

基于 L1 惩罚 Logit 模型的公司财务风险预测与控制^①

许启发^{1,2}, 张可新¹, 蒋翠侠¹

(1. 合肥工业大学管理学院, 合肥 230009;

2. 合肥工业大学 过程优化与智能决策教育部重点实验室, 合肥 230009)

摘要: 将 L1 惩罚 Logit 模型应用于公司财务风险分析, 通过 Logit 模型预测破产概率, 实现对公司财务风险状态预测; 通过 L1 惩罚实现变量选择, 完成对公司财务风险关键影响因素的识别, 有利于风险控制。通过 Monte Carlo 数值模拟, 发现 L1 惩罚 Logit 模型具有比支持向量机更为简单的结构, 通过较少的解释变量就能够获得更为准确的预测效果。结合沪深股市 2005~2014 年 ST 公司与非 ST 公司的财务数据对公司财务风险进行实证分析, 一方面基于混淆矩阵与 ROC 曲线的分类评价结果表明, L1 惩罚 Logit 模型获得了比支持向量机更高的预测精度; 另一方面筛选出的关键影响因素为公司实现风险控制提供了依据。

关键词: 财务风险; L1 惩罚 Logit 模型; 变量选择; 分类效果评价

中图分类号: F224.0 **文献标识码:** A **文章编号:** (2016) 01-0001-09

0 引言

公司财务状况备受多方利益群体的关注, 对公司决策与经营有至关重要的影响, 高效的公司财务风险管理模型显得尤为必要。其有助于公司做到财务风险的预防或及时化解, 提升危机管理的科学性; 有助于借贷者(银行)对贷款公司的评测, 一定程度上避免贷款的高风险; 有助于投资者获得公司财务风险的警示, 从而更好地规避风险; 有助于政府监管部门科学有效地进行市场监管, 维护市场稳健运行。

当前关于财务风险问题的研究很普遍, 其建模技术主要集中在统计分析方法和机器学习方法。统计分析方法主要基于多元判别分析、Logit 回归以及 Bayes 方法等。这类方法发展时间较长, 技术相对成熟, 应用范围也最为广泛。其中最具代表性的 Logit 模型由于预测精度高、计算方法简单、变量解释能力强等特点被国内外研究者广泛关注。吴世农等^[1]应用剖面分析和单变量分析, 选定 6 个财务指标, 应用 Fisher 判定分析、多元线性回归分析和 Logit 回归分析三种方法分别建立三种预测财务困境模型; Philip 等^[2]主张 Logit 回归是全球早期预警系统(early warning system, EWS)和信号识别的最适当方法; 韩立岩等^[3]运用主成分分析与 Logit 回归结合, 建立了国内外中小上市公司财务危机判别模型; 孔宁宁等^[4]基于主成分分析和 Logit 回归对我国制造业上市公司财务危机预警问题进行比较研究; 刘维奇等^[5]使用三因子模型对资本市场资源配置效率进行了检验; 王君萍等^[6]以我国能源上市企业为研究对象, 进行指标选取和运用 Logit 回归构建预警模型。

实际中, 财务风险预测涉及变量众多且相关性大, 包含许多冗余信息, 传统的统计分析方法往往使用全变量分析, 势必影响模型的解释能力以及预测性能, 而作为近年来新兴的风险研究方法——机器学习方法因其可以处理非线性问题, 对数据约束要求不高, 逐渐成为研究热点, 且已有研究者证实

^① 资助项目: 国家社会科学基金一般项目(15BJY008); 教育部人文社会科学研究规划基金项目(14YJA790015); 安徽省哲学社会科学规划基金项目(AHSKY2014D103); 合肥工业大学产业转移与创新发展研究中心招标项目(SK2014A073); 山东省科技发展计划项目(编号2014GGX101055)。

作者简介: 许启发(1975—), 男(汉族), 安徽和县人, 教授、博士生导师, 研究方向: 数量经济理论与方法、金融计量, Email: xuqifa1975@163.com; 张可新(1991—), 男(汉族), 辽宁盘锦人, 硕士, 研究方向: 数量经济理论与方法、风险管理, Email: 965393622@qq.com; 蒋翠侠(1973—), 女(汉族), 安徽砀山人, 副教授、硕士生导师, 研究方向: 金融时间序列分析、金融计量, Email: jiangcuixia@hfut.edu.cn。

