0.227	0.908	99.235						
23	0.144	0.577	99.812						
24	0.045	0.179	99.991						
25	0.002	0.009	100.000						

提取方法:主体元件分析.

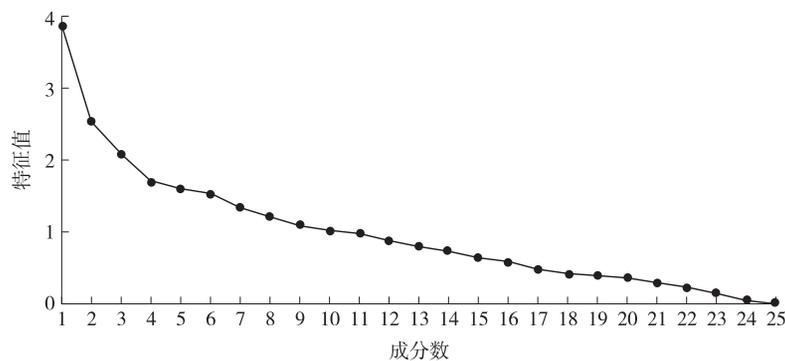


图 1 因子分析的碎石图

Fig. 1 Scree plot of factor analysis

最终根据因子分析的结果可得筛选后的指标体系,如表 4 所示.

表 4 最终的指标体系

Table 4 The final index system

一级指标	二级指标
偿债能力	流动比率、资产负债率
发展能力	固定资产增长率、总资产增长率、可持续增长率、营业总成本增长率
盈利能力	资产报酬率、净资产收益率、营业净利率
经营能力	营运资金周转率、固定资产周转率、总资产周转率
风险水平	财务杠杆
现金流分析	营业收入现金含量、营业利润现金净含量
对外担保情况	担保期限、实际担保金额
企业高管学历	1=中专及中专以下,2=大专,3=本科,4=硕士研究生,5=博士研究生,6=其他
政府任职情况	1=有任职,2=无任职

分别将未进行筛选的指标体系和筛选后的指标体系代入 Logistic 回归、多层感知器、随机最速下降法(SGD)、序列最小优化算法(SMO)、决策树、随机森林和 AdaBoost 等机器学习方法中,采用十折交叉验证法进行分类预测,实验结果如表 5 所示.

表 5 两个指标体系下各分类器的准确率

Table 5 Accuracies of classifiers under different index systems

方法	Logistic	多层感知器	随机最速下降法(SGD)	序列最小优化算法(SMO)	决策树	随机森林	AdaBoost
未经筛选的指标体系下分类准确率/%	83.50	84.47	86.41	89.32	85.44	91.26	92.23
本文构建的指标体系下分类准确率/%	80.60	85.44	88.30	90.30	85.40	91.26	91.26

由表 5 可知,本文构建的指标体系在多层感知器、随机最速下降法(SGD)、序列最小优化算法(SMO)这 3 种分类算法中准确率高于未经筛选的指标体系;在决策树和随机森林分类器中,筛选前后的指标体系分类准确率相同;在 Logistic 和 AdaBoost 分类算法中,本文构建的指标体系准确率略低于未经筛选的指标体系.由此可见,本文构建的指标体系在分类准确率上较优于未经筛选的指标体系,且本文构建的指标体系剔除了冗余指标,更为简洁.

## 2.2 信用评估模型构建

### 2.2.1 不同分类器的实验结果分析

如表 5 所示,以本文构建的指标体系为基础,观察各个分类器的分类准确率可知,随机森林和 AdaBoost 这两种集成学习方法的分类准确率最高,达到 91.26%,其次是 SMO 算法.多层感知器、随机梯度下降法和决策树方法的分类准确率一般,Logistic 回归方法与其他方法相比准确率最低.

ROC 曲线是以真正类率 TPR(true positive rate)为纵坐标、假正类率 FPR(false positive rate)为横坐标绘制的曲线,可以综合反映分类器的准确率.ROC 曲线下的面积就是 AUC 值,AUC 值越大说明分类器的分类效果越好.图 2 给出了几种分类器的 AUC 值,可以看出,随机森林和 AdaBoost 的 AUC 值较高,与其准确

