

文章编号:1671-9352(2008)11-0048-06

# 基于主成分分析和粗径向基神经网络的 财务预警模型研究

朱世伟, 赛英

(山东财政学院计算机信息工程学院, 山东 济南 250014)

**摘要:** 将主成分分析和径向基函数神经网络结合, 以粗糙集作为预处理器进行指标约简, 并以传统财务指标为基础, 引入反映企业现实财务状况的现金流量指标, 通过主成分分析提取指标和降维, 利用径向基函数神经网络作为判别企业财务状况的工具, 构建上市公司财务危机预警的 RPR 模型, 实证研究结果证明了该模型具有较高的建模精度和泛化能力。

**关键词:** 财务危机预警; 现金流量; 主成分分析; 径向基函数神经网络; 粗糙集

**中图分类号:** TP183      **文献标志码:** A

## The prediction model of financial distress of Chinese listed corporations based on a hybrid RPR model

ZHU Shi-wei, SAI Ying

(School of Computer & Information Engineering, Shandong University of Finance, Jinan 250014, Shandong, China)

**Abstract:** A new hybrid RPR model for predicting financial distress of Chinese listed corporations was put forth. The proposed model integrates the rough set(RS), the principle component analysis(PCA) method and the radial-basis function neural network(RBFN). Besides the traditional financial indicators, the cash-flow indicators were introduced, which can perfectly reflect the real-time financial situation of a corporation. In the model, the RS was applied to reduce the indicator, the PCA was employed to select indicators and reduce dimensions, the RBFN was used as a prediction tool for the corporate financial situation. Experimental results suggest that the model has high prediction accuracy and execution efficiency.

**Key words:** financial distress prediction; cash-flow; principal component analysis; radial basis function network; rough set

### 0 国内外研究综述

现代企业在经营过程中面临纷繁复杂的环境因素, 随时都有陷入财务困境或财务危机的可能性。因此, 准确的预测企业财务失败对于上市公司防患于未然, 保护投资者和债权人的权益, 经营者规避财务风险, 政府部门监控上市公司质量和证券市场风险, 都具有重要的现实意义<sup>[1,2]</sup>。

国外早在 20 世纪 30 年代已经开始财务预警的研究, 在理论研究和实践分析方面都取得了显著的

成果。各国学者运用不同的预测变量、采用各种数学工具和方法建立了大量的财务预警模型, 早期的财务危机预测模型主要有: 单变量判别模型(Fitzpatrick<sup>[3]</sup>, 1932; William Beaver<sup>[4]</sup>, 1966)、多元线性判定模型(Altman. E. I<sup>[5,6]</sup>, 1968; Haldeman 和 Narayanan, 1977)、条件概率模型(Ohlson<sup>[7]</sup>, 1980)、多元回归和逻辑回归模型(Meyer 和 Pifer, 1970)等; 然而这些传统的统计学模型要求指标变量是线性的、相互间是不相关的、并且要严格的服从正态分布等, 从而限制了其在实践中的应用。近年来, 随着人工智能和软计算技术的发展出现了一些新兴的财务预

警模型,主要有:人工神经网络模型(Coats 和 Fant<sup>[8]</sup>, 1993; Bortiz 和 Kennedy<sup>[9]</sup>, 1995; Coakley 和 Brown, 2000 等)、基于案例推理的方法(Buta, 1994; Bryant, 1997)、专家系统方法(Messier 和 Hansen, 1998)和剖面分析法等。

尽管大量的理论和实证研究结果表明,神经网络技术(主要是 BPN)建立的上市公司财务危机预警模型,克服了传统模型依赖线性函数建立模型的缺陷,具有较高的精确度。但它本身存在一些固有的缺点,如:网络模型和结构选择困难;易陷入局部极小点;收敛速度慢,容易出现过学习,推广能力有限等<sup>[10]</sup>。径向基函数神经网络在逼近能力、学习速度,避免局部极小等方面优于 BPN,但是当输入节点过多时 RBFN 的网络结构复杂度较高,为此,本文提出结合粗糙集和主成分分析方法优化的 RPR 模型,该模型首先利用 RS 方法进行指标约简,剔除冗余属性,然后利用 PCA 方法提取指标和降维,将简化后的综合指标作为 RBFN 的输入向量进行模型的训练和预测。实证分析结果表明,与传统的 BPN 和 RBFN 相比,该方法具有准确度高、推广能力强、网络结构简单、学习速度快等优点,在上市公司财务危机预警系统中有良好的应用前景。

