

神经动力学模型在信用评级中的应用

孟庆福，邓宏雨

(吉林大学商学院，吉林 长春 130012)

摘要：本文主要介绍神经动力学模型在信用评级问题上的应用。首先简要说明什么是神经动力学；然后简介神经动力学模型中的 Hopfield 模型、BSB 模型和多层感知器 (MLP) 模型，再说明如何将神经动力学应用于信用分类问题；最后对这种应用做出评价。

关键词：神经动力学；神经网络；Hopfield 模型；BSB 模型；MLP 模型；信用分类

中图分类号：F224.0

文献标识码：A

1 引言

神经网络在最近 20 年中得到了迅速的发展，有关的论文及著作已有许多，而神经网络与数学中动力学系统理论的交叉结合（称之为神经动力学）虽也有所发展，但是在应用上却不是很广泛。

神经细胞或者叫做神经元是神经网络的结构单元，也是它的功能单元，神经网络的研究只把神经元作为构成神经网络的基本元件，而不把它本身也当作一个更下一层次的元件——细胞膜上的膜电容、膜电导和各种离子通道等所构成的系统。

在自然界中，有千变万化的现象，从这些现象出发，可以用各种数学模型去描述，但是总体上可以分为两大类，一类是确定性的数学模型，另一类是随机性的数学模型。而在确定性的数学模型中最普遍的是动力学模型，即系统的状态随时间演化的过程的模型。

事实上，神经动力学具有固定的权重、外部的输入、内部的状态，可以将它看成以权重、外部输入作为参数的关于内部状态的行为动力学，也可以看作权学习的动力系统。广泛一点说神经网络可以看作是权矩阵空间和输入输出状态空间的 **Dicard** 乘积下的一个动力学系统。

而在信用风险管理中，信用的评估是其中重要的组成部分。信用评估的目的是控制信用风险。对于信用的提供者来说，信用评估为是否授信提供了决策基础。持续的评估可以帮助信用管理者监测客户的账户。对于现金充足的大公司来说，对银行的评估有助于帮助他们决定分别应在各家银行存入多少钱。对于寻求贷款的企业，几个银行的评估有时可以指导她们选择合适的银行来借款。

许多大的公司、银行、政府以及政府机构现存的债务都有各自的信用评级。评级通常是由穆迪 (Moody's) 标准普尔 (Standard&Poor's) 和惠誉 (IBCA) 这样的专业机构完成的。根据企业评级结果，银行可以决定对该企业的贷款使用何种等级的贷款利率。例如，一个信用等级较低的企业贷款利率会比较高。企业可以利用银行评级来决定它们在银行的存款额度。

在信用评级中，最重要的一个环节就是对企业的信用等级进行分类。从一般意义上讲分类问题可以归结为映射：

$$F : A \rightarrow B (f(A) \rightarrow B)$$

其中 A 表示分类对象特征的数据集合，在风险分类中，即流动比率、速动比率、债务/权益比率、存货周转率、应收账款周转率、固定资产周转率、营运资本周转率、毛利率、总资产报酬率、和股东权益报酬率等关键指标值的集合； B 表示分类结果，如 AAA、A、BBB 等。

在目前的企业信用评级中，Z 值评分制是评估公司财务能力的一种统计方法。在 Z 值模型中，那些关键的财务比率被赋予不同的权重，利用这些比率可以计算出一个得分。如果一个公司的 Z 值低于一定水平，那么它将被认为有很高的潜在信用风险。Z 值评分在长期的信用决策中比较有用，特别是对银行的帮助很大。但是银行对 Z 值评分的可靠性常常有自己的看法。他们会或多或少使用 Z 值评分或类似的信用评分模型，但是这些可能只是它们对客户进行信用分析的一部分。然而，在我国，Z 值分析法模型主要基于多元统计分析方法（包括判别分析、聚类分析、因子分析）为基础的信用分析方法。然而，该分析方法对样本的分布、协方差等有着比较高的要求，对样本存在的噪音数据、偏差数据也很敏感。

本文着重说明神经动力学模型能够在信用风险管理中得到应用，试图做到举一反三，而不做实证分析，为推动神经动力学在信用分析中的应用提供一些参考意见。尤其是在信用等级分类中，神经动力学模型对数据的要求没有传统的评级方法的要求那么高，且应用较其它领域更直接一些。

