

基于对向传播神经网络的人脸识别方法

金明曦, 武妍

(同济大学计算机科学与工程系 上海 200092)

【摘要】根据对向传播网络适于模式分类的特性,提出了基于对向传播神经网络的人脸识别方法。同时,为了克服对向传播网络在训练过程中的不稳定性,改进了对向传播神经网络的学习算法,并且以国际通用的ORL人脸库为对象进行实验研究。结果表明,选择合适的参数,就可以达到理想的识别效果。证明了基于对向传播神经网络的人脸识别方法是有效可行的。

关键词 神经网络; 对向传播网络; 人脸识别; 模式分类
中图分类号 TP183 文献标识码 A

Face Recognition Based on Counter Propagation Network

Jin Mingxi, Wu Yan

(Department of Computer Science and Engineering, Tongji University Shanghai 200092)

Abstract It is well known that, counter propagation network is fitful for pattern classification. According to such attribute, we present a face recognition algorithm based on counter propagation network. Meanwhile, we modify the learning method of counter propagation network in case of its instability during the training phase, and do some experiments with ORL face library that is international universal. Experiments show that we can achieve sound result by choosing parameters appropriately. So, the recognition algorithm based on counter propagation network is effective and practicable.

Key words neural network; counter propagation network; face recognition; pattern classification

人脸识别是当前人工智能研究的重点,在国家安全、民事经济、家庭娱乐等领域,具有广泛的应用前景。近年来,许多针对人脸识别的研究方法,但神经网络的方法是研究热点,各种神经网络为不同目的的研究提供了可能。

在以往用神经网络进行人脸识别的研究中,较多采用的是反向传播网络和径向基网络^[1,2]。而本文所应用的对向传播神经网络(Counter Propagation Network, CP)是将特征映射网络与基本竞争型网络相结合,发挥各自特长而构成的一种新型神经网络^[3]。该网络适用于模式分类、函数逼近、统计分析以及数据压缩等领域。

1 CP网络

CP网络拓扑结构如图1所示^[4],它由输入、竞争和输出层构成,各层神经元之间全互连接。输入层与竞

收稿日期:2004-06-14

基金项目:国家自然科学基金资助项目(60135010)

作者简介:金明曦(1980-),女,硕士生,主要从事模式识别,人工神经网络,图像处理,语音处理方面的研究;武妍(1967-),女,博士,副教授,主要从事人工神经网络,计算智能及其在模式识别中的应用研究等方面的研究。

争层构成特征映射网络；竞争层与输出层构成基本竞争型网络。

在学习过程中，CP网络反复不断地在竞争层内挑选获胜神经元，并且调整与获胜神经元对应的连接权，最终趋于稳定。各神经元所对应的连接权在经过学习调整后，记录了所有输入模式的综合信息，并且通过这些信息对目标进行正确地识别。传统的学习算法每次只对与竞争层获胜的那个神经元对应的连接权进行调整，假如前后两次获胜的都是同一神经元，则与该神经元对应的连接权会记录下前后两个输入模式的信息。为了避免获胜的神经元过于集中导致记录信息混乱的情况，人为地干预获胜神经元，使之分散开来，对于提高CP网络的训练效果是有益的。

为了能够对改进的CP网络学习算法进行更好的描述，设置的网络符号如下：设CP网络输入模式为 $U_k = [u_1^k, u_2^k, \dots, u_n^k]^T$ ，竞争层的输出为 $V_k = [v_1^k, v_2^k, \dots, v_m^k]^T$ ，输出层的实际输出为 $C_k = [c_1^k, c_2^k, \dots, c_z^k]^T$ ，输出层的希望输出为 $Y_k = [y_1^k, y_2^k, \dots, y_z^k]^T$ 。其中 n 、 m 和 z 分别为输入层、竞争层和输出层神经元的个数， $k=1,2,\dots,p$ ， p 为输入模式个数。输入层至竞争层连接权矢量为 $W_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T$ ， $j=1,2,\dots,m$ 。竞争层至输出层的连接权矢量为 $Q_l = [q_{l1}, q_{l2}, \dots, q_{lm}]^T$ ， $l=1,2,\dots,z$ 。

改进后的CP网络学习算法如下：

1) 初始化。将 $W_j (j=1,2,\dots,m)$ 和 $Q_l (l=1,2,\dots,z)$ 各分量赋予 $[0,1]$ 区间内的随机值。将输入模式 $U_k (k=1,2,\dots,p)$ 按下式进行归一化处理： $u_i^k = u_i^k / \|U_k\|$ ($i=1,2,\dots,n$)，其中 $\|U_k\| = \sqrt{\sum_{i=1}^n (u_i^k)^2}$ 。同时，为竞争层每个神经元附加一个变量 t (初始值为0)以记录该神经元获胜次数，设定神经元获胜的最大次数 T ，并且指定误差容限值 e 。