## 1 PCA-RBFN 模型理论

### 1.1 RBFN 理论

径向基函数(radial basis function, RBF)理论最早是由 Powell M. J. D<sup>[11]</sup>(1985)在解决在高维线性空间中插值问题时提出的, Broomhead 和 Lowe(1998)率先使用该技术提出了神经网络学习的一种新手段。由于它具有结构自适应确定、输出与初始权值无关的优良特性,在多维曲面拟合、自由区面重建和大型设备的故障诊断等领域有着比较多的应用<sup>[12]</sup>。

RBFN 是以函数逼近理论为基础构造的一种具有单隐层的 3 层前馈网络,输入层节点只传递输入信号到隐层,隐层节点由像高斯核函数(Gaussian)那样的辐射状作用函数构成,而输出层节点通常是简单的线性函数。隐层节点的作用函数(RBF)对输入信号将在局部产生响应,也就是说,当输入信号靠近基函数的中央范围时,隐层节点将产生较大的输出,由此看出作为一种正则化网络,RBFN 模拟了人脑中局部调整、相互覆盖感受野的神经网络结构,因此,它是一种局部逼近网络,能以任意精度逼近任意连续函数,不存在局部最小问题。 $n$  个输入一个输出的 RBFN 结构如图 1 所示。




图 1 RBFN 结构图

Fig. 1 Structure of radial basis function network

输出层的数学表述为:

$$y = \sum_{i=1}^m \omega_i \phi_i(\mathbf{x}), \quad (1)$$

其中, $\mathbf{x}$  是输入向量, $m$  是隐含层节点数, $\omega_i$  ( $1 \leq i \leq m$ ) 是隐含层到输出层的权值,基函数  $\phi_i(\mathbf{x})$  ( $1 \leq i \leq m$ ) 通常选择高斯函数,即:

$$\phi_i(\mathbf{x}) = \exp\left[-\frac{\|\mathbf{x} - \mathbf{c}_i\|^2}{2\sigma^2}\right], \quad (2)$$

其中, $\mathbf{c}_i$  ( $1 \leq i \leq m$ ) 是  $i$  个节点的中心, $\sigma$  是基函数的宽度, $\|\cdot\|$  是 Euclid 范数。

### 1.2 RBFN 的学习算法

在 RBFN 中,输出层和隐含层所完成的任务是不同的,因而他们学习的策略也不同。输出层是对线性权进行调整,采用的是线性优化策略,学习速度较快。隐含层是对作用函数的参数( $\mathbf{c}_i$  和  $\sigma_i$ ) 进行调整,采用非线性优化策略,因而学习速度较慢。隐含层的学习是自组织的学习方法,而输出层的学习方法是有导师的,因而一般分为 2 个层次进行,但整体是个混合的学习过程。RBFN 学习算法主要有<sup>[13,14]</sup>:

(1) 随机选取固定 RBF 中心(直接算法)。在此算法中,隐单元 RBF 的中心是随机地在输入样本数据中选取,且中心固定。而 Gaussian 基函数的宽度固定为:

$$\sigma = \frac{d_m}{\sqrt{2M}}, \quad (3)$$

其中, $d_m$  为所选中间的最大距离, $M$  为中心数。

(2) 采用自组织学习算法选取 BRN 中心。在这种方法中,通过非监督的自组织学习确定其位置。而输出层的线性权则可以通过有导师的学习规则计算。BRN 中心的选取可以采用  $k$ -means 聚类算法、模糊均值聚类算法等。本文使用增强的模糊  $c$ -means 聚类算法作为学习算法<sup>[15]</sup>。