现在我们就来介绍几个比较典型的神经动力学模型。

2 神经动力学模型

2.1 数学模型

一个神经网络包括 n 个处理单元，对于第 i 个单元，有三个相关的实数：网络的输入信号 s_i ，行为的状态 x_i 以及输出 y_i 。输出是行为状态变量的函数 $y_i = g_i(x_i)$ ，输入是所有状态和一个 $n \times n$ 实参数矩阵——权重矩阵 (ω_{ij}) 的函数。一般假定 $s_i = \sum_{j=1}^N \omega_{ij} y_j$ ，此处 ω_{ij} 看成是从第 j 个神经元到第 i 个神经元的传送线路的强度。

为了完成对神经网络的数学描述，我们通过指定表达状态随时间改变的方式的一种规则，即一种动力学使神经网络置于一个动力系统之中。按照动力系统类型的区分，神经网络可以分成决定性的或随机性的、自治的或非自治的、离散的或连续的、无延迟的或有延迟的。我们主要来介绍几类离散的神经动力学模型。

2.2 离散的单层反馈形神经网络的动力学模型

N 个神经元排列成一个单层，如果它构成全反馈的网络，这其中的每个神经元的输出都与其它神经元的输入相连，又整个网络的输入与输出的神经元数是相同的，都为 N 。记第 j 个神经元在 t 时刻的输出为 $x_j(t)$ ，则在时刻 t 的 N 个神经元的输出为向量 $x(t) = (x_1(t), x_2(t), \dots, x_N(t))^T \in R^N$ ，而第 i 个神经元在时刻 t 的内部状态为 $y_i(t)$ ，即 t 时刻 N 个神经元的内部状态为向量 $y(t) = (y_1(t), y_2(t), \dots, y_N(t))^T \in R^N$ ，如果

$$x_i(t+1) = f(y(t)), \quad (1)$$

其中 f 可以是最简单的二值函数 H ，也可以是 S 形单调连续函数，那么得到离散的单层反馈神经网络。下面介绍离散的 Hopfield 神经网络。

假定在 (1) 中的 f 取二值符号函数, sgn 形式, 又第 i 个神经元在时刻 t 的内部状态

$$y_i(t) = \sum_{j=1}^N \omega_{ij} x_j(t) + I_i \quad (2)$$

也就是 $x_i(t+1)$ 有如下两种形式: 若 $y_i(t) \geq 0$, 则 $x_i(t+1) = 1$, 即第 i 个神经元在 $t+1$ 时刻兴奋; 若 $y_i(t) < 0$, 则 $x_i(t+1) = 0$, 即第 i 个神经元在 $t+1$ 时刻抑制。写成统一形式, 网络的数学形式按照网络的工作方式可以写成如下异步和同步两步方式:

(1) 异步方式: 如果在某一时刻 $t+1$, N 个神经元中按照随机方式也可按照预先指定的顺序来选择某一个神经元 (例如 j 个神经元), 它的输出为

$$x_j(t+1) = \text{sgn}(y_j(t)) \quad (3)$$

但是其它 $N-1$ 个神经元的输出保持不变

$$x_i(t+1) = x_i(t), \quad i \neq j \quad (4)$$

(2) 同步方式: 在任何时刻 $t+1$, N 个神经元中的每一个神经元的输出均按同一方式生成

$$x_i(t+1) = \text{sgn}(y_i(t)), \quad i = 1, 2, \dots, N \quad (5)$$

这两种方式中的第 i 个神经元的内部状态 $y_i(t)$ 为

$$y_i(t) = \sum_{j=1}^N \omega_{ij} x_j(t) + I_i, \quad i = 1, 2, \dots, N \quad (6)$$

当输入向量 $I = (I_1, I_2, \dots, I_N)^T$ 作为一个初值时, 网络反馈演化, 从网络的输出端得到一个向量 $x(t) = (x_1(t), x_2(t), \dots, x_N(t))^T$, 如果它是收敛的, 即指存在某时刻 t , 使得

$$x(t+1) = x(t),$$

数学上称它为稳定的平衡点。如果它是振荡的, 即从某时刻 t 开始, 输出 $x(t)$, $x(t+1)$ 周期性重复振荡,

$$x(t), x(t+1), x(t), x(t+1), \dots$$

我们的目的是求出权重 ω_{ij} , 以便求出 y_i , 根据 y_i 的大小和权重对输出进行分类。对于如何判别模型的稳定或振荡以及动力学行为的分析不是本文要说明的内容, 而是数学要解决的问题。首先不妨设满足 $\omega_{ij} = \omega_{ji}$, 即权矩阵是对称的, 相应的定义离散反馈的 Hopfield 神经网络的广义能量函数为如下形式:

$$E = -\frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \omega_{ij} x_i x_j - \sum_{i=1}^N I_i x_i \quad (7)$$