此类方法预测准确度高于传统的统计分析方法。其中，杨淑娥等^[7]采用 BP 神经网络建立财务危机预警模型，实证结果表明其相比主成分分析法建立起模型的预测准确度有很大提高；陈诗一^[8]通过实证发现支持向量机方法的预测准确度比 Logit 模型有明显改进，改进幅度大约为 25%；唐建荣等^[9]基于支持向量机构建我国上市公司信用风险评估模型，并通过实证研究得到该方法比多元判别分析更为准确有效。还有很多国内外研究者使用神经网络和支持向量机模型对风险预测问题做了大量研究分析。尤璞等^[10]基于 PCA-BP 神经网络提出上市公司财务预警策略；王宜刚^[11]基于结构化神经网络构建商业银行贷款风险预警模型；Salim 等^[12]运用 BPNN 方法预测股票市场未来走势变化；沈沛龙等^[13]利用支持向量机原理并引入新的违约距离计算方法对企业信用风险进行分级；Chen^[14]基于支持向量机技术提出一种粒子群优化的混合进化方法来预测财务亏损。可以说，以支持向量机为代表的机器学习方法在模型的预测准确度方面已表现得很优越并得到较高的认可度，但其缺点在于模型采用暗箱操作，虽能进行风险预测，但不能识别关键风险因子，对管理者进行风险控制起不到实质性的指导作用。

因此，对于公司财务风险预测与控制建模，变量选择是不可或缺的关键点。以逐步回归为代表的子集变量选择法，需要进行多次重复计算操作，当数据变量众多时，该方法往往就不适用了^[15-16]。方匡南^[17]在研究个人信用评估问题时，引入 L1 惩罚 Logit 模型，该模型兼具变量选择和参数估计两个方面的功能，成功抓住影响消费信用风险的关键因素，而且预测准确度高。本文尝试将 L1 惩罚 Logit 模型应用于公司财务风险分析，通过 Monte Carlo 数值模拟和实证研究证实了 L1 惩罚 Logit 模型具有很好的变量选择与预测功能，不仅能够准确预测公司财务风险，而且能够识别财务风险关键影响因素，可以为公司财务风险控制提供决策依据。

1 模型与方法

1.1 L1 惩罚 Logit 模型

Tibshirani^[18]提出了具有变量选择功能的 Lasso (least absolute shrinkage and selection operator) 方法，其实质是在由残差平方和定义的损失基础上添加惩罚函数，将不显著的回归系数压缩到 0，实现变量选择。在 Lasso 回归中，由于使用了绝对值惩罚（也称 L1 惩罚），惩罚参数越小，模型的惩罚力度就越小，保留的变量就越多；惩罚参数越大，模型的惩罚力度就越大，保留的变量就越少。Lasso 方法主要应用于解决连续型响应变量回归问题，不能直接应用于基于二元离散响应变量决策的公司财务风险问题。为此，可以将 Lasso 思想与 Logit 模型相结合，建立 L1 惩罚 Logit 模型并将其应用于公司财务风险分析。

1.1.1 模型表示与估计

假设有独立同分布的观测值 (X^i, y_i) , $i=1, 2, \dots, n$, 其中 $X^i = (x_{i1}, \dots, x_{ip})$ 和 y_i 分别是模型的解释变量和被解释变量，并且 y_i 是二元离散数据变量，即 $y_i \in \{0, 1\}$ ，则 Logit 模型的条件概率为

$$\log \left\{ \frac{p(y_i=1 | X^i)}{1-p(y_i=1 | X^i)} \right\} = \eta_\beta(X^i) \tag{1}$$

其中， $\eta_\beta(X^i) = \beta_0 + \sum_{j=1}^p x_{ij}\beta_j$, $p(y_i = 1 | X^i) = \frac{1}{1 + e^{-X^i\beta}}$ 。

根据 Lasso 方法的思想，L1 惩罚 Logit 模型中的系数估计值 $\hat{\beta}_\lambda$ 由式 (2) 凸函数的极小值给定：

$$S_\lambda(\beta) = -l(\beta) + \lambda \sum_{j=1}^p |\beta_j| \tag{2}$$

其中， $l(\cdot)$ 是对数似然函数，则式 (2) 中的 $l(\beta)$ 可以写成式 (3)：

$$l(\beta) = \sum_{i=1}^n \{y_i \eta_\beta(X^i) - \log\{1 + \exp[\eta_\beta(X^i)]\}\} \tag{3}$$

