

文章编号: 1000-8152(2007)06-1015-06

基于CBP的卷烟销售二重趋势时间序列预测模型研究与应用

谢星峰¹, 谢东风², 邹平³

(1. 昆明理工大学 管理经济学院, 云南 昆明 650093; 2. 云南烟草公司, 云南 昆明 650011;
3. 云南师范大学, 云南 昆明 650092)

摘要: 二重趋势时间序列的预测结果与其整体趋势变动性和季节波动性的特征有较大的关系, 在采用神经网络并针对其特征的基础上还没有较好的预测方法。本文以圆形反向传播网络(CBP)为基础, 提出二重趋势时间序列预测组合模型(CCBP), 即根据二重趋势时间序列特征对其趋势分量与周期分量采用圆形反向传播网络分开进行预测, 再对二者积乘。以云南省某片区若干卷烟销售网点的采样数据为研究实例, 证实了CCBP模型在二重趋势时间序列预测方面性能有所提高。

关键词: 圆形反向传播网络; 二重趋势时间序列; 预测

中图分类号: TP273 文献标识码: A

Study and application of double trend time series prediction models of cigarette sell based on CBP

XIE Xing-feng¹, XIE Dong-feng², ZOU Ping³

(1. School of Management and Economy, Kunming University of Science and Technology,
Kunming Yunnan 650093, China;
2. Yunnan Province Tobacco Corporation, Kunming Yunnan 650011, China;
3. Yunnan Normal University, Kunming Yunnan 650092, China)

Abstract: The prediction performance of double trend time series has dependence relation to its character: the trend change nature and season fluctuation characteristic. However, there is no effective way to construct the forecast method with the Neural Network and this double trend character. Based on circular back propagation network(CBP), a combined forecast model-CCBP is proposed which separates the weight of trend and the weight of fluctuation from predicted series data, respectively predicts the two weights, then multiplies two weight. After comparatively studying the data cases of some Yunnan tobacco company, it is proved that the CCBP model in the double trend time series has effectively enhanced the prediction performance.

Key words: circular back propagation(CBP); double trend; time series; forecast

1 问题提出及解决方案(Issue and solution)

影响卷烟销售的因素是多方面的, 如市场、经济水平、人口及季节等, 同时卷烟销售具有时间序列二重趋势变化的特点, 即整体趋势变动性和季节波动性, 其数据特征如图1(*样本集是指以若干具有相对稳定市场的固定网点为数据采样的集合)。二重趋势预测的特点是观察值排列顺序的重要性和前后观察值及其同期比之间的相关性, 即预测点与其相距较近的观察点的相关性较强, 而与其相距较远的观察点相关性较弱。二重趋势预测通常的方法有: 线性回归法、时间序列分析法、神经网络等。然而这些

预测方法只是从数据本身的角度进行数据分析预测, 未考虑到环境因素对卷烟销售量的影响; 而神经网络在此类预测应用中, 却并未考虑时间序列本身的结构性, 忽略了预测点与其他时刻数据的时间相关性。

本文以人工神经网络中圆形反向传播网络模型为基础考虑环境因子建立二重趋势中趋势变动分量(long CBP)LCBP模型, 再结合数据时间相关性建立二重趋势中波动分量(period CBP)PBCP模型, 最终组合两分量CBP模型建立整体的趋势预测模型(combined CBP)CCBP模型。

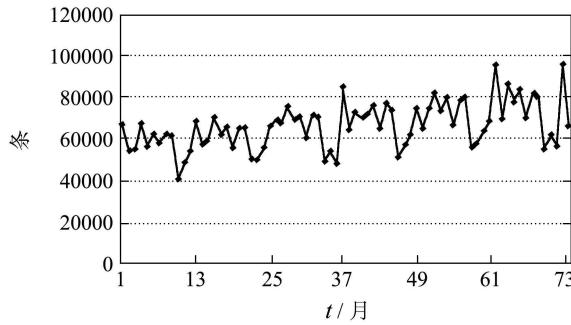


图1 样本集*历年卷烟销售量曲线图

Fig. 1 Cigarette saleroom graph of specific sample set

2 圆形反向传播网络(Circular back propagation network)