显然，由于 x_i, x_j 只能取+1 或-1 二值， $\omega_{ij}, I_i (i, j = 1, 2, \dots, N)$ 均为有界的，

$$|E| \leq \frac{1}{2} \sum_{i,j=1}^N |\omega_{ij}| + \sum_{i=1}^N |I_i|$$

从任意一个初始状态出发，如果每次迭代都能满足相邻两个时刻的能量函数的变化 $\Delta E \leq 0$ ，那么网络的能量随时间变化越来越小，最后趋向于极限集中的最大的不变集，可能是平衡点集，也可能是极限环周期解集，在这些集合上的点满足 $\Delta E = 0$ 。它的物理意义是，在那些渐进稳定的不动点集及周期点集的吸引域内，当状态离吸引子越远，则能量越大，当状态离吸引子越近，则能量越小。而能量 E 的单调下降，说明状态的运动从远离吸引子的地方跑到了吸引子上，最后网络达到稳定。

2.3 BSB 模型

2.3.1 BSB 模型

设 W 是对称矩阵，且其最大的特征值有正的实部。记 $x^{(0)}$ 是模型的初始状态向量，表示启动一个输入。假设模型由 N 个神经元构成，状态向量的维数也为 N ，矩阵 W 是 $N \times N$ 阵，于是 BSB 模型的算法可以由以下方程完全给出：

$$y(n) = x(n) + \beta W x(n) \quad (8)$$

$$x(n+1) = \phi(y(n)) \quad (9)$$

其中 β 是小正常数，称之为反馈因子， $x(n)$ 是离散时间 n 的状态向量， W 表示单层线性神经网络。函数 ϕ 是一个分段线性函数依赖于 $y_j(n)$ ，

$$x_j(n+1) = \phi(y_j(n)) = \begin{cases} +1, & y_j(n) > +1, \\ y_j(n), & -1 \leq y_j(n) \leq +1, \\ -1, & y_j(n) < -1, \end{cases} \quad (10)$$

其中 $y_j(n)$ 是 $y(n)$ 的第 j 个分量。

2.3.2 模型的应用——分类

BSB 模型的一项基本的应用就是分类，这是由于作为吸引子的超立方体的顶点和相应的定义完善的区域，于是 BSB 模型被用来作为一种无监护的分类算法，而每一个不动点代表一组相关的数据构成的分类，由正反馈产生的自我放大是分类方法的最重要的特征之一。

Anderson 于 1990 年描述了利用 BSB 模型进行分类的方法，它可以从不同的放射射线中区分出辐射的信号。在这一应用中，权矩阵是通过误差纠正的线性相关的学习过程得到的。为了详细说明，假设有 K 个训练的向量

$$x_k \rightarrow x_k \quad (k = 1, 2, \dots, K) \quad (11)$$

随机选择向量 x_k ，于是权矩阵可以根据偏差纠正算法得到

$$\Delta W = \eta(x_k - Wx_k)x_k, \quad (12)$$

其中 η 是学习率参数。根据计算，输入向量 x_k 像其“老师”一样表现，因为线性结合会重新构造输入向量，而学习的目标是使得

$$Wx_k = x_k \quad k = 1, 2, \dots, K. \quad (13)$$

由式 (11) 给出的纠偏算法在最小均方意义下接近于理想的条件 (12)。学习的过程是为了促使线性结合器给出一组特征向量，相应的特征值等于 1。

为了模拟雷达分类，BSB 模型应用上述方法给出了权矩阵。具体的计算方式如下：

$$x(n+1) = \phi(\gamma x(n) + \beta Wx(n) + \delta x(0)) \quad (14)$$

(I) 衰变项 γ 使得当前的状态发生衰变，如果假设 γ 是一个小于 1 的正常数，那么误差最终将趋向于 0；

(II) 第三项 $\delta x(0)$ 是为了使初始状态 $x(0)$ 始终存在，它具有对 BSB 模型的状态影响。

不断的迭代使得具有大的特征值的权矩阵 W 的特征向量占优，于是向量 x_1, x_2, \dots, x_K 被线性结合器学习。BSB 模型分类能力通过模型中的正反馈加强了，所以经过若干次迭代后，其控制了系统的状态。另一方面，与噪声相关的特征向量总与小特征值联系在一起，所以为了减少对 BSB 模型状态的影响，可以假设收到的信号相应于噪声而言是非常强的。

