

商场客流量中改进 BP 神经网络的应用

俞克强, 宫宁生, 徐昊骞

(南京工业大学 电子与信息工程学院, 江苏 南京 210009)

摘 要: 通过对商场客流量中行人的相关特征进行提取以及对获得的相应数据样本进行处理, 利用改进的 BP 神经网络算法, 建立了相应的 BP 网络模型, 对客流量中行人出入商场的一些模式进行自动识别, 并分析了隐含层神经元个数、学习速率等因素对网络训练的影响. 实验表明该模型在实际项目中的应用是可行的.

关键词: 商场客流量; 改进的 BP 神经网络; 模式; 识别

中图分类号: TP29

文献标识码: A

文章编号: 1000-7180(2013)02-0065-04

Application of Modified BP Neural Network in Marketplace Passenger Volume

YU Ke-qiang, GONG Ning-sheng, XU Hao-qian

(College of Electronics and Information Engineering, Nanjing University of Technology, Nanjing 210009, China)

Abstract: Through the related features of extraction in marketplace passenger volume and the different sample data processing, constructing the BP neural network model for some pattern with automatic recognition aiming at the pedestrians in and out of the market by using the algorithm of modified BP neural network. Other than, a research has been made to show the effect of different hidden layer numbers and learning rate in neural network training. The experiment also shows the application of the model in actual project is feasible.

Key words: marketplace passenger volume; modified BP neural network; pattern; recognition

1 引言

客流量作为零售行业的一项基础指标, 因其与销售量直接的成正比关系, 许多经营管理者已经意识到了客流量数据对于决策分析的重要性. 一方面客流量的相关统计能有效解决人员密集场所安全问题, 比如火车站, 汽车站, 机场等; 另一方面它能提高商家的管理率和经营效益, 比如商场, 购物中心, 超市等.

客流量是一种重要的衡量工具, 通过这些准确量化的数据, 人们能够科学、有效地对客流量进行时间和空间上分析, 不仅可以获得商场、购物中心或者飞机场等完整的运行状况, 而且可以利用这些数据, 综合分析客流量、销售额、回头率、转化率等, 不断改

善通路设计, 快速及时地做出经营决策. 本文则根据传统人工计数方法的不足, 提出了一种改进的 BP 神经网络模型并应用于商场的客流量之中.

2 改进的 BP 神经网络

人工神经网络是由大量的处理单元即神经元互相连接而成的网络, 它具有很强的自学习、自适应、鲁棒性、容错性及存储记忆的能力, 其中 BP 神经网络^[1-4]是目前应用最为广泛的一种网络模式. 传统的 BP 算法存在收敛慢、振荡和陷入局部极小点等问题. 本文首先针对这些特点, 对传统的 BP 算法进行了改进.

BP 网络的权值修正从理论上讲, 其训练是沿着误差曲面切面向下逼近的, 其误差曲面是一个高维空间中的曲面, 分布着许多局部极小点, 在网络的训

收稿日期: 2012-05-06; 修回日期: 2012-06-12

基金项目: 国家“九七三”计划项目(2005CB321901); 软件开发环境国家重点实验室开放课题(BUAA-SKLSDE-09KF-03)

练中,很容易陷入这样的局部极小点,为了使学习速度足够快而不易产生振荡,往往在 δ 规则中再加上一个“势态项”,即:

$$\Delta w_{ji}(k+1) = \eta \delta_{kj} o_{ki} + \alpha \Delta w_{ji}(k) \quad (1)$$

式中, α 是一个常数(动量系数),它决定过去权值的变化对目前权值变化的影响程度, k 为网络学习训练次数。

学习速率表现为训练后对权值所作修改的剧烈程度. 为了提高性能,加速收敛过程,本文采用变学习速率的方法. 在开始训练时,使用大的学习速率以满足加快训练速度的要求,而在接近极值点时,使用小的学习速率有利于网络的收敛.