则 L1 惩罚 Logit 模型中的系数估计值 $\hat{\beta}$ 可写成如式 (4) 所示形式：

$$\hat{\beta} = \operatorname{argmax}_\beta \sum_{i=1}^n \{y_i \eta_\beta(X^i) - \log\{1 + \exp[\eta_\beta(X^i)]\}\} + \lambda \sum_{j=1}^p |\beta_j| \tag{4}$$

1.1.2 惩罚参数选择

L1 惩罚 Logit 模型的变量选择，其关键在于惩罚参数 λ 的选取，常用方法有 Bootstrap、交叉验证、广义交叉验证 (generalized cross validation) 等，本文采用广义交叉验证方法确定惩罚参数 λ 的值，其具体算法如下：

若令 $p(\lambda) = \text{tr} \{X(X^T X + \lambda(\text{diag}(|\hat{\beta}_1|, \dots, |\hat{\beta}_p|))^{-1})^{-1} X^T\}$ ，可定义广义交叉验证统计量为

$$\text{GCV}(\lambda) = \frac{\|y - X\hat{\beta}(\lambda)\|^2}{n \{1 - p(\lambda)/n\}^2} \quad (5)$$

显然，使 GCV 取值达到最小的惩罚参数为最优的惩罚参数 λ ，则最优 λ 的估计值为

$$\hat{\lambda} = \underset{\lambda}{\text{argmin}} \text{GCV}(\lambda) \quad (6)$$

1.2 分类效果评价

1.2.1 混淆矩阵

混淆矩阵能直观清楚地分析出预测模型的准确率，在本文的分类问题中，预测的情形存在四种，相应的判断矩阵如表 1 所示。

表 1 混淆矩阵

Table 1 Confusion matrix

真实类	预测类	
	非 ST	ST
非 ST	a	b
ST	c	d

从该判断矩阵中可以看出，在样本集中共有 $a+b$ 家非 ST 公司，其中 a 家公司被正确的判定为非 ST， b 家公司被错误的判定为 ST (即第 II 类错误，纳伪)；另外，样本集中共有 $c+d$ 家 ST 公司，其中 c 家公司被错误的判定为非 ST (即第 I 类错误，弃真)， d 家公司被正确的判定为 ST。所以，通过判断矩阵能够容易且快速的得出一个模型的预测准确度，即 $(a+d)/(a+b+c+d)$ ，以及第 I 类错误率 $c/(c+d)$ 和第 II 类错误率 $b/(a+b)$ 。

1.2.2 ROC 曲线

ROC 曲线是根据截断值的变化而绘制出的一条曲线。每一个截断值对应于曲线上的一个点，其纵坐标为真阳性率 (模型将 ST 公司正确的判定为 ST 的概率)，横坐标为假阳性率 (模型将正常公司错误的判定为 ST 的概率)。理想模型的 ROC 曲线为从 (0, 0) 到 (0, 1) 再到 (1, 1) 的一条折线段。鉴于两个模型，性能优者的 ROC 曲线更接近左上角。

一个模型的预测准确度也可以通过 ROC 曲线下区域的面积经过计算获得

$$\text{Acc} = 2 \times (S_{\text{ROC}} - 0.5) \quad (7)$$

2 数值模拟

2.1 数据生成

考虑解释变量 x 与响应变量 y ，设计如下的数据生成过程：

$$y_i^* = \beta_0 + \beta_1 x_{1i} + \dots + \beta_p x_{pi} + \sigma \varepsilon_i \quad (8)$$

$$y_i^* \geq 0 \text{ 时, } y_i = 1; \text{ 否则 } y_i = 0$$

其中， σ 取 1； p 取 10， x_p 为在 $[-5, 5]$ 上均匀产生的 10 个随机数；取 $\beta_0 = 1, \beta_1 = 2, \beta_2 = -1, \beta_3 = 0, \beta_4 = 0, \beta_5 = 5, \beta_6 = \dots = \beta_{10} = 0$ ； ε_i 为随机扰动项，本文对 ε_i 设计了三种不同的分布形式： $N(0, 1)$ 、 $t(3)$ 和 $\chi^2(3)$ ，分别与正常形态、厚尾形态和有偏形态相对应，检验模型对不同数据类型的适应能力。