2.4 感知器模型

如图 1 所示，在二维平面中有一个由两类样本构成的样本集。一类为 A 类样本，集中在平面的左上角，用“o”表示，另一类为 B 类样本，集中在平面的右下角，用“x”表示。我们希望找到一根直线

$$\omega_1 x_1 + \omega_2 x_2 - \theta = 0 \quad (15)$$

把 A, B 两类样本分隔开来。

如果 A, B 两类样本是线性可分的，即可用一根直线将两类样本分隔开来，而且有一段距离（参加图 1），那么形如 (15) 式的解有无数个。我们采用单层感知器来求解这个问题。

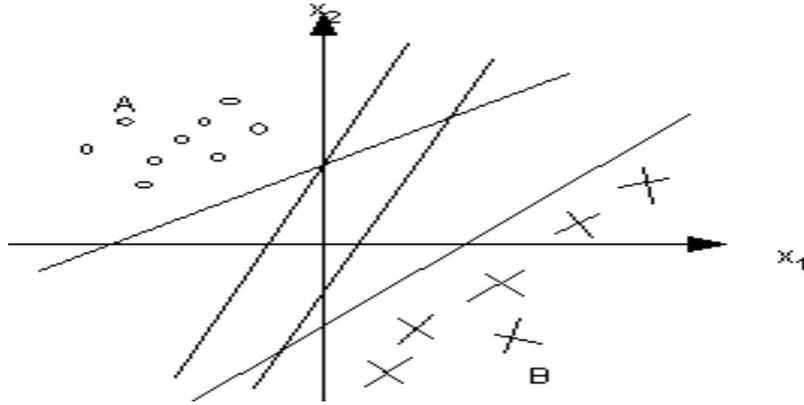


图1 样本集的线性划分

感知器是由 F.Rosenblatt 于 1957 年提出的。设 $x = (x_1, x_2, \dots, x_n)^T$ 为输入量， y 为输出量，输入与输出之间满足：

$$y = f\left(\sum_{i=1}^n \omega_i x_i - \theta\right), \quad (16)$$

其中 $\omega_i (1 \leq i \leq n)$ 为权系数， θ 为阈值，函数 $f(u)$ 为分段常数函数，

$$f(u) = \begin{cases} 1 & u \geq 0 \\ -1 & u < 0 \end{cases} \quad (17)$$

令 $\omega_0 = \theta, x_0 = -1$, 那么

$$y = f\left(\sum_{i=0}^n \omega_i x_i\right) \quad (18)$$

于是问题化为已知两个样本集分别为 $\{x^A\}$, $\{x^B\}$, 要求权系数和阈值 $\omega_i (0 \leq i \leq n)$, 使得

$$y = f\left(\sum_{i=0}^n \omega_i x_i^A\right) = 1 \quad (19)$$

$$y = f\left(\sum_{i=0}^n \omega_i x_i^B\right) = -1 \quad (20)$$

单层感知器的学习过程是一种有教师的学习过程，设教师 t 满足

$$t = \begin{cases} 1 & \text{当输入 } x^A \text{ 时} \\ -1 & \text{当输入 } x^B \text{ 时} \end{cases} \quad (21)$$

那么整个学习过程为

- (1) 随机给出权和阈值的初值 $\omega_i^0 (0 \leq i \leq n)$, 初值为非零的小数, 即 $0 < |\omega_i^0| \ll 1$;
- (2) 任选样本集中的一个样本 x 作为输入向量, 计算实际输出

$$y = f\left(\sum_{i=0}^n \omega_i x_i\right); \quad (22)$$

- (3) 若 $x \in x^A$, 令 $t = 1$; 若 $x \in x^B$, 令 $t = -1$;
 (4) 按下式调节权和阈值

$$\omega_i(k+1) = \omega_i(k) + \eta(t - y(k))x_i(k) \quad (23)$$

其中 k 为迭代次数, $0 < \eta \leq 1$, 用于调节速度。通常 η 不能取得太小, 否则会使 ω_i 的收敛速度太慢; 但 η 也不能取得太大, 否则会影响 ω_i 的稳定;

- (5) 在 x^A 或 x^B 集中选取另一个样本进行学习, 即重复 (2) ~ (4), 直到权系数 ω 对一切样本均稳定不变为止, 即 $\omega_i(k+1) = \omega_i(k) (i = 0, 1, 2, \dots, n)$

为了防止权调整的不均匀性, 学习时样本的选取最好在 x^A 和 x^B 两个样本集中轮流进行。例如, 设输入样本 $x = (x_1, x_2)^T$ 与教师 t 由表 1 给出