在人工神经网络(artificial neural network, ANN)研究中误差反向传播(error back propagation, BP)学习算法(BP神经网络)是应用最多的一种算法。Sandro Ridella等在BP神经网络的基础上提出了圆形反向传播网络(circular back propagation, CBP)模型^[1], 即在BP神经网络的输入层添加输入为各分量平方和(输入向量的模平方的各向同性)的一个额外节点。

2.1 CBP网络结构及其算法(Hierarchy and arithmetic of CBP)

CBP的3层网络结构如图2所示, 有 N_0 个输出节点, N_h 个隐含节点, 输入模式维数为 d 维。扩充输入节点输入为: x_0, x_{d+1} ($x_0 = -1, x_{d+1} = \sum_{k=1}^d x_k^2$)。此处 x_{d+1} 节点与隐含节点间的连接权重也不同。具体给出如下: 网络输入为 x_0, x_1, \dots, x_{d+1} , 输入层与隐含层间的权值矩阵为 V , 隐含层输出层间的权值矩阵为 W ; 网络输出层第 i 个节点输出值为 $y_i = \sum_{j=0}^{N_h} w_{ij} h_j$, $i = 1, \dots, N_0$; 隐含层节点的激活函数为 S 型转移函数, 即第 j 个隐含层节点的激活输出为

$$h_j = \sigma(r_j) = \frac{1}{1 + e^{-r_j}}, \quad j = 1, \dots, N_h.$$

其中: r_j 表示该隐含节点的输入加权和

$$\begin{aligned} r_j(\vec{x}, \vec{v}) &= \sum_{k=0}^d v_{jk} x_k + v_{j(d+1)} \cdot x_{d+1} = \\ &= -v_{j0} + \sum_{k=1}^d (v_{jk} \cdot x_k + v_{j(d+1)} \cdot x_k^2). \end{aligned}$$

CBP网络的学习算法: 设网络期望输出 o_i ($i = 1, \dots, N_0$), 其与实际输出间的误差为 $E = \frac{1}{2} \sum_{i=1}^{N_0} (o_i - y_i)^2$ 。CBP网络采用误差反向传播学习法, 以 t 表示为其在时间序列预测中某段时间窗口, 从而输出层与隐含层间连接权调整量为

$$\Delta w_{ij}(t) = -\eta \frac{\partial E(t)}{\partial w_{ij}} = \eta [o_i(t) - y_i(t)] \cdot h_j(t).$$

其中: $i = 1, \dots, N_0, j = 0, \dots, N_h$, 隐含层与输入层间连接权调整量为

$$\Delta v_{jk}(t) = \eta \left[\sum_{i=1}^{N_0} ((o_i(t) - y_i(t)) y_i(t) (1 - y_i(t)) w_{ij}) \cdot h_j(t) \right] \cdot (1 - h_j(t)) x_k(t).$$

其中: $j = 1 \dots N_h, k = 0 \dots d^2$ 。

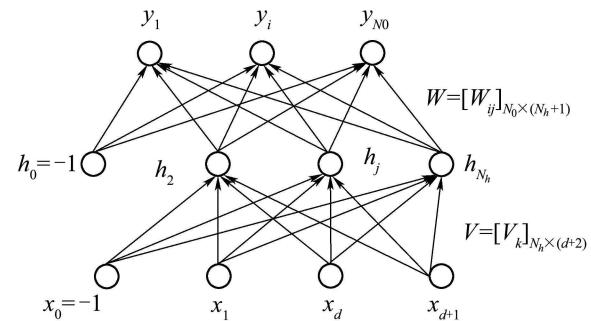


图2 CBP 3层网络结构图

Fig. 2 CBP 3 layer structures

2.2 CBP网络优点(Advantage of CBP)

CBP网络是在BP神经网络的输入层添加输入为各分量平方和的一个额外节点, 其几何解释为: 把上节中 $r_j(\vec{x}, \vec{v})$ 转换成如下形式:

$$r_j(\vec{x}, \vec{v}) = v_{j(d+1)}[(\vec{x} - \vec{c}_j)I(\vec{x} - \vec{c}_j)^T - \theta_j].$$