(3) 中心的监督选择。

(4) 使用监督学习和非监督学习结合的混合算法。

### 1.3 主成分分析原理

主成分分析(principle component analysis, PCA)

的概念首先是由 Karl Pearson(1901)提出的,尔后 Hotelling 将这个概念推广到随机向量,后经 Rao (1964)、Cooley & Lohes(1971)、Morrison(1976)和 Mardia、Kent & Billy(1979)发展和成熟起来。

主成分分析是设法将原来众多具有一定相关性的指标(比如  $P$  个指标)重新组合成一组新的互相无关的综合指标来代替原来的指标。通常数学上的处理就是将原来  $P$  个指标作线性组合,作为新的综合指标。最经典的做法就是用  $F_1$ (即第一个综合指标)的方差来表达,即  $\text{Var}(F_1)$  越大,表示  $F_1$  包含的信息越多。因此在所有的线性组合中选取的  $F_1$  应该是方差最大的,故称  $F_1$  为第一主成分。如果第一主成分不足以代表原来  $P$  个指标的信息,再考虑选取  $F_2$ (即选第二个线性组合),为了有效地反映原来信息, $F_1$  已有的信息就不需要再出现在  $F_2$  中,用数学语言表达就是要求  $\text{Cov}(F_1, F_2) = 0$ ,则称  $F_2$  为第二主成分,依此类推可以构造出第三、第四、...,第  $m$  个主成分<sup>[16]</sup>。

### 1.4 主成分分析的数学模型

假定选取反映上市公司财务状况的  $P$  个财务指标,分别用变量  $X_1, X_2, X_3, \dots, X_p$  表示,选取  $N$  家上市公司对这些指标进行观察,共测得  $N$  个样本观测值,第  $i$  家公司的第  $j$  个财务指标用  $X_{ij}$  ( $i = 1, 2, \dots, n; j = 1, 2, \dots, m$ ) 来表示,观测数据如表 1 所示。

表 1  $n$  个上市公司样本数据  
Table 1 Samples data of  $n$  corporate

ID	$X_1$	$X_2$	...	$X_p$
1	$X_{11}$	$X_{12}$	...	$X_{1p}$
2	$X_{21}$	$X_{22}$	...	$X_{2p}$
...	...	...	...	...
$N$	$X_{n1}$	$X_{n2}$	...	$X_{np}$

因此,可得到  $P$  个指标的  $m$  个主成分分量:

$$\begin{cases} F_1 = a_{11} ZX_1 + a_{12} ZX_2 \cdots + a_{1p} ZX_p, \\ \dots \\ F_m = a_{m1} ZX_1 + a_{m2} ZX_2 + \dots + a_{mp} ZX_p, (m \leq p) \end{cases}$$

其中  $a_{i1}, a_{i2}, \dots, a_{ip}$  ( $i = 1, \dots, m$ ) 为  $X$  的协方差阵的特征值所对应特征向量的系数,  $ZX_1, ZX_2, \dots, ZX_p$  是原始变量经过标准化处理后的值。在解决实际问题时,一般不是取  $p$  个主成分,而是根据累计贡献率的大小取前  $k$  个。

**定义** 称  $\lambda_1 / \sum_{i=1}^p \lambda_i$  为第一主成分的贡献率;称  $\sum_{i=1}^m \lambda_i / \sum_{i=1}^p \lambda_i$  为前  $m$  个主成分的累计贡献率。其中,  $\lambda_i$

为  $X$  的协方差阵  $\Sigma$  的特征值,且  $\lambda_1 > \lambda_2 > \dots > \lambda_p > 0$ 。如果前  $k$  个主成分的累计贡献率达到 85%,表明取前  $k$  个主成分基本包含了全部测量指标所具有的信息<sup>[17]</sup>。

### 1.5 RPR 模型

通常, RBFN 模型不能约简输入向量的维数,当输入节点过多时 RBFN 的结构会变得复杂,训练和学习时间将会变长。因此,有必要对输入向量空间进行指标约简和降维。本研究首先使用 RS 对初始样本集进行约简,剔除冗余指标,然后使用 PCA 方法来提取指标和降维,消除指标间的相关性,最后把经 PCA 处理后的综合指标变量作为 RBFN 的输入向量,主要过程如图 2 所示。

