

BP 算法在信用风险分析中的应用

庞素琳¹, 黎荣舟^{2,3}, 徐建闽²

(1. 暨南大学 数学系, 广东 广州 510632; 2. 华南理工大学 交通学院, 广东 广州 510640;

3. 上海浦东发展银行 广州分行, 广东 广州 510075)

摘要: 建立了基于 BP 算法的神经网络信用风险评价模型, 用来对我国某国有商业银行 2001 年 80 家贷款企业进行两类模式分类. 按照企业的财务状况、经营状况以及过往的信用记录分为“信用好”和“信用差”两个小组. 对于每一家贷款企业, 主要考虑能反映该企业的还款能力、盈利能力、经营效率和资本结构等 7 个财务比率作为分析变量. 对该 BP 网络分别训练 100 次、390 次和 800 次. 仿真结果表明, 当训练 800 次时, 网络达到一定的稳定状态, 目标函数值达到最优, 分类准确率达到 98.75%. 此外, 还给出了该 BP 网络的学习算法和步骤.

关键词: BP 算法; 信用风险评价模型; 信用风险分析

中图分类号: F830 **文献标识码:** A

Application of BP algorithm in credit risk analysis

PANG Su-lin¹, LI Rong-zhou², XU Jian-min²

(1. Department of Mathematics, Jinan University, Guangzhou Guangdong 510632, China;

2. College of Traffic and Communications, South China University of Technology, Guangzhou Guangdong 510640, China;

3. Guangzhou Branch, Shanghai Pudong Developing Bank, Guangzhou Guangdong 510075, China)

Abstract: A credit-risk evaluation model is established, which is based on back-propagation (BP) algorithm. The model has been applied to evaluate the credits of 80 applicants in a commercial bank of our country in 2001. These data are separated into two groups: a “good credit” group and a “bad credit” group according to their finance, management and previous credit records. As to each applicant, seven financial rates are considered that can reflect its debt paying ability, profitability, quality of management and capital structure. The BP network is trained 100, 390 and 800 times respectively. The simulations show that, when the network is trained 800 times, it enters steady state and the performance function reaches optimal value, and the classification accuracy rate is 98.75%. In addition, a learning algorithm and steps of the BP network are presented as well.

Key words: BP algorithm; credit risk evaluation model; credit risk analysis

1 引言(Introduction)

信用风险分析是指信用评级机构根据科学的指标体系, 采用严谨的分析方法, 运用简明的文字符号, 对被评级单位履行经济责任的能力及其可信任程度进行客观公正的评价, 并确定其信用等级的一种经济活动. 对贷款企业进行信用评级, 建立相应的信用风险评价模型, 并运用此模型预测某种事态或性质发生的可能性, 以便及早发现信用危机信号, 使贷款企业能够在危机出现的萌芽阶段, 采取有效措施, 改善经营方式, 防范危机发生; 使银行可依据这种信号及时转移资产, 管理应收账款及作出信贷风险决策. 建立贷款企业的准确审核模型, 提高银行的贷前审核质量, 对提高信贷资产的安全性并减少不良资产的产生有极其重要的现实意义.

作为研究复杂性的有力工具, 神经网络技术近

年来在模式识别、分类、预测等方面已展示了非凡的优越性, 它能处理任意类型的数据, 这是许多传统方法所无法比拟的. 神经网络通过不断学习, 能够从未知模式的大量复杂数据中发现其规律. 它克服了传统分析过程的复杂性及选择适当模型函数形式的困难, 是一种自然的非线性建模过程, 毋需分清存在何种非线性关系, 给建模与分析带来了极大的方便. 该方法用于信用风险分析时, 通过处理一系列的输入(如财务比率), 能产生相应的输出(如信用好或信用差, 财务困境或非困境等).

