

商业银行信用风险评估预测模型研究

于立勇

(北京大学光华管理学院, 北京 100871)

摘要:依据商业银行信用风险的内涵,指出信用风险评估应当充分考虑信贷资金安全系数的不确定性和信用风险的相对性特征,并以“信用风险度”作为系统的输出,构建了基于人工神经网络的信用风险评估预测模型,为有效转变信用风险的分类型评估模式,提供更为全面的信贷决策支持奠定了基础。

关键词:信用风险评估; 分类评估模式; 信用风险衡量标准; 信用风险度

中图分类号: F830.5

文献标识码: A

文章编号: 1007-9807(2003)05-0046-07

0 引言

商业银行在金融体系中占有举足轻重的地位,在创造货币存款、实现金融政策效率、社会投资实现等方面都发挥着核心作用。然而,商业银行在营运过程中无时无刻不面临着各种金融风险,巴塞尔银行监管委员会在1997年9月公布的《有效银行监管的核心原则》中,将银行业面临的主要风险归纳为8个方面,即信用风险、国家和转移风险、市场风险、利率风险、流动性风险、操作风险、法律风险和声誉风险。其中,信用风险占有特殊的地位,世界银行对全球银行业危机的研究表明,导致银行破产的最常见原因就是信用风险^[1]。

信用风险是指信贷资金安全系数的不确定性,表现为企业由于各种原因,不愿意或无力偿还银行贷款本息,使银行贷款无法回收,形成呆账的可能性^[2]。

信用风险评估是商业银行信用风险管理的首要工作和关键环节,事关银行的生存和社会的稳定。发达国家对信用风险度量和管理研究的关注程度越来越高,再加上以东南亚诸国为首的发展中国家对信用风险的关心,相信信用风险的度量和管理的必将成为21世纪风险管理研究中最具挑

战的课题^[3]。

长期以来信用风险评估一直被看作是模式识别中的一类分类问题,依据的信用风险衡量标准是贷款企业“违约与否”,利用的是模型与方法的分类功能,形成信用风险的分类型评估模式,这种做法被称为“粗暴的经验主义方法”^[4]。然而,目前这种分类型评估模式和衡量标准未能充分反映信用风险的实质(信贷资金安全系数的不确定性),传统衡量标准对信用风险的度量客观上存在较为突出的“间接性”。另外,“违约与否”有限的取值(“0”和“1”)也难以精确刻画信用风险的“暴露程度”,分类型评估模式所反映的有限的经济信息并不能充分满足信贷风险决策的需要,转变评估模式的关键在于确立更为有效、客观的信用风险衡量标准和评估预测模型,而信用风险衡量标准的构建应当以测度信贷资金安全系数为核心,充分考虑信贷资金形成呆账的可能性在信用风险评估中的重要意义。本文在评析传统信用风险衡量标准和分类型评估模式的基础上,依据信用风险的内涵,从信用风险评估的目的出发,提出以信用风险度作为新的衡量标准,并构建了基于人工神经网络的信用风险评估预测模型,实证分析结果表明,模型可以较为客观、准确地测度信贷资金形成呆账的可能

收稿日期:2001-10-24; 修订日期:2003-06-25.
基金项目:国家社会科学基金资助项目(02BJY126).
作者简介:于立勇(1974—),男,山东黄县人,博士后。

性,是一种较为有效的信用风险衡量工具。

1 信用风险评估方法与模型概述

从20世纪30年代以来,商业银行信用风险的评估方法大致经历了比例分析、统计分析和人工智能三个发展阶段,我国商业银行信用风险管理起步较晚,信用风险评估仍然沿袭传统的比例分析模式。

传统的信用风险衡量标准将商业银行信用风险与贷款企业“违约与否”等同起来,采用所谓的“经济主义方法论”^[5],其基本思想是,通过研究并挖掘“违约类”(到期未还本付息)企业样本和“非违约”类企业样本的基本特征,建立判别公式,进而对新样本分类。