2.2 结果分析

在 Monte Carlo 数值模拟实验中，样本类型为三种，与三种分布类型对应，样本量均为 200；变量个数

均为 10。使用 L1 惩罚 Logit 模型分别对三种类型数据样本进行财务风险分析。一方面, 通过 L1 惩罚分别对三类样本进行变量选择, 观察变量选择效果; 另一方面, 分别对三类样本计算破产概率预测, 并与支持向量机模型进行比较, 考察其预测性能。

2.2.1 变量选择效果

使用 L1 惩罚 Logit 模型对三类数据样本分别进行变量选择, 每类样本重复实验 100 次。从变量选择准确率 (0 系数变量被估计为 0 系数、非 0 系数变量被估计为非 0 系数的个数和与总变量个数之比) 的均值来考察模型的变量选择效果, 结果如表 2 所示。另外, 表 2 还给出各类样本其中一次实验得到的最优惩罚参数 λ , 以及此时模型所选变量及其估计系数。可以看出, L1 惩罚 Logit 模型对各类数据样本均有较好的变量选择效果, 并且可以获取筛选出的指标变量名称及其对应的估计系数。

表 2 变量选择
Table 2 Variable selection

样本类型	λ 对数值	所选变量	估计系数	变量选择准确率均值 (%)
$N(0, 1)$	-6.2621	x_1	0.6264	73.9
		x_2	-0.2668	
		x_3	0.0307	
		x_5	2.0023	
		x_7	0.2334	
$t(3)$	-4.6906	x_1	0.3484	75.0
		x_2	-0.2178	
		x_5	1.2905	
		x_8	-0.0214	
$\chi^2(3)$	-5.1224	x_1	0.3993	73.2
		x_3	0.0147	
		x_5	0.8886	
		x_7	0.0020	

2.2.2 预测能力比较

为进一步考察 L1 惩罚 Logit 模型的预测性能, 将其与在财务风险预测问题中已表现极为优越的支持向量机模型进行比较。将每一类型样本一分为二, 分别得到: 样本量为 100 的训练样本和样本量为 100 的测试样本。使用两种模型分别进行财务风险状态预测, 重复实验 100 次。从区分力 (预测准确度的均值) 和稳定性 (预测准确度的标准差) 对财务风险预测能力进行比较, 结果如表 3 所示, 可以看出 L1 惩罚 Logit 模型在三种样本类型上的预测准确度均高于支持向量机模型, 且更小的标准差表明其预测稳定性更好, 数值模拟显示了 L1 惩罚 Logit 模型在财务风险预测问题中的优越性能。

表 3 两模型预测能力对比
Table 3 Comparison of prediction ability

样本类型	支持向量机		L1 惩罚 Logit	
	均值	标准差	均值	标准差
$N(0, 1)$	0.9435	0.0283	0.9609	0.0214
$t(3)$	0.9422	0.0238	0.9526	0.0235
$\chi^2(3)$	0.9307	0.0255	0.9398	0.0246

3 应用研究

3.1 样本和指标选取

本文实证研究数据取自国泰安数据库 (www.gtarsc.com)，以沪深股市上市公司为研究对象，研究其财务风险预测与控制问题。整个样本由两类公司组成：代表出现财务风险的 ST 公司与代表未出现财务风险的非 ST 公司。ST 公司为 2005 ~ 2014 年因出现财务亏损满两年及以上而首次被特殊处理的共计 247 家企业，按样本中 ST 公司与非 ST 公司 1 : 2 的数量比，在相同时间段运营良好的公司（除金融类公司外）中随机选取 494 家企业作为样本中的非 ST 公司。其中，2005 ~ 2011 年共 7 年的 169 家 ST 公司和 338 家非 ST 公司组成训练样本，2011 ~ 2014 年这 3 年间的 78 家 ST 公司和 156 家非 ST 公司组成测试样本。

上市公司在第 T 年是否被特别处理，将由其第 $T-1$ 年公布的财务报告所决定，因此根据第 $T-1$ 年的财务数据进行预测势必会高估分类器的预测性能，在实际财务风险预测中的应用价值也不大。本文选取被特别处理的上市公司均出现财务亏损满两年及以上，即第 T 年被特别处理的公司第 $T-2$ 年就出现了财务亏损，而且公司第 $T-2$ 年的财务数据对于诊断公司未来发展也起到至关重要的作用。因此，本文选取第 $T-2$ 年财务数据来进行实证研究，即 2005 年 ST 和非 ST 公司的数据取自公司 2003 年的财务报表；2006 年 ST 和非 ST 公司的数据取自公司 2004 年的财务报表；其他的以此类推。