1992 年, Tam 和 Kiang 建立了 3 层 BP 网络对银行破产进行了预测^[1]. Jensen(1992)利用 BP 网络算法对贷款企业进行分类, 分类准确率达到 76% ~ 80%^[2]. Coats 和 Fant(1993)采用神经网络分析法对美国公司和银行的财务危机分别进行了预测, 取得

了一定的成果^[3]. Altman, Marco 和 Varetto (1994) 应用神经网络技术对意大利公司进行财务危机预警研究^[4]. Hashemi and Blanc (1998) 构造了一个神经网络和粗糙集成成分的复合模型对银行控股模式进行了预测^[5]. 2000 年, West 将银行贷款企业分为两组: 一组是“信用好”的企业(指能够按时偿还贷款的企业), 一组是“信用差”的企业(指不能按时偿还贷款的企业), 建立了 5 种不同的神经网络模型: MLP、专家杂合系统 (Mixture-of-experts)、RBF、学习向量量化器 (Learning vector quantization) 和模糊自适应共振 (Fuzzy adaptive resonance), 用来研究商业银行信用评价的准确性^[6]. Reshmi Malhotra, D. K. Malhotra (2002) 利用神经模糊系统对“信用好”和“信用差”两类贷款企业进行了辨识^[7]. 在我国, 1999 年, 王春峰等用神经网络技术进行商业银行信用风险评估^[8]. 郝丽萍等 (2001) 研究了商业银行信贷风险分析的人工神经网络模型^[9]. 杨保安和季海 (2001) 利用 3 层 BP 网络对我国商业银行贷款风险进行预警研究^[10]. 庞素琳等 (2003) 利用 BP 算法对我国某商业银行 2001 年 120 家贷款企业进行 3 类模式(“信用好”、“信用一般”、“信用差”)分类, 分类准确率达到 83.34%^[11].

本文利用 BP 算法对我国某商业银行 2001 年 80 家贷款企业进行两类模式(“信用好”和“信用差”)分类, 其中“信用好”的企业是指能够按时偿还贷款的企业, “信用差”的企业是指不能按时偿还贷款的企业(见文献[6]). 然后根据贷款企业的财务状况, 利用负债比率、流动比率、速动比率、主营业务净利润率、净资产收益率、存货周转率和应收帐款周转率等 7 个财务指标, 建立 BP 算法信用风险评价模型, 为商业银行提供一种鉴别企业信用的方法, 以提高银行抵御企业信用危机的能力, 减少不良资产的产生. 研究结果表明, 本文建立的 BP 算法信用风险评价模型, 其分类准确率达到 98.75%, 比 3 类模式分类准确率(83.34%, 见文献[11])要高得多.

2 信用风险评价模型 (Credit risk evaluation model)

本文所采用的数据样本, 是从我国某国有商业银行 2001 年选取 80 家贷款企业, 按照其财务状况、经营状况以及过往的信用记录分为“信用好”和“信用差”两个小组, 其中“信用好”的小组是由那些能够按时偿还贷款的企业组成; “信用差”的小组是由那些不能按时偿还贷款的企业组成. 我们从每个小组中选取 40 个样本, 训练集是由每个小组中的 25 个

样本构成, 因此训练集含有 50 个样本, 余下的 30 个样本构成测试集. 我们将考虑能反映贷款企业的还款能力、盈利能力、经营效率、经营周转率和资本结构等的 7 个财务比率:

1) 反映企业资本结构

$$x_1 = \text{负债比率} = \frac{\text{负债总额}}{\text{资产总额}}$$

2) 反映企业的盈利能力

$$x_2 = \text{主营业务净利润率} = \frac{\text{净利润}}{\text{主营业务收入}},$$

$$x_3 = \text{净资产收益率} = \frac{\text{销售收入净额}}{\text{净资产}} =$$

$$\frac{\text{销售收入净额}}{\text{资产总额} - \text{负债总额}}.$$

3) 反映企业的偿债能力

$$x_4 = \text{流动比率} = \frac{\text{流动资产}}{\text{流动负债}},$$

$$x_5 = \text{速动比率} = \frac{\text{速动资产}}{\text{流动负债}} = \frac{\text{流动资产} - \text{存货}}{\text{流动负债}}.$$

4) 反映企业经营效率

$$x_6 = \text{存货周转率} = \frac{\text{产品销货成本}}{\text{平均存货}},$$

$$x_7 = \text{应收帐款周转率} = \frac{\text{销售净额}}{\text{应收帐款总额}}.$$

其中企业的资本结构是企业的总负债在总资产中所占的比例. 盈利能力是企业赚取利润的能力, 一般只涉及正常的经营状况, 如主营业务的盈利状况等. 企业的偿债能力反映企业拥有债权的安全程度及企业到期偿还债务的能力, 如果企业到期无法偿还债务, 将面临破产的危险. 经营效率指标是用来衡量企业在资产管理方面的效果, 可与企业前期、行业平均水平或其他类似企业的指标进行对比.