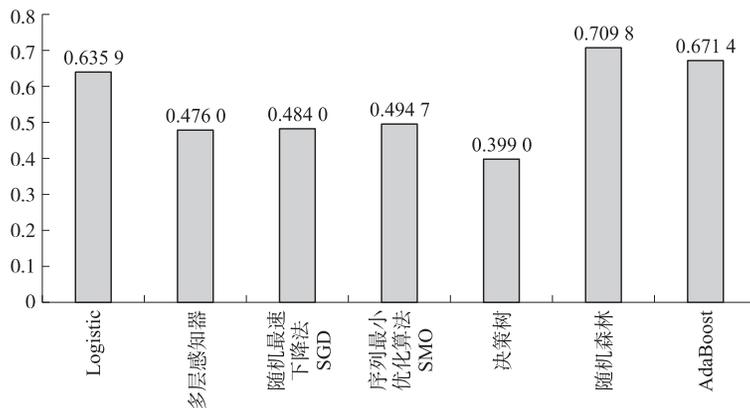


图 2 几种分类器的 AUC 值

Fig. 2 AUC of Classifiers

率较高相一致;随机森林的 AUC 值为 0.709 8,大于 AdaBoost 的 AUC 值 0.671 4,表明随机森林分类器的分类效果最好.虽然 Logistic 回归方法的分类准确率最低,但其 AUC 值为 0.635 9,排名第三,这可能是由于正确率所基于的较佳截断值并不是总体分布中的较佳截断值,AUC 不关注某个截断值的表现如何,而是综合所有截断值的预测性能<sup>[32]</sup>,因此准确率低,AUC 不一定小.综上,随机森林的分类准确率和 AUC 值均最高,因而在本文构建的指标体系上的分类效果最好.

### 2.2.2 多层感知器的优化

表 6 给出了几种模型在相同软件、硬件环境下的运行时间,可知多层感知器的运行时间最长,但其分类效果却一般.对此,本文对多层感知器进行改进和优化,以提高多层感知器在本文样本中的分类性能.本文对多层感知器的隐藏层数和学习率参数进行调整,图 3 给出了不同学习率和隐藏层数下的多层感知器分类准确率.

表 6 几种分类器的运算时间  
Table 6 Operation time of classifiers

方法	Logistic	多层感知器	随机最速下降法 SGD	序列最小优化算法 SMO	决策树	随机森林	AdaBoost
运算时间/s	0.05	0.18	0.05	0.04	0.02	0.09	0.03

根据图 3 的实验结果可知,在对本文的样本进行分类时,当学习率为 0.01 时,多层感知器的分类效果最好,此时隐藏层的个数对分类效果无积极作用,只会延长运算时间.当学习率为 0.02 和 0.03 时,隐藏层数为 1 的分类准确率最高.

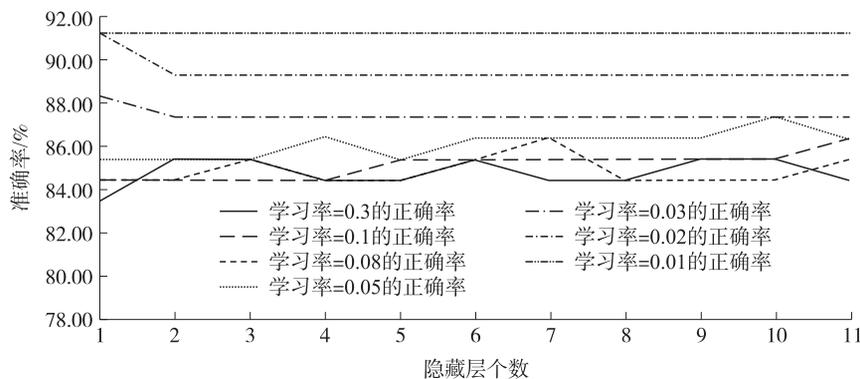


图 3 多层感知器在不同学习率和隐藏层数下的准确率

Fig. 3 Accuracy of multilayer perceptron in different learning rates and hidden layers

## 3 结论

本文综合考虑企业的财务指标和非财务指标,构建了一套较为全面的企业信用评估指标体系,并用相关性检验和因子分析法对指标进行筛选,所构建的指标体系剔除了冗余指标,更为简洁,分类准确率也较高.通过对比几种机器学习分类模型分类准确率和 AUC 值可知,随机森林模型分类效果最佳,其次是 AdaBoost 集成学习方法.对于多层感知器的运算时间最长、分类效果较差的问题,本文对多层感知器进行了优化和改进,得出在学习率为 0.01 时多层感知器的分类准确率最高.

### [参考文献] (References)

- [1] STANDARD & POOR'S. General criteria; principles of credit ratings [EB/OL]. (2011-02-16). [http://www.standardandpoors.com/prot/ratings/articles/en/us/?\\_articleType=HTML&assetID=1245366284668](http://www.standardandpoors.com/prot/ratings/articles/en/us/?_articleType=HTML&assetID=1245366284668).
- [2] MOODY'S. Global business & consumer service industry rating methodology [EB/OL]. (2013-10-13). [https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC\\_127102](https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_127102).
- [3] MOODY'S. Global retail industry [EB/OL]. (2011-06-30). [https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC\\_133476](https://www.moodys.com/researchdocumentcontentpage.aspx?docid=PBC_133476).
- [4] MOODY'S. Global software industry [EB/OL]. (2012-10-09). <https://www.moodys.com/researchdocumentcontentpage>.