较为早期的信用风险评估方法(如主观分析法和财务比例分析法)在对贷款企业进行判别时,往往存在主观臆断性较强,缺乏客观评价基础等不足,而基于严谨统计分析的信用风险评估方法得到了更为广泛的应用。

在Fisher做出了启发性的研究之后^[6],多元判别分析^[7]、多元回归分析、Logistic回归、Factor-logistic法、数学规划、K临近判别^[8]、贝叶斯决策模型、聚类分析^[9]、存活分析等方法得到大量应用。这些统计模型的判别函数和样本分布的假设前提不尽相同,它们较为突出的优点在于具有较强的解释性,模型中变量的系数都具有一定的涵义,缺点在于统计方法一般都有较为严格的前提假设,如应用最多的多元判别分析要求样本数据服从正态分布、等协方差,且协方差、错分成本和先验概率均要已知等^[10],但现实中许多数据难以满足这些要求。虽然可以采用对数变换、二次差别分析等一些必要的技术手段和方法加以改进,但这些方法应用的同时又会相应地产生变量经济涵义不清等新的问题。

随着信息技术的发展,近年来人工智能(AI)模型被引入信用风险评估中。神经网络方法作为一种具有自组织、自适应、自学习特点的非参数方法,对样本数据的分布要求不严格,不仅具有非线性映射能力和泛化能力,而且有较强的“鲁棒性”和较高的预测精度,这些都促使神经网络在信用风险评估领域取得了长足的发展,如模式神经网

络、概率神经网络、扩展的学习向量量化器和多层感知机等先后得到应用^[11, 12]。但神经网络也有自身的缺点,主要集中在网络结构确定较为困难,训练效率低下和解释能力差等方面。同样,虽然决策树方法^[13]可以通过对历史样本的学习构造出决策型的知识表示,与统计分析方法相比,显得更为直观、易理解,而且对专业知识没有较高要求,但其建模过程中经常出现的组合爆炸、过渡拟合等现象也制约了其进一步的发展。

针对神经网络的不足,许多学者做了大量有益的尝试,如通过采用一些改进算法使由于局部无穷小、训练瘫痪、收敛速度慢等原因导致神经网络训练效率低下的问题在一定程度上得以解决;另外,通过引入模糊逻辑、误差函数的偏导数等方法增强了神经网络的解释能力。Green和Smith运用遗传算法来研究信用风险评估问题^[14],鉴于遗传法定长编码机制的局限性,王春峰等人采用遗传规划方法取得了较好的效果^[15]。

不难发现,虽然人工智能模型克服了统计方法对前提假设要求较强以及静态反映信用风险等缺点,但它们评估信用风险的衡量标准始终是企业“违约与否”(或是其他有限个风险类别),模型利用的都是各自对样本的分类功能,因此这些模型都可以归结为分类评估模型,其中,衡量标准的离散性是信用风险评估采用分类评估模式的主要原因。传统信用风险的分类评估模式虽然在特定历史阶段和环境起到了较为积极的作用,但其自身的低效性已经不能满足日益复杂的信贷风险决策的需要,而实现评估模式有效转变的关键在于确立更为科学、有效的信用风险衡量标准,并依此构建信用风险的评估预测模型。

2 信用风险度的确立

2.1 信用风险衡量标准的理论分析

依据商业银行信用风险的定义,可以看出信用风险的实质是信贷资金安全系数的不确定性,这种不确定性实际强调的是信贷资金形成呆账的可能性,而形成信用风险的原因在于贷款企业无力或不愿清偿贷款本息。因此,评估信用风险不仅要分析贷款企业的还款意愿和还款能力,更要测度特定还款能力和还款意愿所对应的信贷资金安

全系数的不确定性,确定信贷资金形成呆账的可能性,这是信用风险内涵的本质要求,也是信用风险评估的主要目的.仅评估贷款企业还款能力和还款意愿而不能确定信贷资金安全系数(或贷款形成呆账可能性)的信用风险评估并没有将信用风险评估进行到底,不能充分实现信用风险评估的目的.因此,信用风险衡量标准的构建应当充分考虑“信贷资金形成呆账的可能性”在信用风险评估中的重要意义.