表 1

输入样本 x		教师 t
x_1	x_2	
0	0	0
0	1	0
1	0	0
1	1	1

由单层感知器计算可得 $\omega_0 = 1.5, \omega_1 = 1, \omega_2 = 1$, 于是分隔直线为

$$x_1 + x_2 - 1.5 = 0 \quad (24)$$

而输出函数为

$$y = f(x_1 + x_2 - 1.5) \quad (25)$$

其中

$$f(u) = \begin{cases} 1, & u \geq 0, \\ 0, & u < 0, \end{cases} \quad (26)$$

这个例子说明了“逻辑与”运算可以用单层感知器来实现。若将“逻辑与”的输入样本看成是直角坐标系下单位正方形的 4 个顶点 (参见图 2), 那么直线 (24) 将这 4 个点分成两类, 右上方为 A 类, 输出为 1, 左下方为 B 类, 输出为 0。

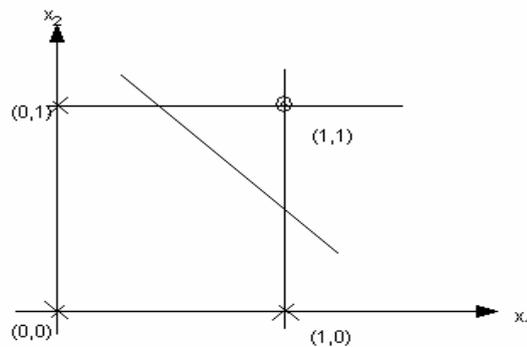


图 2 用单层感知器实现“逻辑与”运算

同样地, “逻辑或”运算也可以用单层感知器来实现, 设输入样本 $x = (x_1, x_2)^T$ 与教师 t 由表 2

给出。

表 2

输入样本 x		教师 t
x_1	x_2	
0	0	0
0	1	1
1	0	1
1	1	1

由单层感知器计算可得 $\omega_0 = 0.5, \omega_1 = 1, \omega_2 = 1$ ，于是分隔直线为

$$x_1 + x_2 - 0.5 = 0 \quad (27)$$

而输出函数为

$$y = f(x_1 + x_2 - 0.5) \quad (28)$$

其中 $f(u)$ 由 (26) 给出。“逻辑或”运算的几何图示见图 3。

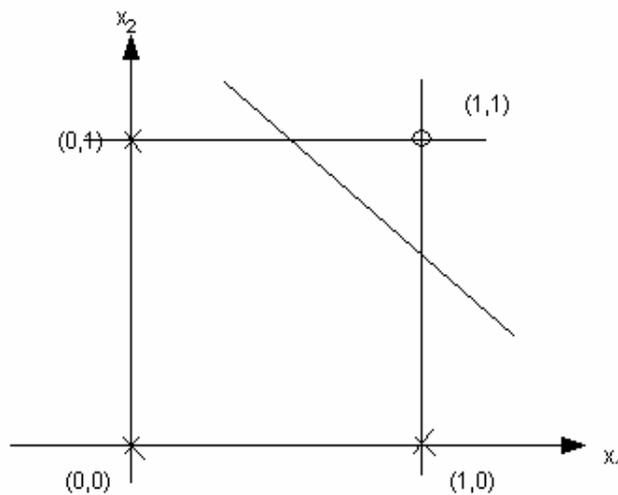


图 3 用单层感知器实现“逻辑或”运算

但是单层感知器只能满足线性分类，如果两类样本不能用一个超平面分开，那么单层感知器就无能为力了。

例如“逻辑异或”运算就无法用单层感知器实现。事实上，设输入样本 $x = (x_1, x_2)^T$ 与教师 t 由表 3 给出。

表 3

输入样本 x		教师 t
x_1	x_2	
0	0	0
0	1	1
1	0	1
1	1	0

由单层感知器应成立

$$0 \cdot \omega_1 + 0 \cdot \omega_2 - \theta < 0$$

$$0 \cdot \omega_1 + 1 \cdot \omega_2 - \theta \geq 0$$

$$1 \cdot \omega_1 + 0 \cdot \omega_2 - \theta \geq 0$$

$$1 \cdot \omega_1 + 1 \cdot \omega_2 - \theta < 0$$

显然上述不等式方程组无解，即单层感知器无法解决“逻辑异或”问题。从几何图形来看，A类顶点(0, 1), (1, 0)与B类顶点(0, 0), (1, 1)分别在单位正方形的对角顶点上，无法用一根直线将他们分开(参见图4)。