其中 I 为 d 维矩阵,

$$\begin{aligned} \vec{c}_j &= -\frac{1}{2v_{j(d+1)}}(v_{j1}, v_{j2}, \dots, v_{jd}), \\ \theta_j &= (\vec{c}_j I \vec{c}_j^T + \frac{v_{j0}}{v_{j(d+1)}}). \end{aligned}$$

由于 I 是一个单位矩阵, 对于每一个隐含节点, 样本 \vec{x} 与 \vec{c}_j 的超球距离与 θ_j 比较后再乘以系数 $v_{j(d+1)}$, 经激活函数 σ 作用后输出, \vec{c}_j 为一超球体的中心, 从而从结构上保证了输入向量的模平方的各向同性, 使得CBP网络在波动性较强的特征数据预测中, 与BP比较提高了网络结构的学习效率和预测的准确度, 这点将在下文实验中得以证明。

3 时间序列时间相关性(Time relativity of time series)

误差反向传播学习算法是一个使用梯度下降法最小化平方差的过程。一般的误差函数对训练集中的所有样本赋与相等的权重, 而实际上时间序列的值间常有如下相关性: 预测点与其相距较近的观察样本相关性较强, 而与其相距较远的训练样本相关性较弱。因此训练时时间窗内的样本对网络权值的影响是不等的, 与预测对象时间上较近的样本对

网络权值的影响应较大, 相应的与预测对象时间上较远的样本对网络权值的影响应较小, 由此定义打折最小平方的误差函数为

$$E_p = \frac{1}{2N_0} \sum_{p=1}^{N_0} \omega(p) (\vec{o}_p - \vec{y}_p)^2.$$

其中: $\omega(p)$ 是第个 p 个样本对整体误差的贡献量的一个量度, 从而使误差函数偏向于最近的观察; $\omega(p)$ 可以有多种形式, 如线性型、指指数型等^[3]. 本文的 $\omega(p)$ 为

$$\omega(p) = \frac{1}{1 + e^{a-bp}}, b = \frac{2a}{N}.$$

因为上式中的 b 是由 a 和 N 导出, 所以 $\omega(p)$ 的唯一控制参数是打折率 a .

最后可推导出误差打折的神经网络的输出层与隐含层间连接权调整量为

$$\Delta w_{ij}(t) = -\eta \frac{\partial E(t)}{\partial w_{ij}} = \frac{\eta}{1 + e^{a-bp}} [o_i(t) - y_i(t)] \cdot h_j(t).$$

其中: $i = 1, \dots, N_0$, $j = 0, \dots, N_h$ ^[3]. 隐含层与输入层间连接权调整量为

$$\Delta v_{jk}(t) = \frac{\eta}{1 + e^{a-bp}} \left[\sum_{i=1}^{N_0} ((o_i(t) - y_i(t)) y_i(t) (1 - y_i(t)) w_{ij}) \cdot h_j(t) \cdot (1 - h_j(t)) x_k(t) \right].$$

其中: $j = 1, \dots, N_h$, $k = 0, \dots, d$ ^[3].