信贷资金形成呆账的可能性不仅由贷款企业还款能力和还款意愿决定,贷款方式对信贷资金的安全系数也有重要影响.从发放信贷资金到最终回收贷款本息(或形成呆账)的过程中,贷款方式可以通过第二还款来源减少贷款损失,而不同的贷款方式对信贷资金损失的防范作用是不同的,因此,即便相对于同一贷款企业而言,不同贷款方式所对应的信用风险也是不同的,从这个角度讲,信用风险其实是一个“相对”概念,即信用风险的评估结果应是相对特定贷款方式的量化值,信用风险的衡量标准应当能够体现信用风险的“相对性”特征.

在信用风险衡量标准中,贷款企业“违约与否”一直占据着主导地位,这种做法简单明了,判别标准较易掌握,更重要的是许多评估方法和技术手段都可以应用,提高了信用风险评估的可操作性,促使信用风险评估方法得到深入的发展.然而,以“违约与否”作为衡量标准,也明显存在许多不足之处,主要体现在“违约与否”不能充分反映商业银行信用风险的实质和“相对性”特征.

商业银行信用风险的实质是信贷资金安全系数的不确定性,而非贷款企业违约与否,虽然两者间存在一定的内在联系,但并非完全等价,因为即便银行能够确知企业到期违约与否(或违约的概率)仍然难以测算该笔贷款形成呆账的可能性.另外,“违约与否”的取值仅有“0”和“1”两个,只能描述风险“暴露与否”,很难以此准确反映信用风险的具体“暴露程度”.而且鉴于信用风险的“相对性”特征,只要银行拥有足额易变通的抵押品,即使企业违约也不一定会形成贷款损失.因此,企业违约风险其实是商业银行信用风险的必要条件,而非充分条件.基于此种风险衡量标准的模型和方法更适合作为企业“违约风险”的“风险识别”工

具,而非商业银行“信用风险”的“风险衡量”工具.

2.2 信用风险度的提出

在综合考虑信用风险的实质及其相对性特征的基础上,本文从商业银行信用风险的定义出发,提出以“信用风险度”作为一种新的信用风险衡量标准.

信用风险度是一种以测度信用风险暴露程度(信贷资金安全系数)为核心的信用风险衡量标准,它是指在某一笔信贷业务中,在特定的贷款方式下,贷款企业由于各种原因,不愿意或无力偿还银行贷款本息而使贷款成为呆账的可能性.具体表现形式如下:

$$D_i^k = \frac{B_i^k}{S_i^k} \tag{1}$$

其中: D_i^k 为企业 k 在第 i 种贷款方式下的信用风险度; B_i^k 为企业 k 在第 i 种贷款方式下信贷资金形成呆账的数额; S_i^k 为企业 k 在第 i 种贷款方式下的贷款总额; $\sum_{i=1}^m S_i^k = S^k$, S^k 为企业 k 的贷款总额; i 为第 i 种贷款方式的序号.

不难发现,以信用风险度作为评估方法和模型的输出具有如下特点:

第一,以信用风险度衡量信用风险具有“直接性”,它可以直接较为准确地反映信用风险的实质(信贷资金的安全系数或形成呆账的可能性);

第二,信用风险度的取值不再是离散的若干个有限的值,而是“0”到“1”的整个连续闭区间($[0, 1]$),从而能够更为精确地刻画风险的暴露程度;

第三,信用风险度注重贷款方式的重要作用,强调了信用风险的“相对性”特征;

第四,信用风险度具有“可验证性”和“客观性”,其评估结果可以通过事后的考察与测算得以验证.