2) 将第 k 个输入模式 U_k 提供给网络输入层。

3) 将连接权矢量 $W_j (j=1,2,\dots,m)$ 进行归一化处理： $w_{ji} = w_{ji} / \|W_j\|$ ($i=1,2,\dots,n$)，其中 $\|W_j\| = \sqrt{\sum_{i=1}^n (w_{ji})^2}$ 。

4) 求竞争层神经元的输入激活值： $S_j = \sum_{i=1}^n w_{ji} u_i^k$ ($j=1,2,\dots,m$)。

5) 在计算出的 S_j 中找出最大的激活值 S_a ($1 \leq a \leq m$)。如果 S_a 的 $t < T$ ，则 $t = t + 1$ ，且将 S_a 对应的神经元作为竞争层获胜神经元 g ；否则，若 $t = T$ ，就选择除 S_a 外的最大激活值 S_b 。若 S_b 的 $t < T$ ，则 $t = t + 1$ ，且将 S_b 对应的神经元作为竞争层获胜神经元 g ；否则，按照激活值从大到小的顺序依次在 S_j 中寻找。将竞争层获胜神经元 g 的输出 v_g 置1，其余置0，它所对应的连接权即为 W_g 。

6) 调整 W_g ，即 $w_{gi}(t+1) = w_{gi}(t) + a(u_i^k - w_{gi}(t))$ ($i=1,2,\dots,n$)，式中， a 为学习率 ($0 < a < 1$)。

7) 调整竞争层获胜神经元 g 至输出层神经元的连接权矢量 $Q_g = [q_{1g}, q_{2g}, \dots, q_{lg}]$ ，而其他连接权保持不变，即 $q_{lg}(t+1) = q_{lg}(t) + b v_j (y_l^k - c_l^k)$ ($l=1,2,\dots,z$)，式中， b 为学习率 ($0 < b < 1$)。

8) 求输出层各神经元的综合输入信号加权和，并将其作为输出神经元的实际输出值 c_l^k ， $c_l^k = \sum_{j=1}^m q_{lj} v_j = q_{lg}$ ， $l=1,2,\dots,z$ 。

9) 计算网络实际输出 C_k 与希望输出 Y_k 的之间的误差： $err = \sqrt{\sum_{i=1}^z (c_i^k - y_i^k)^2}$ 。

10) 判断步骤9)中算出的误差是否小于误差容限，如果小于误差容限，则继续步骤11)，进行下一模式的学习；若大于误差容限，则返回步骤3)，继续学习。

11) 返回步骤2)，直至 p 个输入模式全部提供给网络。

从算法的描述可以看出，改进后的CP网络学习算法可通过设置神经元获胜的最大次数 T 来迫使网络对于不同类别的模式分配不同的竞争优势单元。这样有效地克服了CP网络竞争层的不稳定性，避免了网络在训练过程中出现的局部最小点，使得竞争层各单元的连接权能够比较精确地表示各类模式向量的空间分布情况。

2 CP网络用于人脸识别

为了利用CP网络识别人脸,按照图1所示建立一个包括输入层在内共三层的神经网络:

1) 将人脸图片各点像素值按照一定顺序变为一个高维向量作为输入模式送入CP网络,因此网络输入层的神经元数目为人脸图片像素数。

2) 输出层的神经元数目由模式类别数确定。换言之,有多少个不同的人需要我们识别,输出层的神经元个数就为多少,也可再加上1~2个神经元用以计算拒识率。在训练过程中,每个输入模式的希望输出为 $[0, \dots, 0, 1, 0, \dots, 0]$,输出为1的神经元即对应着该输入模式所属的模式类别。

3) 中间竞争层的神经元数目没有限制,但是为了保证CP网络的性能,建议其个数最好不要小于输出层的神经元数目。

建立好网络,按照学习规则对其进行训练即可。

网络收敛速度的快慢、训练后网络性能的好坏与很多因素有关,比如误差容限。如果误差容限值设置较大,则网络收敛速度很快,但是性能可能会下降;如果设置较小,性能可能很好,但是训练时间会增长。因此,误差容限值设置要适中,一般为0.001~1。