在指标选取方面，考虑综合反映上市公司盈利能力、偿债能力、成长能力、营运能力、现金流量和资本结构等变量因素共选取 34 个财务指标（见表 4）。

表 4 财务指标及代号

Table 4 Financial index with number

代号	财务指标	代号	财务指标
x_1	每股收益	x_{18}	总资产增长率
x_2	每股净资产	x_{19}	存货周转率
x_3	每股净资产增长率	x_{20}	应收账款周转率
x_4	净资产收益率	x_{21}	流动资产周转率
x_5	净资产收益率增长率	x_{22}	股东权益周转率
x_6	资产报酬率	x_{23}	总资产周转率
x_7	总资产净利润率	x_{24}	营业收入现金净含量
x_8	息税前利润	x_{25}	全部现金回收率
x_9	净利润与利润总额比	x_{26}	资产负债率
x_{10}	流动资产比率	x_{27}	权益乘数
x_{11}	流动负债比率	x_{28}	主营业务利润占比
x_{12}	产权比率	x_{29}	利息保障倍数
x_{13}	经营活动产生的现金流量净额/负债合计	x_{30}	股东权益对固定资产比
x_{14}	经营活动产生的现金流量净额/带息债务	x_{31}	固定资产周转率
x_{15}	经营负债比率	x_{32}	固定资产比率
x_{16}	营业利润增长率	x_{33}	留存收益资产比
x_{17}	净利润增长率	x_{34}	营运资金比率

3.2 实证结果及分析

3.2.1 模型估计

首先，使用 L1 惩罚 Logit 模型，通过广义交叉验证，得到图 1 所示的 λ 选择图。图 1 中，横坐标为惩罚参数 λ 的对数值，纵坐标为模型偏差，并在图 1 最上方给出 λ 不同取值相对应筛选出来的变量数。

图 1 中有两条虚线, Tibshirani^[18]认为在这两条虚线间的 λ 取值对应的模型偏差波动幅度很小, 左侧虚线对应使得模型偏差最小的 λ , 但根据 Tibshirani 的取值经验, 在模型偏差相差不大的基础上, 尽量获得相对比较重要的变量, 使压缩程度获得最大, 即获得的变量数目尽量少。为此, 本文选取图 1 中右侧虚线对应的 λ 值, 即 $\log(\lambda) = -4.4088$ 。此时模型解释变量系数有 5 个不为 0, 即模型选择出 5 个有效的预测财务指标 (见表 5), 它们构成最优的变量子集, 分别对应财务指标是每股收益、每股净资产、总资产净利润率、全部现金回收率、主营业务利润占比。

表 5 选择出的指标变量

Table 5 The selected variables and regression coefficients

指标代号	指标名称	变量系数值
x_1	每股收益	-0.5789
x_2	每股净资产	-0.0018
x_7	总资产净利润率	-14.8665
x_{25}	全部现金回收率	-0.3133
x_{28}	主营业务利润占比	-0.0080

表 5 还给出, 各指标变量对应的系数值均为负, 所以管理者可以通过适当促进这 5 个财务指标的增长在一定程度上降低财务风险发生的概率; 另外, 总资产净利润率对应的变量系数绝对值最大且大很多, 然后依次是每股收益、全部现金回收率、主营业务利润占比和每股净资产, 所以总资产净利润率对财务风险的影响效果最为明显, 管理者可以集中主要精力来提高总资产净利润率, 从而达到有效控制规避财务风险。




图 1 λ 选择图

Fig. 1 The process of the choice of λ

3.2.2 模型准确度比较

实证研究同样使用具有优越预测性能的支持向量机模型进行财务风险预测, 与本文模型进行比较。表 6 给出了支持向量机与 L1 惩罚 Logit 两个模型预测得到的混淆矩阵, 并根据混淆矩阵计算出来的预测准确度、第 I 类错误率和第 II 类错误率等评价指标。由表 6 可知, 无论从模型的预测准确度还是出现第 I 类错误率或者第 II 类错误率来考量, L1 惩罚 Logit 模型的预测结果均优于支持向量机模型。再从图 2 所示的两模型 ROC 曲线可以看出, L1 惩罚 Logit 模型的 ROC 曲线更接近左上角, 表现出更好的预测效果。究其原因在于: 财务指标变量间的相关性较大, L1 惩罚 Logit 模型通过变量选择功能, 将一些干扰变量的系数压缩为 0, 避免了一些冗余信息的干扰, 提升了模型的预测性能。