4 二重趋势时间序列分解(Disassemble double trend time series)

二重趋势特性的时间序列数据, 具有整体趋势变动性和季节波动性的二重变化的特点. 在时间序列分析应用中通常将其分解为: 趋势分量和周期分量, 在其两分量分解的方法中比较典型的模型是乘积模型^[4]:

$$B_t = C_t * Z_t * E_t.$$

其中: B_t 为月观测值, C_t 为月观测值的趋势分量, Z_t 为月观测值的周期分量, E_t 为均值为零的随机噪声. t 与年份 i ($i = 1, 2, \dots, N$; N 为观测数据年份个数), 月份 j 满足关系式:

$$t = (i - 1) \times 12 + j.$$

设序列为 B_1, B_2, \dots, B_H , 其中 H 为序列长度, 它与观测数据序列年份个数 N 及月周期数12的关系为 $H = 12N$.

用中位移动平均法, 可提取不含周期波动的趋势分量:

$$\hat{C}_t = \frac{1}{12} \left[\sum_{i=-5}^5 Y_{t+i} + \frac{1}{2} (B_{t+6} + B_{t-6}) \right],$$

$$t = 7, 8, \dots, H - 6.$$

式中: 以12为周期, 以 t 为中心, 2阶对称滑动平均数字滤波. \hat{C}_t 经数字滤波后, 不再含有周期分量. 然后可分离出带有噪声的周期分量:

$$Z_t \cdot E_t = B_t / \hat{C}_t (t = 1, 2, \dots, H).$$

5 卷烟销售预测CCBP网络模型(Combined CBP for cigarette sell prediction)

从卷烟市场销售情况的大量数据分析得出, 影响卷烟销售量的主要因素有经济收入水平、年龄结构层次及流动人口流量等, 且卷烟销售数据是具有二重趋势性质的时间序列数据, 从图1可以看出, 其时间相关性表现非常强. 基于卷烟销售的特点, 笔者根据二重趋势时间序列乘积模型中的中位移动平均法把所收集到的销售数据进行分解, 分解为: 趋势分量和周期分量. 以圆形反向传播网络模型(CBP)为基础考虑经济收入(国内生产总值水平)、国内人均生产总值、年末总人口、城镇可支配收入等环境因子建立二重趋势中趋势分量(long-term CBP)LCBP模型, 再结合数据时间相关性并利用打折最小平方思想建立二重趋势中周期分量(period CBP)PCBP模型, 分别对两个分量进行预测, 最后组合两分量CBP模型的预测值得到销售量的整体预测值. 称此趋势预测模型为(combined CBP)CCBP模型, 即

$$V_{CCBP} = V_{LCBP} \cdot V_{PCBP}.$$

本文以下将以CCBP模型中的LCBP模型对趋势分量进行预测, 再用PCBP模型对周期分量进行预测, 最后将此二分量预测值合成CCBP模型的预测值, 并将此CCBP预测值与其他同类模型预测值进行比较.

5.1 LCBP模型建立及趋势分量的预测(Build LCBP model and predict the trend weight)

LCBP模型就是对趋势量进行分析预测, 把从1999~2003年每年12个月卷烟销售量数据趋势分量、人口及经济水平等该片区的年鉴数据的换算作为输入, 以下一年(由于样本数据集空间大小的关系, 本文粗略的采用次年作为目标输入)12个月趋势分量作为目标输入来进行模型的训练. 如到2002年的时候, 把2002年的各月趋势分量12个及4个环境因子作为CBP网络的输入, 而2003年12个月趋势分量的数据作为目标输出. 最后把2004年作为模型预测值, 以和2004年实际数据相比较. 由于月趋势分量数据很大, 根据圆形反向传播网络模型的要求, 需要把上述数据映射到(0,1)区间, 本文采用如下公式进行映射:

$$in_i = \frac{IN_i - \min(IN)}{\max(IN) - \min(IN)} \times 0.8 + 0.1,$$

得到准备的数据. 隐含层节点数为30个, V, W 各权值为 $2.4/N^{[5]}$ (N 为输入层或隐含层节点数据)到 $-2.4/N$, 即 $(-1.333, 1.333)$ 和 $(-0.8, 0.8)$ 之间的随机数, 权值学习率为 $\eta = 0.05$, 经过18万次的样本训练网络学习, 最后得误差 E 为 8.21×10^{-6} .