与传统信用风险衡量标准相比,信用风险度的优越性如表1所示.

表1 信用风险度与传统衡量标准的比较

	企业违约与否	企业违约概率	信用风险度
直接性	企业违约风险	企业违约风险	信用风险
连续性	{0,1} 两个值	[0,1]	[0,1]
相对性	无	无	具备
客观性	客观,可验证	较难验证	客观,可验证

3 基于 Levenberg-Marquardt 算法的前向神经网络模型

3.1 前向人工神经网络

神经网络是由按层进行组织的神经元和连接弧所组成的,这些神经元以不同的方式组织起来形成不同的网络结构,几种常用的网络结构包括前向网络、反馈网络、相互结合型网络、混合型网络等等,其中前向网络应用较为广泛,而且对于函数的估计具有较好的性能。

在前向网络中有三种神经元:输入神经元、输出神经元和隐含神经元。输入神经元接受环境的信息,位于网络的最底层;输出神经元把信息传递到环境中去,位于网络的最高层;隐含神经元不与环境发生交互作用。神经元间前向连接,同层神经元互不连接,信息只能向着一个方向传播。每个神经元都是一个简单的计算装置,其特性由简单的数学函数所描述。神经元 i 接收其他神经元传递来的输入信息,根据和函数 net_i 进行加权平均,然后根据激励函数 f_i 产生输出信息,输出信息又按照网络的拓扑结构传递到下一个神经元。

前向网络的连接模式是用权值向量表示的,权值向量决定着网络如何对环境中的任意输入做出反应,网络中每一条连接弧都被赋予一定的数值来表示连接弧的连接强度。正的权值表示影响增加,负的权值表示影响减弱,网络通过不断调整权值完成整个学习过程。

3.2 Levenberg-Marquardt 算法

传统的BP算法通常存在收敛速度慢、容易陷入局部无穷小等缺陷,为此,本文采用 Levenberg-Marquardt (LM) 算法训练前向神经网络。LM算法比梯度下降法要快得多,但是它需要更多的内存。

设误差平方和为

$$E = \frac{1}{2} \sum_p (e_p)^2 = \frac{1}{2} \sum_p \left(\sum_i z_{pi} (w_i^{\text{new}} - w_i^{\text{old}}) \right)^2 \quad (2)$$

其中 p 是第 p 个样本的序号, z_{pi} 是以 z_{pi} 为元素的向量。假设当前位于 w^{old} ,并向新位置 w^{new} 移动,如果移动量 $w^{\text{new}} - w^{\text{old}}$ 很小,则可将 E 展成一阶 Taylor 级数

$$E(w^{\text{new}}) \approx E(w^{\text{old}}) + Z(w^{\text{new}} - w^{\text{old}}) \quad (3)$$

其中, Z 为误差对权值微分的 Jacobian 矩阵,其构成元素为

$$(Z)_{pi} = \frac{\partial e_p}{\partial w_i} \quad (4)$$

于是误差函数可写成

$$E = \frac{1}{2} \sum_p (w^{\text{old}})^2 + Z(w^{\text{new}} - w^{\text{old}})^2 \quad (5)$$

对 w^{new} 求导以使 E 最小,可得

$$w^{\text{new}} = w^{\text{old}} - (Z^T Z)^{-1} Z^T (w^{\text{old}}) \quad (6)$$

其中 T 代表矩阵的转置。

由 E 的表达式(2),其 Hessian 阵的元素为

$$H_{ik} = \frac{\partial^2 E}{\partial w_i \partial w_k} = \sum_p \left[\frac{\partial^2 e_p}{\partial w_i \partial w_k} + \frac{\partial e_p}{\partial w_i} \frac{\partial e_p}{\partial w_k} \right] \quad (7)$$