我们定义两类错误: 第一类错误是将“信用差”的贷款企业误判为“信用好”的贷款企业; 第二类错误是将“信用好”的贷款企业误判为“信用差”的贷款企业.

为了确定网络结构, 我们在 Matlab 神经网络工具箱中输入贷款企业的 7 个指标变量值和相应的目标值, 可得如下 BP 网络结构: 输入层含有 7 个结点, 隐层含有 4 个结点, 输出层含有 1 个结点(见图 1).

根据图 1 的网络结构, 可得到基于 BP 算法的信用风险评价模型如下:

$$y = g\left(\sum_{j=1}^4 v_j g\left(\sum_{i=1}^7 w_{ji} x_i + b_j\right) + b\right). \quad (1)$$

模型(1)可用向量表示为

$$y = g(Vg(W^T X + B_1) + B_2).$$

其中 $X = (x_1, x_2, \dots, x_7)^T$ 是输入向量, Y 是输出向量, $W = (w_{ij})_{7 \times 4} (i = 1, 2, \dots, 7, j = 1, 2, 3, 4)$ 是输入层和隐层之间的连接权, $V = (v_1, v_2, v_3, v_4)$ 是隐层和输出层之间的连接权, $B_1 = (b_1^{(1)}, b_2^{(1)}, b_3^{(1)}, b_4^{(1)})^T$ 和 $B_2 = (b)$ 分别是隐层和输出层的偏置权向量, 隐层结点的传递函数及网络输出函数 $g(h)$ 均采用 logistic 函数, 即

$$g(h) = \frac{1}{1 + \exp(-h)}.$$




图1 BP网络结构

Fig. 1 BP network structure

3 仿真结果分析 (Simulating results analysis)

设定误差指标值为 $e = 0.01$, 取学习率 $\eta = 2$,

表1 3种训练方式的最大误差值

Table 1 Maximal errors of the three training methods

	训练集						测试集					
	“信用好”的小组			“信用差”的小组			“信用好”的小组			“信用差”的小组		
训练次数	100	390	800	100	390	800	100	390	800	100	390	800
$e(k)_{\max}$	0.0045	0.0193	0.0007	0.0587	0.0006	0.0001	0.0045	0.0193	0.0007	0.0586	0.0006	0.0001

3种训练方式的误差曲线和学习率分别见图2~4.




图2 均方误差及学习率

Fig. 2 Mean-error and learning rate




图3 均方误差及学习率

Fig. 3 Mean-error and learning rate

将80个样本分为训练样本(50个)和测试样本(30个), 然后对BP网络分别训练100次、390次和800次. 设 k 表示网络训练次数, 此处 k 分别取100, 390, 800(下同). 当网络训练 k 次时, 设样本输出值为 $y(k)$, 原目标值为 t , 用 $e(k)_{\max}$ 表示样本输出值与原目标值之间的最大误差绝对值, 即

$$e(k)_{\max} = \max\{|y(k) - t|\}. \quad (2)$$

再将 k 次训练的最大总误差 $E(k)$ 定义为

$$E(k) = \max\{\max\{e(k)_{\text{good}}^{\text{train}}, e(k)_{\text{good}}^{\text{test}}\}, \max\{e(k)_{\text{bad}}^{\text{train}}, e(k)_{\text{bad}}^{\text{test}}\}\}. \quad (3)$$

其中 $e(k)_{\text{good}}^{\text{train}}$ 表示对训练样本训练 k 次时, “信用好”的小组其输出值与原目标值的最大误差绝对值; $e(k)_{\text{good}}^{\text{test}}$ 表示对测试样本训练 k 次时, “信用好”的小组其输出值与原目标值的最大误差绝对值; $e(k)_{\text{bad}}^{\text{train}}$ 表示对训练样本训练 k 次时, “信用差”的小组其输出值与原目标值的最大误差绝对值; $e(k)_{\text{bad}}^{\text{test}}$ 表示对测试样本训练 k 次时, “信用差”的小组其输出值与原目标值的最大误差绝对值.

将以上3种训练方式的样本输出值与原目标值的最大误差绝对值 $e(k)_{\max}$ 列于表1中.




图4 均方误差及学习率

Fig. 4 Mean-error and learning rate

利用最大总误差值来衡量 BP 算法网络的分类能力.表2列出了 BP 算法网络3种训练方式的分类结果、总误判率、正确率及最大总误差值.