网络训练好后把2003年12个月卷烟销售量数据趋势分量、人口及经济水平等16个数据作为输入, 预测2004年12个月每月的销售量.

5.2 PCBP模型建立及周期分量预测(Build PCBP model and predict the period weight)

PCBP模型是对周期分量进行分析预测, 其中根据周期分量二重趋势时间序列的波动性、及时间相关性, 在模型设计上如前所述采用了在误差反向传播时打折的思想, 对CBP网络权值进

行修正调整, 以用CBP网络实现PCBP网络模型. 把得到的1999~2003年卷烟销售数据周期分量按时间窗为4进行数据的划分, 把下一个月得周期分量作为预测检验值, 进行模型的训练. 如把199901, 199902, 199903和199904的周期分量作为输入, 199905的周期分量作为检验输出, 同理直到200312作为检验输出. 最后把2004年周期分量作为模型预测检验. 模型训练及其参数设置: 打折率 $a = 4.21$, 隐含层为30, 权值学习率为 $\eta = 0.5$. 经过24万次训练后得到误差 E 为 4.63×10^{-6} . PCBP网络训练好后, 对2004年12个月销售量的周期分量进行预测. 对趋势分量和周期分量分别进行了预测后, 再用积乘模型把二分量还原到销售量值, 便是CCBP模型的预测结果(见表2).

表1 样本集历年卷烟销售量(条)、经济水平及人口

Table 1 Primary data of sample set

	1999	2000	2001	2002	2003	2004
1月	66390.5	69143.2	66101.9	84556.3	74910.7	68430.9
2月	53801.5	56485.3	69526.1	63727.5	64710.5	95343.9
3月	54848.3	59098.4	67011.3	73178.0	74407.9	69096.6
4月	67335.3	70340.0	75341.4	69321.4	81856.0	85924.9
5月	56247.4	61108.6	68168.4	71626.0	72815.4	77313.5
6月	62216.2	65463.8	70659.6	75994.1	79637.3	83382.2
7月	57359.0	55633.0	60734.1	64649.0	65948.5	69558.7
8月	62338.3	65149.5	71076.8	77239.7	78283.3	82430.1
9月	61009.5	65164.2	69759.7	73432.6	79934.3	79166.9
10月	40555.4	50021.5	49274.0	51258.7	55653.3	54799.6
11月	48693.4	49758.7	54100.5	57034.5	57355.2	61613.9
12月	54034.3	55813.5	47789.2	61560.2	63713.1	56696.3
年末总人口/万人	206.26	210.81	215.20	220.04	224.20	—
国内生产总值/亿元	584.26	625.00	672.84	730.00	812.00	—
国内人均生产总值/元	12423	13000	13900	14800	16308	—
城镇可支配收入/元	6720	7563	7790	7795	7979	—

注: 其中历年环境因子数据来源于1999~2004年中国城市年鉴数据.

6 BP,CBP及CCBP预测模型比较(Model comparison among BP,CBP and CCBP)

为使在同等结构上与BP,CBP模型进行模型训练及预测性能等方面比较, 笔者分别建立与CCBP模型中LCBP模型相似的BP和CBP网络结构后(输入节点为各年每月实际销售量, 取12; 隐含层节点为30; 输出节点为下年每月预测值, 取12, 学习率为0.05), 以1999~2003年数据作为BP网络和CBP网络模型的训练集, 对BP,CBP二神经网络模型进行训练, 其数据汇总如表1, 部分学习过程图如图3~5. 最后以2003年12个月卷烟销售作

为输入预测2004年每月销售量, 将其预测值、2004年实际数据以及CCBP模型预测的结果汇总, 得表2、图6.