表 6 两模型预测结果对比

Table 6 Comparison of prediction results

模型	混淆矩阵	预测准确度	第 I 类错误率	第 II 类错误率
支持向量机模型	预测类 真实类 0 1 0 146 10 1 22 56	86.32%	28.21%	6.41%
L1 惩罚 Logit 模型	预测类 真实类 0 1 0 154 2 1 21 57	90.17%	26.92%	1.28%




图 2 两模型 ROC 曲线对比图

Fig. 2 Comparison of ROC curves

4 结论与启示

本文将 L1 惩罚 Logit 模型应用到公司财务风险分析中，通过 Monte Carlo 数值模拟验证了其变量选择与预测功能。以沪深两市 ST 公司与非 ST 公司为研究对象进行实证研究，得到了如下结论：第一，L1 惩罚 Logit 模型克服了传统 Logit 模型可能存在多重共线性问题以及支持向量机模型暗箱操作的弊端，增强了模型的解释性，通过变量选择功能识别出影响公司财务风险的关键指标，依据模型估计变量系数的正负来抑制或是促进相应财务指标以完成对风险的有效控制；第二，无论是预测准确度还是第 I、II 类错误率，L1 惩罚 Logit 模型的性能均优于支持向量机模型，而且前者的预测准确度超过了 90%，第 II 类错误率更是控制在 1.28% 的极佳水平。

总之，使用 L1 惩罚 Logit 模型对公司财务风险进行预测与控制，不仅能够对公司财务风险做到准确的预测，而且可以更加科学地抓住影响公司财务风险的关键指标，明确未来调整方向，提高公司财务风险控制工作的科学性和有效性。

参考文献：

[1] 吴世农, 卢贤义. 我国上市公司财务困境的预测模型研究 [J]. 经济研究, 2001, (6): 46-55.

Wu, S., X. Lu. A Study of models for predicting financial distress in China's listed companies [J]. *Economic Research Journal*, 2001, (6): 46-55. (in Chinese)