学习速率的调整公式为^[5-6]:

$$\eta(k+1) = \begin{cases} \mu_+ \cdot \eta(k) & E(k+1) < E(k) \\ \mu_- \cdot \eta(k) & E(k+1) > E(k) \\ \eta(k) & \text{其它} \end{cases} \quad (2)$$

式中, η 为初始学习速率; μ_+ 为学习速率递增系数; μ_- 为学习速率递减系数; $E(k+1)$ 为当前网络训练的均方误差; $E(k)$ 为上一次学习后的网络训练的均方误差. 本文选取 μ_+ 为 1.05, μ_- 为 0.5.

3 商场客流量中应用研究

3.1 网络结构设计

基于 Robert Hecht-Nielsen 的证明^[2], 一个 3 层的 BP 网络可以完成任意的 M 维到 N 维的映射, 因此本文采用具有一个隐层的 BP 网络模型. 本网络中, 输入层为 m 个单元, 经隐层传向输出层, 输出层为 n 个单元.

隐层单元数的选取与问题要求的输入和输出单元的多少有直接的关系. 网络隐层单元数太少, 不能训练好网络, 容错性比较差; 隐层单元数过多又会延长网络学习的时间, 误差并不一定最小. 本文根据经验公式初步选取隐层神经元个数, 公式如下:

$$b = \sqrt{m+n} + a$$

其中, m 为输入层神经元个数, n 为输出层神经元个数, b 为隐层神经元个数, a 为 1 ~ 10 之间的整数.

3.2 实现步骤^[7-8]

设输入层数据 x_i 表示, 期望输出和实际输出分别用 d_k 和 o_k 表示, 结点 i 到隐层结点 j 的连接权值为 w_{ji} , 隐层结点 j 到输出结点 k 的连接权值为 w_{kj} , N_1 、 N_2 和 N_3 分别为输入层、隐层和输出层结点数, $f(x)$ 为网络的激活函数, 一般选用 Sigmoid 函数.

(1) 初始化权值和阈值为较小的随机数值, 范围在 $[-0.5, 0.5]$ 之间并提供训练样本 (X_k, D_k) ;

(2) 计算网络的实际输出以及隐层单元的状态:

$$o_{kj} = f_j(\sum_i w_{ji} o_{ki} + \theta_j)$$

(3) 根据隐层单元和输出层单元的实际输出计算训练误差:

$$\delta_{kj} = o_{kj}(1 - o_{kj})(d_{kj} - o_{kj}) \quad (\text{输出层})$$

$$\delta_{kj} = o_{kj}(1 - o_{kj}) \sum_m \delta_{km} w_{mj} \quad (\text{隐层})$$

(4) 训练误差反向传播, 各神经元之间的连接权值以及神经元的阈值则根据公式(1)作如下修正:

$$\begin{aligned} w_{ji}(t+1) &= w_{ji}(t) + \eta \delta_{kj} o_{ki} \\ &\quad + \alpha [w_{ji}(t) - w_{ji}(t-1)] \\ \theta_j(t+1) &= \theta_j(t) + \eta \delta_j + \alpha [\theta_j(t) - \theta_j(t-1)] \end{aligned}$$

(5) 所有样本训练一次之后, 计算均方误差, 误差计算公式如下:

$$E = \sqrt{\sum_{k=1}^m \sum_{j=1}^n (d_{kj} - o_{kj})^2 / m \cdot n}$$

(6) 根据公式(2)比较本次均方误差与上次均方误差从而调整学习速率, 再次训练所有样本直到最后的指标满足精度(ϵ)要求:

$$E \leq \epsilon;$$

(7) 结束.

4 实验验证

4.1 客流特征的提取

为了识别目标, 首先应该得到目标的相应特征信息, 通过二值化后的前景图像来进行特征提取. 本文主要是通过提取客流视频中行人的宽度信息、高度信息和面积来进行目标识别^[9-10].