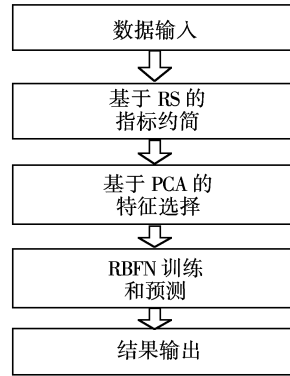


图 2 RPR 模型处理流程  
Fig.2 The main process of RPR model

从图 2 中可以得到 RPR 模型的主要处理过程,分 3 个步骤:首先准备输入数据并进行数据标准化,对于本研究中的问题第一步要根据所要分析的指标按一定标准收集数据;其次,分别使用 RS 和 PCA 方法进行指标的约简和降维;最后用约简后的综合指标作为 RBFN 的输入向量,训练 RBFN 并进行预测。

## 2 实验研究及结果分析

### 2.1 研究样本选取

本文将财务危机公司界定为沪深 2 市 A 股市场因连续 2 年亏损而被特殊处理的上市公司。在设计研究变量时,该研究变量除满足逻辑性原则、有效性原则、客观性原则、敏感性原则的要求外,还借鉴国内外已有的文献,借鉴国家财政部等 4 部委联合颁布的《国有资本绩效评价规则》中广泛应用的财务评价指标体系,以及财务指标获取的难易程度和成本效益等原则,考虑到行业差异因素的影响,最终选取了沪深 2 市 A 股市场中 2001 ~ 2006 年间被特别处理的财务危机公司(180 家)和与其配对的财务正

常公司(180家)共360家上市公司(数据取自色诺芬财经数据库)。根据以下原则按1:1的比例选择财务正常的上市公司作为配对样本以剔除由于不同年份、行业和资产规模等因素对财务危机预测结果的影响:(1)研究时间一致;(2)配对样本与财务危机公司行业类型相同或相近;(3)配对样本与财务危机公司的总资产规模相同或相近;(4)剔除数据严重缺失或不合理公司及上市2年内就被特别处理的公司;(5)剔除因其他状况异常而被特别处理的公司。

表2 指标变量及计算公式

Table 2 The selected indicators and their calculation expressions

偿债能力	营运能力	盈利能力	成长能力	投资收益	现金流量
$X_1$ 速动比率	$X_8$ 应收帐款周转率	$X_{14}$ 销售净利率	$X_{20}$ 主营业务收入	$X_{24}$ 每股收益	$X_{27}$ 现金流动负债比
$X_2$ 流动比率	$X_9$ 存货周转率	$X_{15}$ 资产净利率	增长率	$X_{25}$ 每股净资产	$X_{28}$ 现金负债总额比
$X_3$ 营运资本比重	$X_{10}$ 总资产周转率	$X_{16}$ 净资产收益率	$X_{21}$ 资本积累率	$X_{26}$ 每股经营	$X_{29}$ 主营收入现金回收比率
$X_4$ 资产负债率	$X_{11}$ 固定资产周转率	$X_{17}$ 总资产收益率	$X_{22}$ 总资产增长率	净现金流量	$X_{30}$ 净利润现金比率
$X_5$ 产权比率	$X_{12}$ 流动资产周转率	$X_{18}$ 主营业务利润率	$X_{23}$ 净利润增长率		$X_{31}$ 资产现金回报率
$X_6$ 保守速动比率	$X_{13}$ 所有者权益周转率	$X_{19}$ 主营利润比重			$X_{32}$ 现金流入与流出比
$X_7$ 利息保障倍数					$X_{33}$ 总资产净现率

## 2.2 试验分析步骤

本研究中将ST公司和非ST公司分别用1和0来表示,将研究样本的2/3(240家)作为训练样本,其余(120家)作为测试样本。实验步骤:

(1)为避免由于量纲的不同而造成的结果差异,本文首先对所选原始数据进行标准化,使各指标的均值为0,方差为1。采用z-score标准化方法进行数据标准化处理<sup>[18]</sup>,标准化公式为: $x'_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}$ ,  $i = 1, 2, \dots, n; j = 1, 2, \dots, p$ 。其中, $x_{ij}$ 为原始数据, $\bar{x}_j$ 为第j个指标的平均数, $s_j$ 为其标准差, $n$ 为样本数, $p$ 为指标数。

(2)本文利用Rosetta软件,对选取的样本数据

## 2.1 财务危机预警指标变量的选取

本文运用部分现金流量指标修订传统财务指标进行企业财务危机预警的研究。考虑到企业财务危机的直接原因和根本原因以及财务指标之间的相关性,为全面反映企业财务状况,本文根据我国上市公司特点,在总结前人研究成果的基础上,选择包含偿债能力、营运能力、盈利能力、成长能力和反映现金流量指标等共33个财务指标进行企业财务危机预警模型PCA-RBFN的实证研究。所用指标变量如表2所示。

利用Naïve Scalar算法进行离散化,然后通过RS理论进行约简,约简后剩余的25个指标变量见表3。

表3 粗糙集约简后的指标变量

Table 3 Indicators simplified by RS

指标变量	
约简后删除的指标	$X_2 X_6 X_7 X_{12} X_{13} X_{18} X_{32} X_{33}$
约简后保留的指标	$X_1 X_3 X_4 X_5 X_8 X_9 X_{10} X_{11} X_{14} X_{15} X_{16} X_{17} X_{19} X_{20} X_{21} X_{22} X_{23} X_{24} X_{25} X_{26} X_{27} X_{28} X_{29} X_{30} X_{31}$

(3)对RS约简后的数据进行主成分分析,按方差 $\geq 0.5$ 的原则取前14个主成分(累计贡献率为91.885%)作为RBFN的输入。分析结果如表4所示。

表4 主成分分析结果

Table 4 The results of PCA

因子	初始解			提取的因子总体描述			旋转后因子总体描述		
	特征值	方差贡献率/%	累计贡献率/%	特征值	方差贡献率/%	累计贡献率/%	特征值	方差贡献率/%	累计贡献率/%
1	6.523	26.091	26.091	6.523	26.091	26.091	3.831	15.322	15.322
2	3.076	12.305	38.397	3.076	12.305	38.397	3.010	12.039	27.362
3	2.254	9.017	47.413	2.254	9.017	47.413	2.119	8.475	35.836
4	1.768	7.073	54.486	1.768	7.073	54.486	1.951	7.802	43.639
5	1.238	4.952	59.438	1.238	4.952	59.438	1.117	4.470	48.108
6	1.092	4.367	63.805	1.092	4.367	63.805	1.064	4.256	52.364
7	1.036	4.143	67.948	1.036	4.143	67.948	1.044	4.177	56.541
8	1.005	4.021	71.970	1.005	4.021	71.970	1.012	4.049	60.590
9	0.985	3.940	75.910	0.985	3.940	75.910	1.011	4.043	64.633

续表 4

因子	初始解			提取的因子总体描述			旋转后因子总体描述		
	特征值	方差贡献率/%	累计贡献率/%	特征值	方差贡献率/%	累计贡献率/%	特征值	方差贡献率/%	累计贡献率/%
10	0.976	3.904	79.814	0.976	3.904	79.814	1.009	4.036	68.669
11	0.927	3.709	83.524	0.927	3.709	83.524	1.008	4.030	72.699
12	0.820	3.280	86.803	0.820	3.280	86.803	1.006	4.023	76.722
13	0.655	2.621	89.424	0.655	2.621	89.424	1.003	4.014	80.736
14	0.539	2.156	91.580	0.539	2.156	91.580	0.944	3.776	84.512
15	0.481	1.925	93.505	0.481	1.925	93.505	0.932	3.728	88.240
16	0.435	1.742	95.247	0.435	1.742	95.247	0.772	3.089	91.329
17	0.321	1.285	96.532	0.321	1.285	96.532	0.720	2.882	94.211
18	0.233	0.932	97.465	0.233	0.932	97.465	0.580	2.318	96.529
19	0.217	0.869	98.334	0.217	0.869	98.334	0.319	1.275	97.804
20	0.183	0.731	99.065	0.183	0.731	99.065	0.270	1.081	98.885
21	0.097	0.387	99.451	0.097	0.387	99.451	0.114	0.455	99.341
22	0.069	0.276	99.728	0.069	0.276	99.728	0.085	0.342	99.683
23	0.044	0.175	99.903	0.044	0.175	99.903	0.055	0.219	99.902
24	0.019	0.077	99.980	0.019	0.077	99.980	0.020	0.079	99.980
25	0.005	0.020	100.000	0	0	0	0	0	0