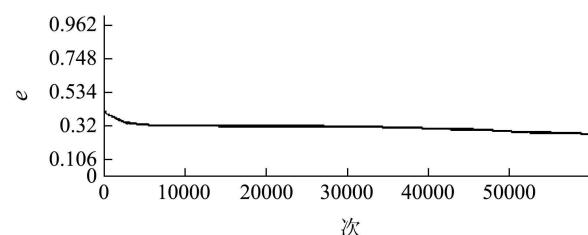


图3 BP模型部分学习过程

Fig. 3 Part learning process of BP

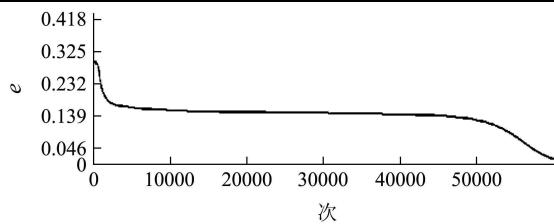


图4 CBP模型部分学习过程

Fig. 4 Part learning process of CBP

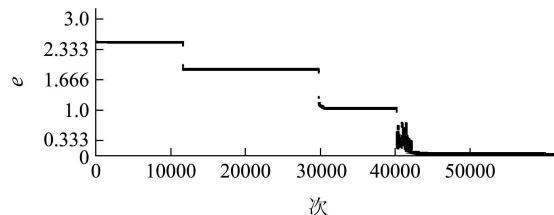


图5 LCBP模型部分学习过程

Fig. 5 Part learning process of LCBP

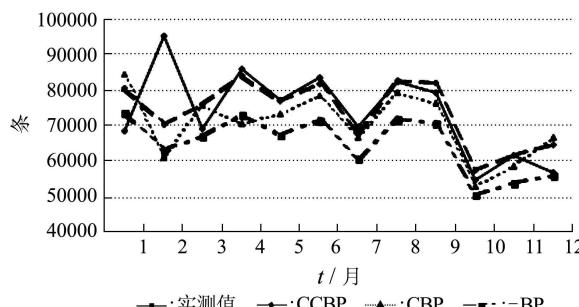


图6 预测年中个月实测值、CCBP,CBP及BP预测值曲线图对比

Fig. 6 BP,CBP and CCBP prediction graph

图形分析: 从学习过程误差变化曲线可看出由于LCBP模型在加入了环境因子, 对学习过程有个

较大的适应过程, 学习开始阶段处于一个不稳定时期, 4万次左右经过一次突变后呈现出比较稳定的下降趋势, 且其误差下降是最为快的一个. 从图6可看出, CCBP预测数据与实际销售数据吻合得很好, 但是在年初年末数据预测有差别, 主要是因为在这段时期与农历的春节假期在公历时间表有一定的分歧. 由于本文所采集的数据为网点销售数据, 而非零售商销售数据, 故从预测曲线来说, 在7月份为卷烟销售的低峰时期, 表现为夏季是卷烟生产的淡季; 在十一假期前期销售量数据处于一个高峰时期, 卷烟的销售在节前有一定的提前, 目的是为了储备库存以保证假期的卷烟销售, 同时也体现了网点销售的超前现象.

CCBP模型的预测偏差均很小, 与实际数据的接近很理想, 而相对来说, CBP模型的预测相比CCBP, CBP与实际数据也很接近, 但是从表2预测偏差来看其效果不如CCBP. 相对来说, BP网络模型预测值数据比实际数据要普遍的低, 预测偏差也大. BP网络模型在预测二重趋势时间序列非线性变化趋势时, 因为忽视了二重趋势的整体趋势增长性, 使得其预测结果普遍低于实际观测值. CBP模型因为在网络结构中添加了输入为各分量平方和的一个额外节点, 即输入向量的模平方的各向同性, 使其结构上具有同向性. 在二重趋势预测中比BP神经网络有了部分改进, 但忽视了二重趋势时间序列的周期波动性的特点, 其预测偏差值相对CCBP来说要差, 因此在波动性的变化预测能力上有待改进.