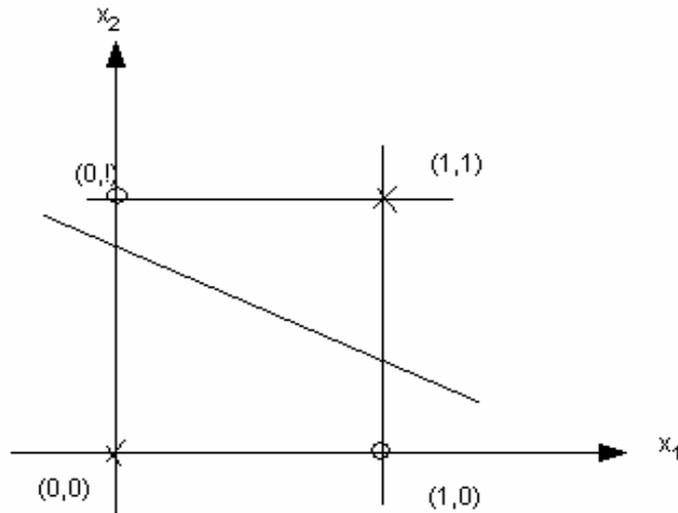


图4 “逻辑异或”运算

又如图5所示的二维平面中，A类样本分布在原点的附近，B类样本分布在A类样本的外部区域中，两类样本不能用直线分隔开来。

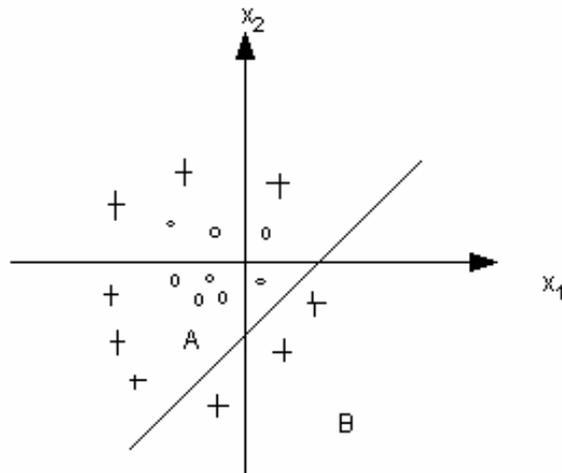


图5 不能线性划分的样本集

对于图5的问题，就是寻找一个区域，使其内部为A类样本，其外部为B类样本。可以在二维输入空间中划出三根直线，因为他们的权系数 ω_i 和阈值各不相同，因此3根直线的斜率与截距也不相同(如图6所示)。将这三个单元所得到的直线作相应的逻辑运算。

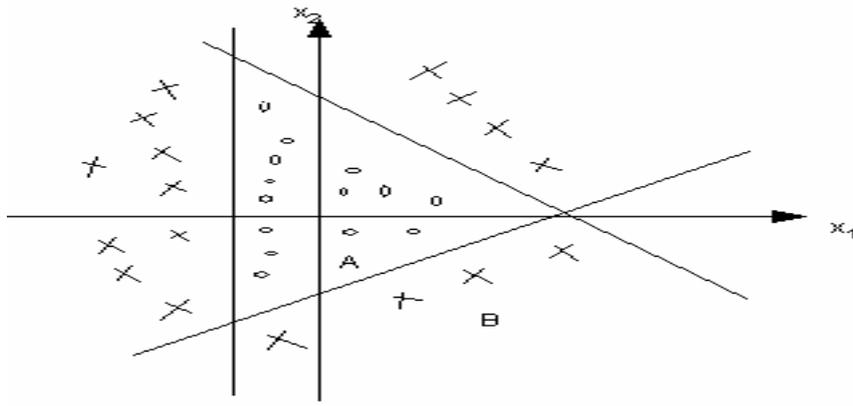


图6 多层感知器网络对样本集的划分

$$z = \left\{ (x_1, x_2) \mid \begin{aligned} &(\omega_{11}x_1 + \omega_{21}x_2 - \theta_1 > 0) \\ &\cap (\omega_{12}x_1 + \omega_{22}x_2 - \theta_2 > 0) \\ &\cap (\omega_{13}x_1 + \omega_{23}x_2 - \theta_3 > 0) \end{aligned} \right\} \quad (29)$$