- [2] Philip D, Dilruba K. Comparing early warning systems for banking crisis [J]. *Journal of Financial Stability*, 2008, 4 (2): 89-120.
- [3] 韩立岩, 李蕾. 中小上市公司财务危机判别模型研究 [J]. *数量经济技术经济研究*, 2010, (8): 102-115.
Han, L., L. Li. On the model of financial crisis discrimination for the small and medium sized listed companies [J]. *The Journal of Quantitative & Technical Economics*, 2010, (8): 102-115. (in Chinese)
- [4] 孔宁宁, 魏韶巍. 基于主成分分析和 Logistic 回归方法的财务预警模型比较 [J]. *经济问题*, 2010, (6): 112-116.
Kong, N., S. Wei. Comparison of financial early-warning model constructed based on principal component analysis and logistic regression [J]. *Economic Problems*, 2010, (6): 112-116. (in Chinese)
- [5] 刘维奇, 牛晋霞, 张信东. 股权分置改革与资本市场效率——基于三因子模型的实证检验 [J]. *会计研究*, 2010, (3): 65-72.
Liu, W., J. Niu, Zhang X. Impact of split-share structure reform upon capital market validity: An empirical study based on three-factor model [J]. *Accounting Research*, 2010, (3): 65-72. (in Chinese)
- [6] 王君萍, 白琼琼. 我国能源上市企业财务危机预警研究 [J]. *经济问题*, 2015, (1): 109-113.
Wang, J., Q. Bai. Financial crisis early-warning of China's energy listed companies [J]. *Economic Problems*, 2015, (1): 109-113. (in Chinese)
- [7] 杨淑娥, 黄礼. 基于 BP 神经网络的上市公司财务预警模型 [J]. *系统工程理论与实践*, 2005, 25 (1): 12-18.
Yang, S., L. Huang. Financial crisis warning model based on BP neural network [J]. *Systems Engineering-theory and Practice*, 2005, 25 (1): 12-18. (in Chinese)
- [8] 陈诗一. 德国公司违约概率预测及其对我国信用风险管理的启示 [J]. *金融研究*, 2008, (8): 58-70.
Chen, S. Default probability prediction in Germany and its revelation for crediting-risk management in China [J]. *Journal of Financial Research*, 2008, (8): 58-70. (in Chinese)
- [9] 唐建荣, 谭春晖. 基于支持向量机的上市公司信用风险评估研究 [J]. *统计与决策*, 2010, (10): 65-67.
Tang, J., C. Tan. Research of evaluating credit-risk in listed corporations based on SVM [J]. *Statistics and Decision*, 2010, (10): 65-67. (in Chinese)
- [10] 尤璞, 武戈. 基于 PCA-BP 神经网络的上市公司财务预警策略 [J]. *统计与决策*, 2012, (22): 181-183.
Long, P., G. Wu. Early warning strategies of financial in listed corporations based on PCA-BP neural network [J]. *Statistics and Decision*, 2012, (22): 181-183. (in Chinese)
- [11] 王宜刚. 基于结构化神经网络的贷款风险预警方法 [J]. *统计与决策*, 2012, (15): 53-55.
Wang, Y. Early warning method of loan-risk based on structured neural network [J]. *Statistics and Decision*, 2012, (15): 53-55. (in Chinese)
- [12] Salim L., Mounir B. A supervised classification system of financial data based on wavelet packet and neural networks [J]. *International Journal of Strategic Decision Sciences*, 2013, 4 (4): 72-84.
- [13] 沈沛龙, 周浩. 基于支持向量机理论的中小企业信用风险预测研究 [J]. *国际金融研究*, 2010, (8): 77-85.
Shen, P., H. Zhou. Research of predicting credit-risk for small and medium-sized enterprises based on SVM [J]. *Studies of International Finance*, 2010, (8): 77-85. (in Chinese)
- [14] Chen M. Using a hybrid evolution approach to forecast financial failures for Taiwan-listed companies [J]. *Quantitative Finance*, 2014, 14 (6): 1047-1058.
- [15] Breiman L. Better subset regression using the nonnegative garrote [J]. *Technometrics*, 1995, 4 (37): 373-384.
- [16] 孙燕. 随机效应 Logit 计量模型的自适应 Lasso 变量选择方法研究 [J]. *数量经济技术经济研究*, 2012, (12): 147-157.
Sun, Y. Variable selection via adaptive lasso for random effect logit model [J]. *The Journal of Quantitative and Technical Economics*, 2012, (12): 147-157. (in Chinese)
- [17] 方匡南, 章贵军, 张惠颖. 基于 Lasso-logistic 模型的个人信用风险预警方法 [J]. *数量经济技术经济研究*, 2014, (2): 125-136.
Fang, K., G. Zhang, H. Zhang. Individual credit risk prediction method: Application of a lasso-logistic model [J]. *The Journal of Quantitative and Technical Economics*, 2014, (2): 125-136. (in Chinese)
- [18] Tibshirani R. Regression shrinkage and selection via the Lasso [J]. *Journal of the Royal Statistical Society*, 1996, 1 (58): 267-288.

Forecasting and Control of Company's Financial Risk via L1-penalty Logit Model

Xu Qifa^{1,2}, *Zhang Kexin*¹, *Jiang Cuixia*¹

1. School of Management, Hefei University of Technology, Hefei 230009, China;
2. Key Laboratory of Process Optimization and Intelligent Decision-making, Ministry of Education, Hefei 230009, China

Abstract: We applied the L1-penalty Logit model to the company's financial risk analysis. The advantages of the model lied in two aspects. First, the model was able to judge the company's financial risk status by bankruptcy probability prediction in the binary Logit analysis. Second, the model enabled us to identify the key factors that affect the company's financial risk through variable selection in L1-penalty term, which was helpful for risk control. The Monte Carlo simulations showed that the L1-penalty Logit model could obtain higher accuracy of prediction than the classical support vector machine (SVM) with less explanatory variables or simpler model structure. In addition, we conducted an empirical analysis on financial data of the ST and non-ST companies in Chinese stock market from 2005 to 2014. The empirical findings also showed that the prediction accuracy of L1-penalty Logit model was higher compared to the SVM through confusion matrix and ROC curve. Moreover, those key factors selected by the L1-penalty Logit model provided a basis for controlling company's financial risk.

Key words: Financial Risk; L1-penalty Logit Model; Variable Selection; Classification Effect Evaluation