

基于提升小波变换与学习矢量量化网络的鉴别分析方法

陈 蕾,黄贤武,刘家胜,仲兴荣
(苏州大学 电子信息学院,江苏 苏州 215021)
(chenlei@suda.edu.cn)

摘 要:提出了一种基于提升小波变换(LWT)和学习矢量量化网络(LVQ)相结合的鉴别分析方法。提升小波又叫作第二代小波,比传统的第一代小波变换更为快速有效,利用它的多分辨率特性,可以获取输入图像的低频信息并使图像降维。LVQ 算法是在有教师状态下对竞争层进行训练的一种学习算法。LVQ 网络结构简单,但却表现出比 BP 网络更强的有效性和鲁棒性。在 ORL 标准人脸库及现实人脸图像上的实验结果表明该方法具有很好的鉴别分析能力。

关键词:提升小波变换;学习矢量量化;鉴别分析;神经网络;人脸识别

中图分类号: TP391.41; TP183 **文献标识码:** A

Discriminant analysis based on lifting wavelet transform and learning vector quantization

CHEN Lei, HUANG Xian-wu, LIU Jia-sheng, ZHONG Xing-rong
(School of Electronics and Information Engineering, Soochow University, Suzhou Jiangsu 215021, China)

Abstract: A new discriminant analysis method based on LWT(Lifting Wavelet Transform) and LVQ(Learning Vector Quantization) Network was proposed in this paper. LWT is faster and more efficient than the first generation wavelet transform, but it also has the multi-resolution characteristics. LWT can be used to extract the low frequency coefficients and reduce the dimension of an image. LVQ is an effective learning algorithm that trains the competitive layer under supervision. It has a simple network structure, but it also has good discriminant analysis ability. The experimental results on ORL face database show that the method proposed has very good classification capability and high recognition rate.

Key words: LWT(Lifting Wavelet Transform); LVQ(Learning Vector Quantization); discriminant analysis; neural network; face recognition

0 引言

小波分析是傅里叶分析发展史上里程碑式的进展,由于它在时频两域都具有表征信号局部特征的能力,因此成为一种有效的信号分析和处理方法。传统的第一代小波是在欧氏空间内通过基底的平移和伸缩构造小波基的,不适合非欧氏空间的应用,而且基于卷积的离散小波变换计算量大,计算复杂度高,对存储空间的要求高,不利于硬件实现。因此小波提升方案应运而生,它使我们能够用一种简单的方法解释小波的基本理论。提升算法继承了第一代小波的多分辨率特征,但不依赖于傅里叶变换,给出了小波完全的空间域解释,它具有许多优良的特性:结构简单、运算量低、原位运算、节省存储空间,以及可逆的整数到整数变换,便于实现。图像经过提升小波变换,其低频部分保留了绝大部分信息和能量,利用这个特点可以有效地对图像特征进行压缩和提取。

学习矢量量化网络是一种混合网络,由输入层、竞争层和线性输出层组成。通过有监督及无监督的学习进行分类。比起普遍使用的 BP 网络,有其独特的优势。BP 网络的缺点在于采用基于梯度下降的非线性优化策略,有可能陷入局部最小问题,不能保证求出全局最小值。其他一些优化策略如遗传算法、模拟退火算法等,虽然可以求得全局最小,但是计算

量很大,有时候会出现效率问题。LVQ 网络的优点是不需要将输入向量进行归一化、正交化处理,只需要直接计算输入向量与竞争层之间的距离,即可实现模式识别,而且对姿态变化的人脸图像具有一定的鲁棒性。

将提升小波变换与学习矢量量化网络结合起来,可以有效提高特征提取速度和鉴别分析效率。

1 提升小波变换原理




图 1 提升算法的分解和重构

基于提升算法的小波变换又被称为第二代小波变换, Daubechies 证明,凡是第一代小波变换都可以找到等效的提升方案^[1]。提升算法给出了双正交小波简单而有效的构造方法,使用基本的多项式插补来获取信号的高频分量,再通过构建尺度函数来获取低频分量。提升算法的基本思想是将现有的小波滤波器分解成基本的构造模块,分步骤完成小波变

收稿日期:2006-03-10; 修订日期:2006-06-07

作者简介:陈蕾(1967-),女,广东海丰人,博士研究生,主要研究方向:图像处理、模式识别; 黄贤武(1941-),男,教授,博士生导师,主要研究方向:图像处理、模式识别、多媒体通信; 刘家胜(1971-),男,博士研究生,主要研究方向:图像加密技术、数字信号处理; 仲兴荣(1970-),男,讲师,主要研究方向:视频图像分割、多媒体通信。