表2 3种训练方式的总误判、正确率及最大总误差值

Table 2 The total misclassification, accuracy rate and the maximal errors of the three training methods

训练次数	训练集(50个样本)		测试集(30个样本)		总误判	正确率/%	最大总误差值
	第1类错误	第2类错误	第1类错误	第2类错误			
100	1(2%)	0(0%)	0(0%)	0(0%)	1(1.25%)	98.75	0.0587
390	0(0%)	1(2%)	0(0%)	0(0%)	1(1.25%)	98.75	0.0193
800	0(0%)	1(2%)	0(0%)	0(0%)	1(1.25%)	98.75	0.0007

4 BP 网络学习算法和步骤(Learning algorithm and steps of the BP network)

假设在第 k 次迭代中,样本输出值 $y(k)$ 与原目标值 t 之间的最大误差绝对值 $e(k)_{\max}$ 如式(2)定义,最大总误差 $E(k)$ 如式(3)定义,则 $E(k)$ 关于 $W(k)$ 的梯度为

$$\nabla(E(k))|_{W(k)} = \frac{\partial E(k)}{\partial W(k)} = \frac{\partial E(k)}{\partial Y(k)} \cdot \frac{\partial Y(k)}{\partial W(k)} = -e(k) \cdot g'(U(k)) \cdot V \cdot g'(W(k)^T X + B_1(k))^T \cdot X.$$

$E(k)$ 关于 $V(k)$ 的梯度为

$$\nabla(E(k))|_{V(k)} = \frac{\partial E(k)}{\partial V(k)} = \frac{\partial E(k)}{\partial Y(k)} \cdot \frac{\partial Y(k)}{\partial V(k)} = -e(k) \cdot g'(U(k)) \cdot g(W(k)^T X + B_1(k))^T.$$

据最小均方误差(LMS)算法,连接权值的修正向着误差梯度反方向进行.令 η 为修正步长,则输入层和隐层之间的连接权值以及隐层与输出层之间的连接权值可分别按如下公式进行修正:

$$\Delta W(k) = \eta e(k) \cdot g'(U(k)) \cdot V.$$

由表2知,3种训练方式的分类准确率都是一样的(98.75%),但最大总误差值各不相同.当网络训练100次时,最大总误差值为0.0587,没有满足误差指标预先设定值 $e = 0.01$ 的要求;当网络训练390次时,最大总误差值为0.0193,由于 $0.0193 > 0.01$,所以仍不满足误差指标预先设定值 $e = 0.01$ 的要求;而当网络训练800次时,最大总误差值为0.0007,由于 $0.0007 < 0.01$,所以满足误差指标预先设定值的要求.由此我们认为,当网络训练800次时,目标函数达到最优,网络分类的准确率在远远小于预定的误差值 $e = 0.01$ 达到98.75%.

实验结果表明,对训练样本来讲,第一类误判个数为0,第二类误判个数为1,误判率为2%,分类准确率达到98%.对测试样本来讲,第一类和第二类误判个数都为0,误判率为0%,分类准确率达到100%.因此,对两类样本而言,总的误判个数为1,总的误判率为1.25%,这表明BP算法网络的分类准确率达到98.75%.

$$g'(W(k)^T X + B_1(k))^T \cdot X,$$

$$\Delta V(k) = \eta e(k) g'(U(k)) [g(W(k)^T X + B_1(k))^T]^T$$

由此得到基于BP算法的网络学习算法和步骤:

i) 将网络中的连接权值和偏置权值初始化(也可由随机数产生);

ii) 如果最大总误差 $E(k)$ 满足预先设定的精度 e ,则终止迭代;否则,需按如下公式修正权值:

$$W(k+1) = W(k) + \eta e(k) \cdot g'(U(k)) \cdot V.$$

$$g'(W(k)^T X + B_1(k))^T \cdot X,$$

$$V(k+1) =$$

$$V(k) + \eta e(k) g'(U(k)) [g(W(k)^T X + B_1(k))^T]^T.$$

iii) 重复第ii)步,一直进行到达到所要求的精度 e 为止.