其中 z 为输出单元，这样得到一个封闭区域即可正确划分两类样本。

显然，隐单元到输出单元之间为“逻辑与”的关系，它可以用感知器实现，于是图 5 的问题可以用三层感知器来实现。

对于“逻辑异或”运算可以抽象为图 7 的问题。

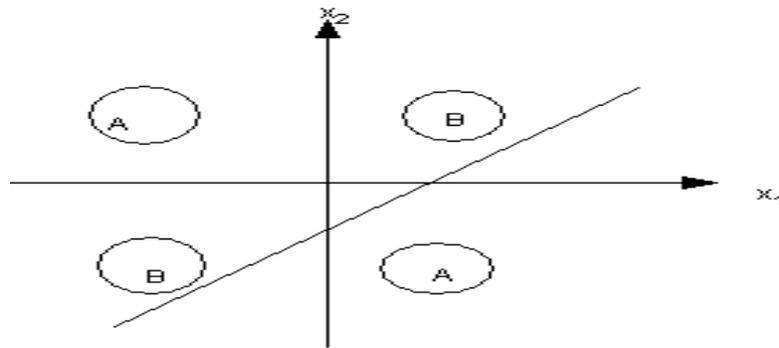


图7 另一类不能线性划分的样本集

若用 4 层感知器网络来实现，第一层为输入层，第二层起线性划分作用，第三层为“逻辑与”运算，第四层“逻辑或”运算。划分的区域为

$$z = \left\{ (x_1, x_2) \mid \left(\bigcap_{j=1}^3 (\omega_{1j}x_1 + \omega_{2j}x_2 - \theta_j > 0) \right) \cup \left(\bigcap_{j=4}^6 (\omega_{1j}x_1 + \omega_{2j}x_2 - \theta_j > 0) \right) \right\} \quad (30)$$

这里有 6 根直线,各用 3 根直线组成了两个三角形的区域,这是用“逻辑与”来完成的。两个区域内部属于 A 类，这又是“逻辑或”的关系，其它区域为 B 类（见图 8）。

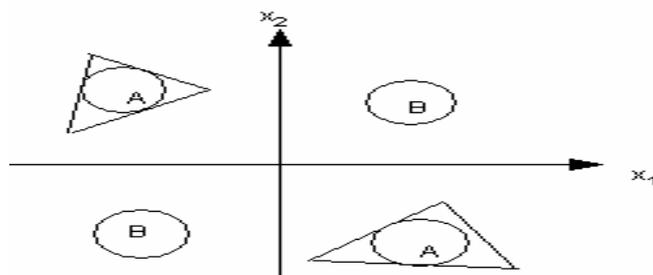


图 8 用 4 层感知器网络对样本集进行划分

若用 3 层感知器网络来完成，第一层为输入层，第二层起线性划分作用，第三层为“逻辑与”运算。划分区域为

$$z = \{(x_1, x_2) | (\omega_{11}x_1 + \omega_{21}x_2 - \theta_1 > 0) \cap (\omega_{12}x_1 + \omega_{22}x_2 - \theta_2 > 0)\} \quad (31)$$

这里用两根直线的“逻辑与”运算完成了样本的划分（见图 9）。

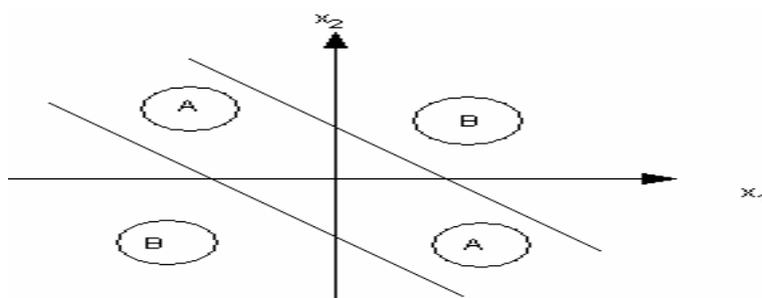


图 9 用 3 层感知器对网络样本集的划分

可以看出，多层感知器可通过单层感知器进行适当的组合达到任何形状的划分。

2.4.2 模型在信用评级上的应用

从理论上讲，以上三类模型都能解决分类问题，前两类神经动力学模型是有导师学习的神经动力学，是一种具有联想记忆功能的反馈动力学系统，能较好地逼近 f ，而多层感知器最适合解决分类问题，因为分类问题可视为求解静态的映射 f ，前向网络通过简单处理单元的复合可获得较强的处理输入输出关系的能力，能更好地逼近 f 。用多层感知器解决分类问题是一个“黑盒子”，即不能像判别分析那样可以明确地给出判别函数，多层感知器不能给出明确的表达式，而是通过 BP 有导师学习算法不断地调整权重 ω_i ，最终可以获得一个稳定的权重矩阵。多层感知器神经动力学模型就是把有关非线性映射 f 的知识储存在这些权重之中。这些权重虽然是可以打开的，但不能解释它们的含义，这是神经动力学解释功能差的一个原因。