(4) 将 PCA 得到的 14 个主成分作为 RBFN 模型的输入节点,中心及隐层节点数由增强的模糊 c-means 聚类算法确定,初始隐层数为 0,宽度  $\sigma^2 = 0.4$ ;隐层和输出层之间权值的调整可采用 LMS 算法: $\omega_{ki}(t+1) = \omega_{ki}(t) + \partial \frac{e_k(t)R_{ji}}{\|R_p\|}$  (其中,  $\partial$  为常量,  $0 < \partial < 2$ )。

### 2.4 实验结果分析

本文将所提出模型的预测结果与 BPN、传统的 RBFN 模型运行结果进行比较,可以得出。

本研究中提出的 RPR 模型对财务危机公司和财务正常公司的财务状况预测准确率均超过了 85%,其中犯第 I 类错误(指将实际财务危机公司误判为非财务危机公司)的概率为 10%,低于传统的 RBFN 模型 18.33%的误判率,RPR 和 RBFN 模型对非财务危机公司的预测准确率均略高于财务危机公司。

同时,通过表 5~8 还可以得出:在相同条件和输入节点相同时,BP 网络训练效率和训练精度明显低于 RBFN,这是因为 RBFN 的输出层是对隐层的线性加权,使得网络避免了像 BP 反向传播那样繁琐的计算从而提高了网络的运算速度和较强的非线性映射能力,同时,由于 RBFN 还克服了 BP 网络对初值的依赖性而具有了最佳的性能和全局最优特性。

表 5 与 BP 模型训练时间比较

Table 5 Training time comparison with BP model

模型	训练集运行时间/s	模型最后输出平均误差
BPN	3.254 0	0.012 4
RPR	0.021 4	0.004 3

表 6 RPR 和 RBFN 模型对 ST 公司样本的预测准确率

Table 6 Predicting accuracy of RPR and RBFN models for ST corporate

模型名称	ST 公司实际数	预测值为 ST 数	误判数	预测准确率/%
RBFN	60	49	11	81.67
RPR	60	54	6	90

表 7 RPR 和 RBFN 模型对非 ST 公司样本的预测准确率

Table 7 Predicting accuracy of RPR and RBFN models for non-ST corporate

模型名称	非 ST 公司实际数	预测值为非 ST 数	误判数	预测准确率/%
RBFN	60	52	8	86.67
RPR	60	55	5	91.67

表 8 与传统模型试验结果比较

Table 8 Hit ratio comparison with traditional models

模型	测试样本数	误判数	准确率/%
BPN	120	26	78.33
ARIMA	120	35	70.83
RBFN	120	19	84.17
RPR	120	11	90.83

通过表5还可以得到:运用PCA方法对RBFN的输入空间进行重构可有效地降低输入空间维数,避免像BP网络等传统数据挖掘工具在训练和预测中的维灾难问题,所以在降低问题复杂度的同时也提高了评估的精度。