若忽略其中第 2 项,则 Hessian 阵可表示为

$$H = Z^T Z \quad (8)$$

可见(6)中包含了 H^{-1} ,这与牛顿方向是一致的,但其中给出的步长可能过大,为此把误差表达式改写成为

$$E = \frac{1}{2} \sum_p (w^{\text{old}})^2 + Z(w^{\text{new}} - w^{\text{old}})^2 + \lambda (w^{\text{new}} - w^{\text{old}})^2 \quad (9)$$

求 E 对 w^{new} 的极小点,可得

$$w^{\text{new}} = w^{\text{old}} - (Z^T Z + \lambda I)^{-1} Z^T (w^{\text{old}}) \quad (10)$$

当 λ 很小时,变为牛顿法, λ 很大则成为梯度下降法(此时步长为 λ^{-1})。实际计算过程中通过反复测算 E 的变化来调节 λ 的大小,直到 E 合乎要求为止。

4 样本数据和模型构建

4.1 指标体系和样本数据

以某国有商业银行为例,选择同一行业(制造业)的企业客户为研究对象,考察它们的短期贷款清偿情况。所选用的指标主要是借鉴我国财政部统计评价司的企业绩效评价指标和中国工商银行企业资信评估指标以及国内外有关文献的相关指标,在分类、汇总、整理的基础上,同时兼顾数据的可获取性原则和可量化原则,最终确定流动比率、速动比率、超速动比率、营运资金/资产总额、资产负债率、净资产收益率、资产收益率、销售收入/资产总额、成本费用利润率、存货周转率、应

收账款周转率、总资产周转率、流动资产周转率、固定资产周转率、销售净利率、贷款方式等 16 项输入指标,其中贷款方式的量化结果是依据人民银行确定的贷款方式风险系数确定的,模型的输出为信用风险度,通过这些指标可以在突出反映企业偿债能力的同时较为全面地刻画企业的资信状况。

调查范围涉及贷款发放金额合计 160 余亿元人民币,从中获取信贷交易 636 笔,删除奇异样本 76 笔,最终得到有效信贷交易样本 560 笔。由于同一贷款企业可以发生多笔信贷交易,而且每笔交易的贷款方式(本文依据我国商业银行通用的划分方法,将贷款方式分为信用、保证和票据贴现等三种)可以不同,实际涉及贷款企业近 200 个。在此基础上,为了化简输入指标数据并排除部分指标之间存在的相关性,本文采用 SPSS 软件包对这些数据进行了因子分析。

首先对各项指标数据进行标准化处理,标准化后的变量分别为 x_1, x_2, \dots, x_k , 其中 x_i 为具有零均值、单位方差的标准化变量, $k = 16$ 。

在因子分析之前还需要进行巴特利特球体检验(Bartlett test of sphericity)和 KMO(Kaiser-Meyer-Olkin measure of sampling adequacy)测度,测试结果

果如表 2 所示。

表 2 KMO 测度和巴特利特球体检验

Kaiser-Meyer-Olkin Measure of Sampling Adequacy		0.751
Bartlett's Test of Sphericity	Approx. Chi-Square	14 352.118 8
	Df	120
	Sig.	0.000

由表 2 可知,两项测度指标均显示有必要对模型输入指标进行因子分析。本文采用主成分分析法求解初始因子,依据特征值准则(取特征值大于等于 1 的主成分作为初始因子),因子个数应该确定为 4,根据碎石检验准则(Scree Test Criterion)也得到同样的结论,而此时因子累计解释方差的比例可以达到 74% 以上,保留了原有数据的主要经济信息,并且各因子经济含义较为明确,表明因子个数的确定较为适宜。

由于在因子负载矩阵中,相对于 0.3 的负载而言,变量的方差能够被该因子解释的部分不足 10%,所以对于绝对值小于 0.3 的负载一般可以不予解释。为突出各因子的经济含义,对于绝对值小于 0.3 的负载在下面的因子负载矩阵表中并未予以显示。

