

基于 LM 算法 BP 神经网络的 审计重大错报风险识别

王翠琳 何其恩

(兰州理工大学经济管理学院 兰州 730050)

【摘要】 本文根据 1998~2009 年期间,证监会、深交所、上交所公布的财务舞弊违规处罚意见,参照 2006 年 1211 号审计准则的规定构建了涵盖持续经营能力、融资能力、营运能力、重大关联交易、关键人员变动、内部控制环境等因素的重大错报风险识别模型。通过与 Logistic 算法重大错报风险识别模型预测结果进行对比,发现基于 LM 算法 BP 神经网络重大错报风险识别模型具备较高的识别准确率,具有更强的实用性。

【关键词】 重大错报风险 BP 神经网络 LM 算法

我国自 2007 年起实施的新审计风险模型相对于传统审计风险模型更加注重对风险的识别和评估,且贯穿于整个审计业务过程中。所以,新模型应用的重难点在于重大错报风险的识别和评估。重大错报风险的识别和评估是提高审计效率、保证审计效果的重中之重。

对财务舞弊风险识别、评估的研究,一方面集中于以神经网络作为准确率较高的模拟仿真工具,对被审计单位各种舞弊行为进行测度。典型代表有:Odom(1990)最早把神经网络应用于财务危机预警研究,以公司财务危机前一年的五个财务比率为研究变量,将 BP 神经网络和传统多元识别分析方法进行比较,分析显示 BP 神经网络预测能力更好。Lin、Hwang 和 Becker(2003)融合模糊回归、神经网络等方法,构建基于模糊神经网络的财务舞弊识别模型,研究表明该模型为审计人员提供了准确、高效的舞弊分析方法。田金玉、聂丹丹(2008)结合主成分分析和 BP 神经网络建立会计舞弊识别模型,证明该模型是一种具有现实可操作性且识别率较高的财务舞弊识别方法。

另一方面,学者们研究的是针对重大错报风险识别模型的构建。典型代表有:汪国平(2006)从宏观、行业和微观三种视角下构建重大错报风险识别模型,以权重为依据评估重大错报风险水平,但该分析只针对总体层次水平,未对指标设计做进一步解释。王翠琳(2008),邹晶、欧阳程(2007)等学者采用模糊数学、对偶价值度量三角法、沃尔评分法等方法进行重大错报风险识别和评估的应用研究。

以上学者的相关研究为本文撰写提供了坚实的基础,为重大错报风险的量化提供了许多方法。本文将 BP 神经网络法应用于重大错报风险的识别,并尝试用 LM 算法进一步提高其识别效率,以期为注册会计师识别被审计单位重大错报风险提供一个实用性较强的分析工具。

一、数据选取及变量设置

1. 样本选取。本文选择 1998~2009 年间 76 个因财务报

告舞弊违规而被证监会、深交所、上交所公开处罚的上市公司作为高重大错报风险样本,同时按 1:1 的比例,选择与高重大错报风险样本同会计期间、同行业、同规模且无财务舞弊违规处罚意见的 A 股上市公司,作为低重大错报风险样本。

2. 自变量选取。本文依据新审计准则 1211 号第 98 条规定,从在严厉、复杂的监管环境开展业务、持续经营和资产流动性出现问题、融资能力受到限制、重大的关联方交易、关键人员变动、内部控制薄弱、重大的非常规交易指标六个方面,选取易量化、易获得的 24 个财务指标作为实证研究的自变量和重大错报风险识别模型的输入变量。

(1)持续经营能力和融资能力:①偿债能力:X1 代表流动比率、X2 代表速动比率、X3 代表资产负债率、X4 代表利息保障倍数;②成长能力:X5 代表营业收入增长率、X6 代表净利润增长率;③盈利能力:X7 代表资产报酬率、X8 代表净资产收益率、X9 代表总资产净利润率、X10 代表每股收益。

(2)资产流动性:X11 代表流动资产周转率、X12 代表总资产周转率、X13 代表应收账款周转率。

(3)重大关联交易:X14 代表关联购销比率、X15 代表对外担保比率。

(4)关键人员变动:X16 代表高管更迭。

(5)在严厉、复杂的监管环境开展业务:X17 代表是否为国有控股。

(6)内部控制环境:X18 代表流通股比例、X19 代表年度股东大会会议出席率、X20 代表独立董事比例、X21 代表董事长兼总经理、X22 代表股权集中度、X23 代表第一大股东控制度、X24 代表被出具非标意见。

其他可能发生重大错报的风险事项侧重于定性评价,在不同环境下被审计客户的重大错报风险所在领域会有所不同,不同的专家或注册会计师会得出不同的职业判断,所以沿袭现有学者提出的模糊数学、沃尔评分法等评价方式。

3. 自变量筛选。因变量为 0 和 1 两个值,1 为高重大错报

风险,0为低重大错报风险,采用SPSS 17.0软件对数据的均值、中位数进行T检验和卡方检验,以此判断24个财务指标在高重大错报风险和低重大错报风险两组样本中是否具有显著性差异。