### 3 结论和展望

通过试验数据的分析可以得到,基于PCA和RS约简的RBFN财务预警模型——RPR模型,在本文所研究的财务预警问题上要优于传统的统计分析模型和BP网络模型。引入粗糙集剔除样本中的冗余指标,克服了以往预警指标变量选取上的困难,使得指标的选取能全面地反映企业财务运行状况,指标变量的选取更加科学、合理;使用PCA对输入向量空间的重构可以有效地缩减RBFN输入节点,在降低网络结构复杂度的同时显著提升了模型预测的准确率,本文提出的RPR财务危机预警模型为研究企业的财务危机预警提供了一个新的研究思路和方法,同时也能更好地丰富和完善企业财务预警的理论和方法。

虽然RPR模型在实验中显示了良好的性能,但是仍然存在一定的局限性,有待于在未来的研究中改进。例如:参数的合理选择方法、预警指标变量的选择标准、非财务指标的应用等问题有待论证。同时还将在未来的研究中考虑RBFN模型结构的进一步优化,如RBFN和粒子群优化(PSO)算法、模糊理论、遗传算法<sup>[19]</sup>以及支持向量<sup>[20]</sup>等的结合,以期能取得更加准确的预测结果,为我国上市公司的财务管理和投资决策提供可借鉴的依据。

#### 参考文献:

[1] 张鸣,张艳,程涛.企业财务预警前沿研究[M].北京:中国财政经济出版社,2004.

[2] 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(1):12-26.

[3] FITZPATRICK P J. A comparison of ratios of successful industrial enterprises with those of failed firms[J]. Certified Public Accountant, 1932:656-662.

[4] BEAVER William. Financial ratios as prediction of failure[J]. Journal of Accounting Research, 1966(Supplement):71-111.

[5] ALTMAN Edward. Financial ratios discriminate analysis and

prediction of corporate bankruptcy[J]. Journal of Finance, 1968, 9:589-609.

[6] ALTMAN E I. Zeta analysis: a new model to identify bankruptcy risk of corporate[J]. Journal of Banking and Finance, 1977, 1:29-54.

[7] OHLSON J A. Earnings and dividends, an analysis and extension of the Beaver, Lambert, and Morse valuation model[J]. Journal of Accounting and Economics, 1989, 7:109-116.

[8] COATS P, FANT L. Recognizing financial distress patterns using a neural network tool[J]. Financial Management, 1993, 3:142-155.

[9] BORITZ J, KENNY D. Effectiveness of neural networks types for prediction of business failure[J]. Expert Systems with Applications, 1995, 9:503-512.

[10] 刘永,张立毅. BP和RBF神经网络的MATLAB实现及其性能比较[J]. 电子测量技术, 2007, 30(4): 77-80.

[11] POWELL M J D. Radial basis functions for multivariable interpolation: a review [C]// Mason J, C, Cox M G. Algorithms for Approximation, Oxford: Oxford University Press, 1987: 143-167.

[12] SIMON Haykin. Neural networks: a comprehensive foundation [M]. Beijing: Tsinghua University Press, 2001.

[13] ACOSTA F. RBF and related models: an overview [J]. Signal Processing, 1995, 45:37-58.

[14] MARTIN T Hagan, HOWARD B Demuth, MARK Beale. Neural network design [M]. Thomson Learning: PWS Publishing Company, 1996.

[15] ANTONINO Staiano, ROBERTO Tagliaferri, WITOLD Pedrycz. Improving RBF networks performance in regression tasks by means of a supervised fuzzy clustering [J]. Neuro Computing, 2006, 69: 1570-1581.

[16] 刘红霞,张心林. 以主成分分析法构建企业财务危机预警模型[J]. 中央财经大学学报,2004(4): 70-75.

[17] 宇传华. SPSS与统计分析[M]. 北京:电子工业出版社,2007.

[18] HAN Jiawei, MICHELINE Kamber. Data mining: concepts and techniques[M]. Beijing: China Machine Press, 2001.

[19] WHITEHEAD B A. Cooperative competitive genetic evolution of radial basis function centers and widths for time series prediction[J]. IEEE Trans on Neural Networks, 1996, 7(4): 869-880.

[20] 顾民. 神经网络、模糊系统、支持向量机内在联系研究[D]. 成都:电子科技大学控制理论与控制工程,2004.

(编辑:孙培芹)