根据小孔成像原理, 目标的投影面积不仅与其实际体积有关, 也与目标到镜头的距离成反比, 因此本文采用的行人检测区域则是比较靠近摄像头的一个区域并且摄像头位于商场出入口的上方.

本文主要对人行通过检测线区域的几种情况进行了分析和处理. 人行通过检测线区域的几种情况如图 1~图 3 所示.




图 1 单人通过检测线区域




图 2 双人并行 图 3 三人并行

实验过程中,我们首先提取到了视频中的行人图像并对它做了膨胀、腐蚀、滤波等相关处理,将行人从二值前景图像中分割出来,作为分析区域,从而获得客流量中行人的特征信息(宽度信息、高度信息和面积),其效果图如图 4 所示。




图 4 特征信息提取效果图

在图像序列中,行人的面积大小可以近似为目标在摄像头拍摄区域中的投影面积大小,本文是使用白色像素点的个数来计算近似目标的面积,计算公式如下:

$$\text{Area} = \sum_{i=\text{Min}x}^W \sum_{j=\text{Min}y}^H B_t(i,j)$$

公式中, $B_t(i,j)$ 是 t 时刻的二值图像,点是 $(\text{Min}x,\text{Min}y)$ 是目标外接矩形的左上角端点, W 和 H 分别是矩形的宽度和高度。

4.2 网络结构选取及训练

本文针对客流的相关特征,初步确定训练网络结构为 3—8—3,即输入层为 3 个神经元,表示宽度信息、高度信息和面积 3 个输入向量,隐含层为 8 个神经元,输出层为 3 个神经元,初始学习率 $\eta = 0.4$,动量系数 $\alpha = 0.3$,误差精度 $e = 0.0045$ 。

本文首先对样本的输入层数据向量进行归一化处理,部分结果见表 1。

通过实验,我们发现,当采用 $(1,0,0)$ 、 $(0,1,0)$ 和 $(0,0,1)$ 作为网络的输出向量时,BP 网络无法收敛。因为采用的激活函数的输出永远不可能达到 0 或 1,而只能是无限逼近。因此本文的输出层向量采用如下类型,见表 2。

由于网络的初始隐层神经元个数是根据经验公式选取的,对于不同的隐层神经元个数,网络性能也将受到影响,因此本文测试了不同隐层神经元个数下网络训练的训练次数以及训练时间,见表 3。

表 1 部分归一化后的输入层数据向量

宽度信息	高度信息	面积
0.00526047	0.00205351	0.289103
0.00539805	0.00081519	0.238291
0.00546279	0.00425261	0.237887
0.00480863	0.00232366	0.259376
0.00491759	0.00331863	0.298657
0.0048958	0.00135332	0.301244
0.00527517	0.00425428	0.287997
0.00511979	0.00426537	0.302473
0.0103339	0.00271463	0.550277
0.0107842	0.00249097	0.630534
0.0111457	0.00414713	0.457745
0.0114095	0.00345081	0.469402
0.0109717	0.00269631	0.466616
0.0109487	0.00394675	0.444239
0.017923	0.00351333	0.848617
0.0179561	0.00372161	0.889714
0.0193189	0.0042568	0.9323
0.0188116	0.00425815	0.829779

表 2 输出层数据向量

样本类别	备注	输出向量		
类别 1	单人通过	0.9	0.1	0.1
类别 2	双人并行通过	0.1	0.9	0.1
类别 3	三人并行通过	0.1	0.1	0.9

表 3 隐层结点数不同对网络训练的影响

次数	隐含层结点数	训练次数	训练时间(ms)
1	8	320380	306406
2	10	131334	145125
3	15	264315	421468
4	20	394827	821906
5	25	203896	990859

根据表 3,最终确定隐含层神经元个数为 10 个。另外由于网络训练的学习速率不是固定的,因此本文还在确定隐层单元数的情况下,分析了误差收敛过程中学习速率的变化状态,如图 5 所示。




图 5 学习误差和学习速率变化的曲线

5 实验结果分析

本文选取了 250 个训练样本, 160 个测试样本. 其中 100 个训练样本是单人通过检测区域时的特征信息, 100 个训练样本是两人并行通过检测区域时的特征信息, 50 个训练样本是三人并行通过检测区域时的特征信息. 选取部分样本测试输出结果, 见表 4. 对样本进行训练以及测试之后, 本文对样本的识别率进行了相应统计, 结果见表 5.