神经动力学用于解决信用分类问题的思路是这样的：

(1) 首先确定分类结果的关键指标（如流动比率、速动比率、债务/权益比率、存货周转率、应收账款周转率、固定资产周转率、营运资本周转率、毛利率、总资产报酬率、和股东权益报酬率等）及分成几类（如四类，六类等）。

(2) 给出训练样本和测试样本，比如将信用分成六类，就得给出对应于这六类结果的关键指标的样本值。

- (3) 确定神经动力学的拓扑结构，学习参数的初始化，确定学习算法。
- (4) 输入训练样本，通过学习算法不断地调节权重，直至输出的总误差不超过某个值。
- (5) 利用测试样本评判网络的精度。并对之进行优化。
- (6) 系统权重稳定之后，输入待分类数据，输出分类结果。

对神经动力学模型在信用评级应用的评论

(1) 准确性比较高。特别是在测试数据为非线性关系的情况下，尤其是如此。比如，在信用分类中加入了行业分析、发展潜力等因素的情况下，多层感知器分类的准确性明显地高于多元统计中的判别分析法。而在测试数据线性可分时，则线性判别分析方法的准确性和多层感知器相当。这主要是由于多层感知器通过学习样本获取了映射关系 f 这一客观知识，而较少地掺入人为主观因素。

(2) 适应性强。多层感知器有较强的适应训练样本变化的能力，当训练样本增加新的数据时，多层感知器能记忆原有的知识，根据新增的数据作适当的调整，使之表示的映射关系能更好地刻画新样本所含的信息。这一点不仅使多层感知器具有较强的适应样本变化的能力，还使它具有动态刻画映射关系的能力，也克服了线性判别分析方法的静态特点。

(3) 健壮性。多层感知器对样本的分布、协方差等没有要求，对样本中存在的噪音数据、偏差数据不敏感。线性判别分析方法虽然对噪音数据不很敏感，但它对样本分布和协方差均有很高的要求。

(4) 神经动力学的主要缺点是对样本的依赖性过强，这就要求在选择样本时既要全面又要典型。因为它很少有人主观判断的介入，所以它对样本的选择提出了很高的要求。

(5) 神经动力学方法的第二个缺点是解释功能差。它仅能给出一个判断结果，而不能告诉你为什么。为了解决这个缺点，就应该将多层感知器和其它解释功能较好的方法结合起来，形成杂和系统，这样既可以保持神经网络的准确性高、适应性强、健壮性的特点，同时也增加了它的解释功能。

(6) 在神经动力学方法中还有一个比较重要的问题，既输入特征变量的确定。首先，要从所有的可能的指标中确定出关键指标，这同时也需要依赖于其他的统计方法。第二个问题是样本分成多少个种类，即分成哪几种信用等级比较合适。这些问题都是神经动力学方法无法独自解决的，要依赖于其他方法。

参考文献

- [1] 阮炯, 顾凡及, 蔡志杰 [著] 神经动力学模型方法和应用 [M]. 科学出版社, 2002, 4.
- [2] 英国皇家银行学会, 布莱恩.科伊尔 [著] 周道许, 关伟 [译] 信用风险管理[M]. 中信出版社 2003, 3.
- [3] 石晓军, 陈殿左 [著] 信用治理: 文化、流程与工具[M]. 机械工业出版社. 2004, 1.
- [4] 约翰.B. 考埃特, 爱德华.I. 爱特曼, 保罗. 纳拉亚南 [著] 石晓军, 张振霞 [译] 演进着的信用风险管理: 金融领域面临的巨大挑战[M]. 机械工业出版社. 2001, 4.

The application of Nerve dynamics model to credit rating

MENG Qing-fu, DENG Hong-yu

(Business School of Jilin University , Chang chun Jilin 130012)

Abstract: This article mainly introduces the application of Nerve dynamics model to credit rating. First we briefly explain what is nerve dynamics, Then introduce Hopfield model, BSB model and multilayered sensation (MLP) model in nerve dynamics model and explain how to apply the nerve dynamics to the credit classification, Finally make the appraisal to this kind of application.

Keywords: Nerve dynamics; Nerve network; Hopfield model; BSB model; MLP model; Credit classification

收稿日期 : 2005-5-12

作者简介 : 孟庆福 , 吉林大学商学院教授 , 硕士生导师。