表 3 因子负载矩阵和因子得分系数矩阵

序号	指标	1	2	3	4	1	2	3	4
1	销售收入 / 总资产	0.966				0.195	0.052	- 0.033	0.032
2	总资产周转率	0.966				0.195	0.052	- 0.033	0.032
3	流动资产周转率	0.953				0.192	0.022	- 0.038	- 0.009
4	固定资产周转率	0.843				0.170	0.076	- 0.029	0.064
5	存货周转率	0.819				0.165	0.025	- 0.045	0.104
6	应收账款周转率	0.755				0.152	- 0.037	- 0.014	- 0.227
7	流动比率		0.899			- 0.032	0.276	0.009	- 0.053
8	营运资金 / 总资产		0.891			- 0.040	0.273	0.014	- 0.136
9	速动比率		0.782			- 0.038	0.240	0.004	0.249
10	超速动比率		0.750			- 0.024	0.230	0.007	0.230
11	资产负债率		- 0.566		0.353	0.012	- 0.174	0.004	0.338
12	成本费用利润率			0.879		0.048	0.005	0.325	0.037
13	销售净利率			0.843		0.050	0.005	0.312	0.045
14	资产收益率			0.823		0.009	0.009	0.304	- 0.117
15	净资产收益率			0.694		0.007	- 0.022	0.257	- 0.065
16	贷款方式				0.821	- 0.004	- 0.028	0.037	0.786

由表 3 不难看出各因子的经济含义较为明确,而且因子与指标间的内在联系比较显著,各因子依次可以归结为营运能力因子、偿债能力因子、盈利能力因子和贷款方式因子。

4.2 模型构建

为了测算简便,在神经网络模型的实证过程中随即选取 50 个企业作为测试集,并在剩余样本集中随机选取 100 个企业构成训练集,从而在不失一般性的基础上有效地减少了运算量。

神经网络模型的构建主要需要考虑两个方面的问题:网络结构的确定和学习参数的设定。网络结构中网络的层数、各层神经元的数量和适用的激励函数是需要明确的主要任务。Hecht Nielsen 曾证明当各节点具有不同的阈值时,对于在任何

闭区间内的一个连续函数都可以用一个隐含层的网络来逼近,但由于上述先决条件难以满足,实践中常导致应用的困难。目前一般认为对于二进制分类或判决边界问题,一个隐含层就足够了,但是如果要求输出是输入的任意连续函数,采用两个隐含层或者不同的激励函数则更为有效^[16]。

依据上述分析,本文在设定相同模型参数(最大循环次数为 1 000,目标误差为 0.001、最小梯度为 0.000 1, 的初始值为 0.001, 的增加系数为 10、的减小系数为 0.1、的最大值为 1e10)的条件下,通过试值法测试隐含层的层数、节点数、激励函数类型对网络性能的影响,测试结果如下表所示(为了简化测算,对于含有两个隐含层的网络结构,假设各隐含层所含神经元个数相同)。

表 4 隐含层数、节点数、激励函数类型的影响

Nodes	MAPE/ %	Nodes	MAPE/ %	Nodes	MAPE/ %	Nodes	MAPE/ %
T8L8	19.52	L8T8	20.11	T16	22.29	L16	23.24
T9L9	17.58	L9T9	16.48	T18	22.53	L18	21.78
T10L10	10.74	L10T10	11.53	T20	19.79	L20	19.05
T11L11	13.96	L11T11	14.14	T22	18.25	L22	20.21
T12L12	13.72	L12T12	16.76	T24	20.01	L24	19.35
T13L13	16.09	L13T13	17.14	T26	21.09	L26	21.87
T14L14	15.57	L14T14	14.35	T28	21.84	L28	21.26

其中:Nodes 表示网络隐含层节点数; $MAPE = \frac{1}{N} \left| \frac{e_i}{y_i} \right|$, y_i 表示实际值, e_i 表示预测误差, N 表示样本数,其他相关误差指标 (SSE, MAE, MSE 等) 限于篇幅未列出。T8L8 表示第一、二隐含层分别由 8 个双曲正切 sigmoid 函数神经元和 8 个对数 sigmoid 函数神经元构成。同理, T16 表示网络含有一个隐含层,并且该隐含层由 16 个双曲正切 sigmoid 函数神经元构成。