在变量筛选过程中,首先,当连续型自变量服从正态分布时,采用配对样本T检验方法用于统计连续型变量均值显著水平;其次,当连续型变量不服从正态分布时,采用Mann-Whitney U检验用于统计连续型变量中位数显著水平;再次,对离散型变量采用Chi-Square检验用于统计离散型变量均值显著水平。

由T检验、Mann-Whitney U检验和Chi-Square检验均值和中位数统计结果显示,高重大错报风险样本和低重大错报风险样本在持续经营能力、融资能力、营运能力、重大关联交易、关键人员变动、内部控制环境等方面存在显著差异。

但上市公司财务报表的重大错报风险识别显然不是某个单独的因素能够予以充分解释的,是多因素相互关联、共同作用的结果。进一步,以显著性(Sig.)水平小于5%为筛选标准,本文最终取得其中12个自变量:X3代表资产负债率、X7代表资产报酬率、X9代表总资产净利润率、X10代表每股收益、X11代表流动资产周转率、X12代表总资产周转率、X14代表关联购销比率、X18代表流通股比例、X19代表年度股东大会出席率、X22代表股权集中度、X23代表第一大股东控制度、X24代表审计意见,通过多变量分析模型来建立重大错报风险识别模型。

下文中构建的两个重大错报风险识别模型将分别对高、低重大错报风险样本集拟合出一个函数,用以识别新输入的样本属于高重大错报风险还是低重大错报风险。

二、Logistic 算法重大错报风险识别模型

当因变量取值1时为高重大错报风险,当因变量取值0时为低重大错报风险。鉴于因变量是二元变量,而解释变量既有离散变量又有连续变量,且Logistic模型没有关于分布类型、协方差阵的严格假定,理论前提比较宽松,所以识别模型适用于Logistic算法。

Logistic模型系数综合检验(Omnibus Tests Of Model Coefficients)的目的是对12个自变量进行全局检验,对每一步自变量筛选都作了Step、Block和Model的检验,数据显示第五步最终模型的卡方值为55.966,显著性(Sig.)水平为0,说明Logistic模型中包含的自变量整体检验比较显著。在Logistic模型整体检验结果里,-2 Log likelihood用于测量模型对数据的拟合度,在五次变量筛选过程中,-2 Log likelihood逐渐减小,最终为129.797,而Cox & Snell R Square和Nagelkerke R Square逐渐增大,最终为0.341和0.455,说明该Logistic模型拟合过程是合理的。

观察Logistic回归结果中最后一步的拟合情况,从显著性水平(Sig.)来看,X3(资产负债率)、X7(资产报酬率)、X12(总资产周转率)、X14(关联购销比率)、X19(年度股东大会出席股份比率)五个变量检验的显著性水平(Sig.)都小于0.05,因此,五个变量均可进入模型。

表1 Logistic 回归结果

	B	S.E.	Wald	df	Sig.	Exp(B)	
Step 5	X7	-0.133	0.061	4.666	1	0.031	0.876
	X12	-1.988	0.720	7.633	1	0.006	0.137
	X3	0.032	0.015	4.733	1	0.030	1.032
	X14	11.083	4.544	5.950	1	0.015	65 086.252
	X19	-0.067	0.021	9.868	1	0.002	0.935
	Constant	3.644	1.598	5.197	1	0.023	38.244

依据Logistic回归结果中的B列数据,得出重大错报风险的识别模型为:

$$P(Y) = \frac{e^{3.644+0.032X_3-0.133X_7-1.988X_{12}+11.083X_{14}-0.067X_{19}}}{1+e^{3.644+0.032X_3-0.133X_7-1.988X_{12}+11.083X_{14}-0.067X_{19}}}$$

表2观测量分类表显示Logistic算法的重大错报风险模型识别准确率如下:76个高重大错报风险样本中有16个样本误判为低重大错报风险,模型对高重大错报风险样本的识别准确率为78.9%;76个低重大错报风险样本中有19家误判为高重大错报风险,模型对低重大错报风险样本的识别准确率为75%;模型整体识别准确率为76.9%。

表2 Classification Table(观测量分类表)

		Predicted(预测值)		Percentage Correa (识别正确率)
		高错报风险	低错报风险	
Observed (观测值)	高错报风险	60	16	78.9%
	低错报风险	19	57	75%
Overall Percentage(模型整体识别正确率)				76.9%

三、LM 算法 BP 神经网络重大错报风险识别模型

传统BP神经网络通过非线性函数的复合来完成映射,广泛应用于模型识别、预测环节。由于传统BP神经网络采用梯度下降算法,存在诸如收敛速度慢、易陷入局部最小等不足,因此本文采用基于Levenberg-Marquardt算法(下文简称LM算法)改进型BP神经网络构建模型。它可以大幅度提高收敛速度,并可以提高算法的稳定性,减少陷入局部最小点的可能。LM算法BP神经网络模型基本思路如下:①分别组建训练样本集和测试样本集。1998~2007年的67对样本用于模型的训练,2007~2009年的9对样本用于模型的测试。②初始化LM神经网络算法的参数,以及网络的权值向量。③将训练样本集放入模型中训练,逐步调整权值向量,直至达到期望目标误差时停止。④将预测样本集放入模型中预测,比较目标值与预测值,最后统计该模型预测正确率。