- aspx? docid=PBC\_142367.
- [5] 王丽英. 关于印发《中国建设银行小企业客户债信评级办法》的通知:建总发[2009]101号[R]. 北京:中国建设银行,2009.
- [6] 赵亚,李田,苑泽明. 基于随机森林的企业信用风险评估模型研究[J]. 财会通讯,2017(29):110-114.
- [7] 曹裕,陈霞,刘小静. 违约距离视角下的开发性金融信用风险评估[J]. 财经理论与实践,2017,38(209):14-19.
- [8] 王海峰,张晓妮,石宝峰. 基于模糊聚类的P2P网贷个人信用评估模型及应用[J]. 浙江金融,2017(10):19-26.
- [9] 王克敏,罗艳梅. 中国上市公司对外担保与财务困境研究[J]. 吉林大学社会科学学报,2006,46(5):106-113.
- [10] 王楚萱,陶宝山,吴晨. 对外担保会影响商业信用融资吗?[J]. 财会通讯,2018(18):118-122.
- [11] 付永贵,朱建明. 基于大数据的网络供应商信用评估模型[J]. 中央财经大学学报,2016(8):74-83.
- [12] 王凯,黄世祥. 行业内中小企业信用评估模型及应用[J]. 数学的实践与认识,2008,38(4):64-77.
- [13] NIKOLIC N, ZARKIC J N, STOJANOVSKI D, et al. The application of brute force logistic regression to corporate credit scoring models:evidence from Serbian financial statement[J]. Expert Systems with Applications,2013,40(15):5932-5944.
- [14] 陈永明,周龙,李双红. 基 AHP 和 DEMATEL 方法的农户信用评级研究[J]. 征信,2012(5):20-24.
- [15] GUO W, TONG K N, SHAO H Y, et al. Small and medium-sized enterprises multi-service agent credit rating system construction under cloud manufacturing mode based on RS and AHP[J]. Computer Integrated Manufacturing Systems,2013,19(9):2340-2347.
- [16] CHEN W, GAO M, YANG Y. Dynamic credit supervision system of agent construction in public investment project and process design[J]. Advanced Management Science,2013,22(1-2):12.
- [17] 刘骅,张婕. 互联网金融信用风险预警与审计治理策略研究:以江苏省P2P网贷平台为例[J]. 南京财经大学学报,2017(4):59-66.
- [18] 陈晓红,杨志慧. 基于改进模糊综合评价法的信用评估体系研究[J]. 中国管理科学,2015,23(1):146-153.
- [19] 刘京礼,李建平,徐伟宣,等. 信用评估中的鲁棒赋权自适应Lp最小二乘支持向量机方法[J]. 中国管理科学,2010,18(5):28-33.
- [20] 邵蔚. 对P2P平台信用风险的评估与预测:基于决策树模型[J]. 北方经贸,2017(9):103-104.
- [21] 郑杰. 基于随机森林模型的P2P借款人信用评估研究[D]. 哈尔滨:哈尔滨工业大学,2017.
- [22] ODOM M D, SHARDA R. A neural network model for bankruptcy prediction[C]//IJCNN International Joint Conference on Neural Networks. Diego, USA: Browman C P, Goldstein L, 1990:163-168.
- [23] 叶夏菁. 基于BP神经网络与半监督学习的网贷平台信用评估模型[D]. 浙江大学,2015.
- [24] 孙庆文,张琼琼,仇静莉,等. 基于不同信息获取量的赊销决策风险度判别模型[J]. 系统工程理论与实践,2012,32(1):41-48.
- [25] BAESEENS B, GESTEL V T, VIAENE S. Benchmarking state-of-art classification algorithms for credit scoring[J]. Journal of the Operation Research Society,2003,54(6):627-635.
- [26] ZHANG Q, WANG J, LU A G. An improved SMO algorithm for financial credit risk assessment-evidence from China's banking[J]. Neurocomputing,2018,272:314-325.
- [27] 肖斌卿,柏巍,姚瑶,等. 基于LS-SVM的小微企业信用评估研究[J]. 审计与经济研究,2016,31(6):102-111.
- [28] 赵亚,李田,苑泽明. 基于随机森林的企业信用风险评估模型研究[J]. 财会通讯,2017(29):110-114.
- [29] PALEOLOGO G, ELISSEEFF A, ANTONINI G. Subagging for credit scoring models[J]. European Journal of Operational Research,2010,201(2):490-499.
- [30] 肖进,薛书田,黄静,等. 客户信用评估半监督协同训练模型研究[J]. 中国管理科学,2016,24(6):124-130.
- [31] 黄静,薛书田,肖进. 基于半监督学习的客户信用评估集成模型研究[J]. 软科学,2017,31(7):131-134.
- [32] LEGEN D. AUC 越大,正确率就越高?[EB/OL]. (2018-01-15). <https://blog.csdn.net/legendavid/article/details/79063044>.

[责任编辑:严海琳]