表2 实测值、CCBP,CBP及BP数据对比

Table 2 Prediction comparison among BP,CBP and CCBP

2004年实测值	CCBP模型		CBP模型		BP模型		条
	预测值	预测偏差*	预测值	预测偏差	预测值	预测偏差	
1月	68430.907	0.175473	84445.39	0.234024	73642.76	0.076162	
2月	95343.879	0.261986	61255.77	0.357534	63177.77	0.337942	
3月	69096.642	0.099544	75658.26	0.094963	67068.09	0.029817	
4月	85924.939	0.019840	70499.40	0.179522	72887.40	0.151172	
5月	77313.537	0.003485	73348.15	0.051293	67390.28	0.128077	
6月	83382.200	0.019977	78510.35	0.058436	71556.27	0.141794	
7月	69558.742	0.024558	66679.23	0.041407	60750.42	0.126632	
8月	82430.125	0.003250	79341.91	0.037465	71788.43	0.129063	
9月	79166.881	0.034404	76317.88	0.035992	70472.05	0.109812	
10月	54799.586	0.048724	53019.48	0.032481	50617.44	0.076317	
11月	61613.866	0.001173	58555.70	0.049634	53895.83	0.125262	
12月	56696.272	0.140693	66845.01	0.1790022	55870.59	0.014563	

*: 预测偏差 = |预测值 - 实测值| / 实测值

7 结论(Conclusion)

CCBP模型(LCBP和PCBP), 即结合了CBP在时间序列预测的优势特征, 把周期分量与趋势分量分离后, 结合影响卷烟销售量整体增加趋势的环境因子, 进行趋势分量的预测; 同时根据时间序列时间最近相关性的特点, 利用了打折的思想对周期分量进行预测, 使其预测效果在本文的设计中表现最佳. 该模型克服了单一的CBP模型对具有二重变化趋势预测的表达能力受限的缺点; 同时分开时间相关性和环境因子区别对待二重趋势的两个分量分别进行预测, 充分利用了CBP各向同性预测的优势.

参考文献(References):

- [1] RIDELLA S, ROVETTA S, ZUNINO R. Circular back-propagation networks for classification[J]. *IEEE Trans on Neural Networks*, 1997, 8(1): 84 – 97.
- [2] REFENES A P, BENTZ Y, BUNN D W. Financial time series modelling with discounted least squares backpropagation[J]. *Neurocomputing*, 1997, 14: 123 – 138.
- [3] 项静恬, 史久恩. 非线性系统中数据处理的统计方法[M]. 北京: 科学出版社, 1997.
(XIANG Jingtian, SHI Jiuen. *Data Processing Statistical Method in the Non-linear System*[M]. Beijing: Science Press, 1997.)
- [4] 高隽. 人工神经网络原理及仿真实例[M]. 北京: 机械工业出版社, 2003, 8(1): 51.
(GAO Juan. *The Principle of the Artificial Neural Network and Artificial Instance*[M]. Beijing: Mechanical Industry Press, 2003, 8(1): 51.)
- [5] 谢星峰. 基于神经网络的卷烟销售预测模型的研究及应用[D]. 昆明: 昆明理工大学, 2005
(XIE Xingfeng. *The study and application of cigarette saleroom forecast model based on artificial neural network*[D]. Kunming: Kunming University of Science and Technology, 2005.)

作者简介:

- 谢星峰** (1980—), 男, 研究生, 从事决策支持系统研究, E-mail: xiexiaodao@hotmail.com;
- 谢东风** (1970—), 男, 工程师, 从事决策支持系统研究, E-mail: xdf118@hotmail.com;
- 邹平** (1956—), 男, 教授, 博士生导师, 主要从事决策支持系统、智能工程、决策理论与方法学研究.