表 4 部分样本测试输出结果

样本类别	输出向量		
类别 1	0.901153	0.0978994	0.100894
类别 2	0.101238	0.897763	0.100963
类别 3	0.0974942	0.0989441	0.903457

表 5 样本识别率

类别	测试样本	识别率
类别 1	80	95.12%
类别 2	60	93.65%
类别 3	20	88.01%

从表 5 可以看出, 单人和双人并行的识别率较高, 而三人并行的识别率不是很好, 由此可见单人和双人并行的样本选取比较全面, 但是三人并行的样本选取还不够全面, 这也是在实际项目应用中, 三人并行的情况不够常见导致的.

最后本文使用实验确定的网络结构(3-10-3)对网络进行训练, 并分析了传统 BP 算法下和改进 BP 算法下网络训练误差的不同, 实验结果如图 6 所示.

6 结束语

本文对传统的 BP 算法做了一些改进, 并将改进后的 BP 网络模型应用于客流量中目标的识别和分类, 验证了其在商场客流量应用中的可行性. 与传统的方法相比, 改进的 BP 算法灵活性强, 精度高.




图 6 网络训练的误差曲线对比

另外本文的研究还不够完善, 比如应考虑到光照等客观因素的影响. 由于采用的是 BP 神经网络模型, 也不可避免的存在网络训练中的难点, 如无法从理论上严格确定的训练次数、训练时间等问题. 今后通过对上述问题的改进, 能够寻找到更加合适的方法.

参考文献:

- [1] Jacobs R A. Increased rates of convergence through learning rate adaptation[J]. Neural Networks, 1998, 1(4):295-308.
- [2] 杨建刚. 人工神经网络实用教程[M]. 浙江: 浙江大学出版社, 2003.
- [3] Abhijit S, Pandya, Robert B Macy. 徐勇, 荆涛, 译. 神经网络模式识别及其实现[M]. 北京: 电子工业出版社, 1999.
- [4] 张国翊, 胡铮. 改进 BP 神经网络模型及其稳定性分析[J]. 中南大学学报: 自然科学版, 2011, 42(1): 115-124.
- [5] 郭诚, 李宏伟, 王国庆. 一种新的变学习速率自适应独立分量分析算法[J]. 计算机工程与应用, 2007, 43(1): 53-56.
- [6] 刘巧歌, 付梦印. 改进的神经网络及其自适应学习速率的研究[J]. 小型微型计算机系统, 2007, 28(5): 845-848.
- [7] 郁洪江, 宫宁生, 胡斌. 改进的 BP 神经网络在交通流量预测中应用[J]. 微电子学与计算机, 2010, 27(1): 106-108.
- [8] 李昆仑, 胡小明. 一种改进型 BP 算法在自适应控制系统中应用的研究[J]. 自动化仪表, 2001, 22(12): 15-18.
- [9] 万来毅, 陈建勋, 王卫平, 李俊. 基于 BP 神经网络的图像识别研究[J]. 武汉科技大学学报: 自然科学版, 2006, 29(3): 277-279.
- [10] 卜富清. 基于人工神经网络的图像识别和分类[D]. 成都理工大学, 2010.

作者简介:

俞克强 男, (1987-), 硕士研究生. 研究方向为人工神经网络.

宫宁生 男, (1958-), 教授, 硕士研究生导师. 研究方向为模式识别, 神经网络.

徐昊骞 女, (1985-), 硕士研究生. 研究方向为信号与信息处理.