5 结论(Conclusion)

建立了基于BP算法的神经网络信用风险评价模型,用来对我国某国有商业银行2001年80家贷款企业进行信用评级.按照他们的财务状况、经营状况以及过往的信用记录分为“信用好”和“信用差”两

个小组,每个小组含有 40 个数据样本,训练集是由每个小组中的 25 个样本组成,测试集由余下的 30 个样本组成。

本文利用 BP 算法来解决此分类问题,对该 BP 网络进行 3 种方式的训练:训练 100 次、训练 390 次和训练 800 次。仿真结果表明,按照这 3 种方式进行训练时,网络分类正确率均达到 98.75%,但网络最大总误差值不相同。当网络训练 100 次及 390 次时,网络最大总误差值分别为 0.0587 和 0.0193,均比误差指标预先设定值 0.01 大,故都不符合要求。但当网络训练 800 次时,网络最大总误差值为 0.0007,远远小于误差指标预先设定值 0.01,故满足误差精度的要求。由此说明,当网络训练 800 次时,网络达到一定的稳定状态,目标函数值达到最优,分类准确率在远远小于预先给定的精度 0.01 达到 98.75%。

参考文献(References):

- [1] TAM K Y, KIANG M. Predicting bank failures: A neural network approach [J]. *Management Science*, 1992, 38(7): 927 - 947.
- [2] JENSEN H L. Using neural networks for credit scoring [J]. *Managerial Finance*, 1992, 18(6): 15 - 26.
- [3] COATS P, FANT L. Recognizing financial distress patterns using a neural network tool [J]. *Financial Management*, 1993, 3: 142 - 155.
- [4] ALTMAN E I. Corporate distress diagnosis: comparisons using linear discriminant analysis and neural networks (the Italian experience) [J]. *Banking and Finance*, 1994, 18: 505 - 529.
- [5] HASHEMI R R, LE BLANC L A, RUCKS C T, et al. A hybrid intelligent system for predicting bank holding structure [J]. *European Journal of Operational Research*, 1998, 109: 390 - 402.
- [6] WEST D. Neural network credit scoring models [J]. *Computers & Operations Research*, 2000, 27: 1131 - 1152.
- [7] MALHOTRA R, MALHOTRA D K. Differentiating between good credits and bad credits using neuro-fuzzy systems [J]. *Computing, Artificial Intelligence and Information Technology*, 2002, 136: 190 - 211.
- [8] 王春峰, 万海晖, 张维. 基于神经网络技术的商业银行信用风险评估[J]. *系统工程理论与实践*, 1999, 1(1): 68 - 72.
(WANG Chunfeng, WAN Haiwang, ZHANG Wei. Credit risk assessment in commercial banks using neural networks [J]. *Systems Engineering - Theory & Practice*, 1999, 1(1): 68 - 72.)
- [9] 郝丽萍, 胡欣悦, 李丽. 商业银行信贷风险分析的人工神经网络模型研究[J]. *系统工程理论与实践*, 2001, 21(5): 62 - 69.
(HAO Liping, HU Xinyue, LI Li. Research on the artificial neural network model for the credit risk analysis of commercial banks [J]. *Systems Engineering - Theory & Practice*, 2001, 21(5): 62 - 69.)
- [10] 杨保安, 季海. 基于人工神经网络的商业银行贷款风险预警研究[J]. *系统工程理论与实践*, 2001, 21(5): 70 - 74.
(YANG Baoan, JI Hai. A study of commercial bank loans risk early warning based on BP neural network [J]. *Systems Engineering - Theory & Practice*, 2001, 21(5): 70 - 74.)
- [11] 庞素琳, 王燕鸣, 黎荣舟. 基于 BP 算法的信用风险评价模型研究[J]. *数学的实践与认识*, 2003, 33(8): 48 - 55.
(PANG Sulin, WANG Yanming, LI Rongzhou. Credit-risk evaluation model based on back-propagation algorithm [J]. *Mathematics in Practice and Theory*, 2003, 33(8): 48 - 55.)

作者简介:

庞素琳 (1964—), 女, 博士(后), 暨南大学数学系副教授, 硕士生导师。主要研究领域包括金融工程、神经网络、模式识别、最优化理论与应用, E-mail: pangsulin@163.com;

黎荣舟 (1966—), 男, 博士, 上海浦东发展银行广州分行市场部总经理, 主要研究领域包括金融理论与金融工程, 神经网络技术, 风险管理与分析, E-mail: rzli@163.com;

徐建闽 (1960—), 男, 博士, 华南理工大学教授, 博士生导师, 研究领域为复杂系统控制及应用、智能交通系统、道路交通信息工程, E-mail: aujmxu@scut.edu.cn.