基于上表预测误差的比较分析,最终确立如下网络结构:网络包括四层,其中含有两个隐含层,分别依次使用双曲正切 sigmoid 函数和对数 sigmoid 函数,网络的输出层由 1 个线性神经元构成,输入层有 4 个神经元。

本网络的编写与训练是应用 Matlab 5.3 中的

神经网络工具箱实现的。

5 结果分析

通过反复测试与比较,针对本文的实证数据,可以得到如下分析结果:

(1) 相对于隐含层含有同等数量神经元的网络结构,具有不同激励函数的双隐含层网络预测精度总体优于只含有一个隐含层的网络;

(2) 对于具有单隐含层的神经网络,隐含层神经元使用不同类型的激励函数(双曲正切 sigmoid 函数或对数 sigmoid 函数)其预测精度并无显著差异;

(3) 对于具有两个隐含层的神经网络,选择不同类型的激励函数对预测精度有一定影响,两个

隐含层的神经元依次使用双曲正切 sigmoid 激励函数和对数 sigmoid 激励函数要相对优于相反的排布顺序;

(4) 隐节点数为 20 时对各种网络结构都比较适合, 隐节点的继续增加并无助于预测精度的提高, 而且要耗费大量的机时。

本文提出的基于 LM 算法的前向神经网络, 第 1 层隐元采用双曲正切 sigmoid 激励函数将神经元的输入范围由 $(-\infty, +\infty)$ 映射到 $(-1, +1)$, 而第 2 层隐元的对数 sigmoid 函数又进一步将上一隐含层的输出结果映射到 $(0, +1)$ 的区间上, 由于其映射区间较为贴近“信用风险度”的输出范围, 故这种激励函数的选择与排布顺序将更有利于稳定并提高模型的预测功能, 输出层的神经元采用纯线性激励函数可以将隐含层的输出结果重新映射到 $(-\infty, +\infty)$, 因此, 确保了网络对任意输出结果的逼近, 当然也满足信用风险度 $[0, 1]$ 的输出要求。

6 结束语

本文在深入分析传统信用风险衡量标准和分类评估模式的基础上, 依据信用风险的内涵, 从信

用风险评估的目的出发, 提出以信用风险度作为信用风险评估预测模型的输出, 并构建了基于 LM 算法的神经网络模型。实证分析结果表明, 模型可以较为准确、客观地测度信用风险的具体暴露程度(信贷资金安全系数的不确定性), 对有效转变传统信用风险分类评估模式做了一次有益的尝试。

值得注意的是, 基于“违约与否”的传统信用风险评估结果其实可以近似地看作是本文评估结果的一个特例。基于信用风险度的评估结果不仅能够区分信贷资金将来是否损失, 还能够具体辨别信贷资金将来损失的程度, 而传统信用风险评估结果仅可以判断信贷资金损失与否(需要排除企业虽然违约而信贷资金并未损失的情况)。

以信用风险度作为信用风险评估模型的输出, 虽然较“违约与否”、“违约概率”等衡量标准更具合理性, 但要科学、准确地测度信用风险还需要进一步深入的研究。如对于信用风险度相同的两笔贷款业务, 由于企业在还款时间等其他影响因素上存在差异, 信用风险暴露的程度不一定相同。因此, 为了使“信用风险度”更趋于合理化, 需要通过综合考虑贷款损失额、还款时间等因素, 进一步完善这一评估标准, 为商业银行切实提供信用风险的风险衡量工具。

参考文献:

- [1] 世界银行. 新兴市场经济中的商业银行[M]. 北京: 中国财经出版社, 1997
- [2] 曾国坚, 何五星. 银行风险论[M]. 北京: 中国计划出版社, 1995
- [3] Altman E I, Caoutte J B, Narayanan P. Credit risk measurement management: The ironic challenge in the next decade[J]. Financial Analysis Journal, 1998, (9): 7—11
- [4] Altman E I, Saunders A. Credit risk measurement: Development over the last 20 years[J]. Journal of Banking and Finance, 1998, (20): 1721—1742
- [5] 王春峰, 万海晖, 张维. 组合预测在商业银行信用风险评估中的应用[J]. 管理工程学报, 1999, 13(1): 5—8, 30
- [6] Fisher R A. The use of multiple measurements in taxonomic problems[J]. Ann. Eugenics, 1936, 7: 179—188
- [7] Altman E L. Financial ratios, discriminant analysis and the prediction of corporate bankruptcy[J]. Journal of Finance, 1968, 23(3): 589—609
- [8] Tam K Y, Kiang M. Managerial applications of neural networks: The case of bank failure predictions[J]. Management Science, 1992, 38: 927—947
- [9] Lundy M. Cluster analysis in credit scoring[A]. Credit Scoring and Credit Control[M]. New York: Oxford University Press, 1993. 25—36
- [10] Gordy M B. A comparative anatomy of credit risk models[J]. Journal of Banking and Finance, 2000, (24): 119—149
- [11] Thorsen Poddig. Bankruptcy prediction: A comparison with discriminant analysis[A]. Neural Networks in the Capital Markets[M]. edited by Apostolos Paul Refenes, 1992. 311—323

(下转第 98 页)

[82] 汤海鹏, 金海浩. 基于市场微观结构的证券市场分析[J]. 广西工学院学报, 1998, 9(4): 88—92

Survey of market microstructure theory

LI Ping, ZENG Yong, TANG Xiaowo

School of Management, University of Electronic Science and Technology of China, Chengdu 610054, China

Abstract: In the past twenty years, market microstructure has grown so dramatically that it is now a recognized sub-field within finance. Market microstructure research is valuable for illuminating the behavior of price and markets. This has immediate application in the regulation and design of new trading mechanisms. This paper systematically review the existent research on microstructure domestic and aboard. Then in term of market microstructure theory, we analyze the microstructure of the Chinese stock market, and bring forward some instructive proposals concerning the development of the Chinese stock market.

Key words: market microstructure; price behavior; trading mechanism

(上接第 52 页)

[12] 张 维, 李玉霜. 商业银行信用风险分析综述[J]. 管理科学学报, 1998, (9): 20—27

[13] Frydman H, Altman E I, Kao DuenLi. Introducing recursive partitioning for financial classification: The case of financial distress [J]. Journal of Finance, 1985, 40(1): 269—291

[14] Greene D P, Smith S F. A Genetic System for Learning Models of Consumer Choice[C]. Proceeding 2nd International Conference on GA. Hillsdale, 1987. 217—223

[15] 王春峰, 康 莉. 基于遗传规划方法的商业银行信用风险评估模型[J]. 系统工程理论与实践, 2001, 2: 73—79

[16] 袁曾任. 人工神经网络及其应用[M]. 北京: 清华大学出版社, 1999

Study on credit risk assessing and forecasting model in commercial bank

YU Li-yong

Guanghua School of Management, Peking University, Beijing 100871, China

Abstract: For a long time credit risk assessment has been regarded as one kind of classification issue of pattern identification, which could not fully meet the requirements of credit risk decision-making. In view of the connotation of credit risk, it is put forward that the probability that credit capital becomes bad debt and the relativity of credit risk should be taken into consideration to assess credit risk. By taking credit risk degree as system output, credit risk assessing and forecasting model based on artificial neural network is established so as to transform assessing mode in effect and provide credit decision-making with more efficient tools and support.

Key words: credit risk assessment; assessing mode by classification; criterion to evaluate credit risk; credit risk degree