学习率 a 和 b 的大小对于收敛速度也有影响,一般不超过0.7。

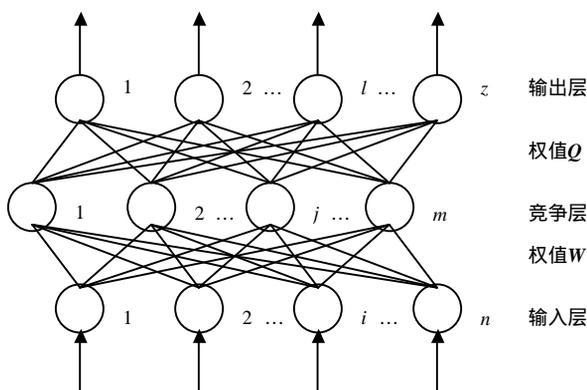


图1 CP网络的结构



图2 ORL库中的图像

3 实验结果与分析

本文实验所采用的人脸图片均来自国际通用的Oliver Research Laboratory (ORL)人脸数据库。该数据库由40人、每人10幅、大小为 92×112 、灰度级为256的人脸图像所组成。这些图像是在不同光照、不同角度、不同表情(睁/闭眼,笑/严肃)和不同细节(有无眼镜)条件下摄取得到的。图2所示的ORL库中的人脸图像。

训练集由ORL库中前20人,每人前 n 幅图像共 $20 \times n$ 个样本组成;测试集1由训练集中20人,每人剩余的图像共 $(200 - 20 \times n)$ 个样本组成,用于测试CP网络对已有人脸的识别率;测试集2由ORL库中其余20人,每人10幅图像共200个样本组成,用于测试CP网络对未知人脸的拒识率。

取误差容限 $e = 0.01$,实验结果如表1所示。

表1 n 取不同值时的识别率

n	训练集样本数	收敛步数	训练集识别率/(%)	测试集1识别率/(%)	测试集2拒识率/(%)
3	60	160	100	85.00	100
4	80	221	100	85.83	100
5	100	243	100	92.00	100
6	120	265	100	93.75	100

由于表1中的训练集是选取每个人的前面几幅图像构成,而ORL库中每个人的10幅图片前后差异较大,因而造成了错误识别。如果对训练集样本进行有目的挑选,使之覆盖各种表情、姿态,识别率还会有所提高。

为了更感性地认识CP网络应用于人脸识别的效果,表2给出了针对相同训练集和测试集,基于反向传播网络(Back Propagation Network, BP)的和基于CP网络的人脸识别方法的效果^[1]。

训练集1、测试集1的定义分别与表1的训练集、测试集1相同,且 n 取5;训练集2由ORL库中前20人,每人取第1、3、5、7、9幅图像共100个样本组成;测试集2由训练集2中20人,每人剩余的第2、4、6、8、10幅图像共100个样本组成;测试集3相当于表1的测试集2,用于测试拒识率。

表2 两种方法用于人脸识别的效果对比

人脸识别方法	收敛步数	训练集1 识别率/(%)	测试集1 识别率/(%)	训练集2 识别率/(%)	测试集2 识别率/(%)	测试集3 拒识率/(%)
基于BP网络	381	100	89.50	100	92.50	100
基于CP网络	243	100	92.00	100	96.00	100

BP网络是采用误差逆传播校正算法的多层前馈型网络。在表2的对比实验中,为了使两种方法具有可比性,BP网络与CP网络的结构基本一致,均采用三层结构:输入层的神经元数目、输出层的神经元数目均相同,分别为10 304个和21个;中间竞争层的神经元数目为30~40个;训练时的误差容限也相同。

在相同条件下,基于CP网络的人脸识别方法与基于BP网络的方法相比,识别率要高出3个百分点左右。特别在对训练样本的构成进行挑选之后(如训练集2),基于CP网络的识别方法其识别率大幅提高:由原来的92%提高到现在的96%。

此外,CP网络学习过程中对连接权调整的计算量与同等规模的其他网络相比是最少的,因而它的学习速度很快。同等条件下,BP网络的收敛步数为381步,而CP网络仅为243步。

4 总 结

不论何种识别方法,高识别率是追求的目标。本文所提出的基于CP网络的方法充分利用了其适宜于模式分类的特性,实验结果也表明它应用于人脸识别,有很好的效果;与其他识别方法相比,表现同等优异,甚至在某些方面更具有优势,如训练速度快等。

如果能对训练集中的图像做一些预处理,对CP网络的构造结构、学习方法和学习率参数的选择做进一步的研究,网络性能应该还会有所提高,由此入手探寻一种快速高效的识别方法是一条可行之路。

参 考 文 献

- [1] 甘俊英,张有为. 基于BP神经网络的人脸识别[J]. 系统工程与电子技术, 2003, 25(1):113-115
- [2] Er M J, Wu Shiqian, Lu Junwei. Face recognition using radial basis function (RBF) neural networks[J]. Decision and Control, 1999, 3:2 162-2 167
- [3] Hecht-Nielsen R. Counter propagation networks[J]. Proc. of IEEE First Int'l Conference on Neural Networks, 1987, 2:19-32
- [4] 王 旭, 王 宏, 王文辉. 人工神经网络原理与应用[M]. 沈阳: 东北大学出版社, 2000. 123-125

编 辑 漆 蓉