图1和图2纵坐标为目标误差,横坐标为达到目标误差均值所需的迭代次数。LM算法BP神经网络在训练过程中,当训练样本全部输入神经网络后才进行一次权值调整,这称为一次迭代。在下次迭代中,训练样本被重新全部输入,达到目标误差时迭代停止,训练结束。因此,达到误差目标所需的迭代次数反映了网络收敛速度的快慢。

两图对比显示,图1中横坐标约170时纵坐标趋于稳定,说明传统BP神经网络经过近170次的迭代过程才基本达到

模型训练稳定状态;图2中横坐标约100时纵坐标趋于稳定,说明LM算法BP神经网络只需近100次的迭代过程即可达到模型训练稳定状态。充分证明LM算法BP神经网络具有收敛速度快、迭代次数少的优点,即当大量财务数据要求较高运算速度时,该模型具备很强适用性。




图1 传统BP神经网络训练误差图




图2 LM算法BP神经网络训练误差图

本文借助 Matlab R2009b 软件实现 LM 算法 BP 神经网络,神经网络构建的成功与否,取决于隐含层神经元个数、目标误差和学习效率,各参数设置情况如下:

(1)输入层。由于采用筛选后的12个财务指标作为预测变量,输入层神经元个数 $n=12$ 。

(2)输出层。本文输出层神经单元数目 $m=1$,取值为0和1。

(3)隐含层。隐含层的神经元个数参考公式: $N \approx 2n+1$,隐含层神经元个数 $N=20$ 。

(4)网络参数。目标误差 $\epsilon=10^2$,选取学习效率为0.01,经过一百余个训练周期后达到要求。

对 LM 算法 BP 神经网络识别模型的预测样本集进行回归检验,回归直线方程: $A=0.96 \times \text{Target}+0.007$ 。其中相关系数 R 为 0.96,通常 R 大于 0.7,认为模型取得较理想的拟合效果。

LM 算法 BP 神经网络识别模型样本集共 76 组,前 67 组样本集用于模型的训练,后 9 组样本集用于模型的预测。当真实值与预测值差值在 $[-0.05, 0.05]$ 区间内,认为真实值与预测值是一致的;否则,认为真实值与预测值不符。

观察表3中预测样本集9组样本的预测结果发现:9个高重大错报风险样本中有3个样本误判为低重大错报风险,

模型对高重大错报风险样本的识别准确率为66.67%;9个低重大错报风险样本全部正确预测,模型对低重大错报风险样本的识别准确率为100%。由表4的LM算法BP神经网络模型预测结果表看出,该模型的整体识别准确率高达83.33%。

表3 LM算法BP神经网络真实值 & 预测值对比表

序号	真实值	预测值	真实值	预测值
1	1.000 0	0.000 1	0.000 0	0.000 0
2	1.000 0	1.000 0	0.000 0	0.038 4
3	1.000 0	0.999 1	0.000 0	0.000 0
4	1.000 0	1.000 0	0.000 0	0.000 0
5	1.000 0	1.000 0	0.000 0	0.000 0
6	1.000 0	0.000 0	0.000 0	0.000 0
7	1.000 0	1.000 0	0.000 0	0.000 4
8	1.000 0	0.000 0	0.000 0	0.000 0
9	1.000 0	1.000 0	0.000 0	0.000 0

表4 LM算法BP神经网络模型预测结果表

	预测样本		识别正确率
	样本总数	正确识别个数	
高错报风险	9	6	66.67%
低错报风险	9	9	100.00%
模型整体识别正确率			83.33%

四、结论

上述实证研究可得出以下结论:首先,资产负债率、资产报酬率、总资产净利润率、每股收益、流动资产周转率、总资产周转率、关联购销比率、流通股比例、年度股东大会出席率、股权集中度、第一大股东控制度、审计意见,这十二个因素与重大错报风险的识别具有较强的相关性。其次,对比上述两种模型之间的识别准确率可以明显看出,基于LM算法BP神经网络重大错报风险识别模型的平均识别准确率为83.33%,Logistic重大错报风险识别模型平均识别准确率为76.9%。这说明基于LM算法BP神经网络重大错报风险识别模型是有效的,准确率更高,泛化能力较强。

主要参考文献

1. Lin J W, Hwang M I, Becker J D. A fuzzy Neural Network for Assessing the Risk of Fraudulent Financial Reporting. Managerial Auditing Journal, 2003; 18
2. 田金玉, 聂丹丹. 基于BP神经网络方法的会计舞弊识别研究. 中国管理信息化, 2008; 11
3. 王翠琳, 李西媛. 基于重大错报风险识别的新审计风险模型构建. 财会月刊(理论版), 2008; 4
4. 邹晶, 欧阳程. 模糊综合评价法在重大错报风险评估中的运用. 中国管理信息化(会计版), 2007; 8
5. 刘旭, 于国祥, 沈西挺. 基于神经网络的预测模型的研究. 河北省科学院学报, 2007; 24
6. 王青梅. BP神经网络算法的一种改进. 青海大学学报(自然科学版), 2004; 2