换。提升算法分为3个步骤,提升算法的分解和重构如图1所示。

(1) 分解。将输入信号 s_i 分为两个较小的子集 $x_e(n)$ 和 $x_o(n)$, $x_o(n)$ 也称为小波子集。通常 $x_e(n)$ 表示信号的低频近似分量, $x_o(n)$ 表示信号的高频细节分量。最简单的分解方法是将输入信号 s_i 根据奇偶性分为两组 $x_e = s_{2i}$ 和 $x_o = s_{2i+1}$ 。

(2) 预测。在基于原始数据相关性的基础上,用偶数部分预测奇数部分,即采用一个与数据集无关的滤波器 P 去预测 $x_o(n)$ 。由于可以用 $x_e(n)$ 预测 $x_o(n)$, 因此,就可以用数据子集 $x_e(n)$ 代替原始的数据集 s_i 。实际中,虽然不可能从子集 $x_e(n)$ 中准确地预测子集 $x_o(n)$, 但是 $Px_e(n)$ 有可能很接近 $x_o(n)$, 因此可以使用 $Px_e(n)$ 和 $x_o(n)$ 的差来代替原来的 $x_o(n)$, 这样产生的 d_{i-1} 比原来的 $x_o(n)$ 包含更少的信息, 于是得到 $d_{i-1} = x_o(n) - Px_e(n)$, 这里,已经可以用更小的子集 $x_e(n)$ 和小波子集 d_{i-1} 来代替原信号集 s_i 。

(3) 更新。为了使原信号集的某些全局特性在其子集中继续保持,必须进行更新。更新的思想是要找一个更好的子集 s_{i-1} , 使得它保持原图的某一标量特性 $Q(x)$ (例如均质、消失距等不变), 即有 $Q(s_{i-1}) = Q(s_i)$ 。可以利用已经计算的小波子集 d_{i-1} 对 $x_e(n)$ 进行更新, 从而使得后者保持特性 $Q(x)$, 即要构造一个算子 U 去更新 s_{i-1} 。定义如下:

$$s_{i-1} = x_e(n) + U(d_{i-1}) \quad (1)$$

可见,提升方法可以实现原位运算,即该算法不需要除了前级提升步骤的输出之外的数据,这样在每个点都可以用新的数据流替换旧的数据流,当重复使用原位提升滤波时,就得到了交织的小波变换系数。

利用提升算法对图像进行分解和重构,并利用低频分量对图像进行压缩的结果如图2所示。




图2 提升小波变换特征提取

2 LVQ 网络

2.1 网络模型

一个LVQ网络由三层神经元组成,即输入层、竞争层、输出层,网络模型如图3所示。该网络在输入层与竞争层之间为完全连接,而在竞争层与输出层之间为部分连接,每个输出神经元与竞争神经元的不同组相连接。竞争层和输出神经元之间的连接权值固定为1。输入层和竞争神经元间的连接权值建立为参考矢量的分量(对每个竞争神经元指定一个参考矢量)。在网络训练过程中,这些权值被修改。竞争神经元和输出神经元都具有二进制输出值。当某个输入模式被送至

网络时,参考矢量最接近输入模式的竞争神经元因获得激发而赢得竞争,因而允许它产生一个“1”。其他竞争神经元都被迫产生“0”。与包括获胜神经元的竞争神经元组相连接的输出神经元也发出“1”,而其他输出神经元均发出“0”。产生“1”的输出神经元给出输入模式的类,每个输出神经元被表示为不同的类^[4,5]。




图3 LVQ网络模型

2.2 LVQ 网络学习规则

假定网络输入层的输入向量为 $X = (x_1, x_2, \dots, x_M)$, 其中, M 为输入神经元的数目; 输入层和竞争层之间的连接权值矩阵为 $W^1 = (w_1^1, w_2^1, \dots, w_p^1)$, $w_i^1 = (w_{i1}^1, w_{i2}^1, \dots, w_{iM}^1)$ 。中, $i = 1, 2, \dots, P; j = 1, 2, \dots, M$, 表示输入层第 i 个神经元和第 j 个神经元之间的连接权值, P 为竞争神经元的数目, 竞争层的输出向量为 $V = (v_1, v_2, \dots, v_p)$, 竞争层与输出层神经元之间的连接权值矩阵为 $W^2 = (w_1^2, w_2^2, \dots, w_N^2)$, 其中 $w_k^2 = (w_{k1}^2, w_{k2}^2, \dots, w_{kp}^2)$ 。中, $k = 1, 2, \dots, N; r = 1, 2, \dots, p$, 表示竞争层第 k 个神经元与输出层第 r 个神经元之间的连接权值, N 为输出层神经元的数目。竞争层的每个神经元通过学习原型向量, 并对输入空间进行分类。将竞争层学习得到的类称为子类, 将输出层学习得到的类称为目标类^[7]。LVQ 学习算法为:

第1步 设置变量和参量: $X(n) = [x_1(n), x_2(n), \dots, x_N(n)]^T$ 为输入向量, 或称训练样本。

$W_i(n) = [w_{i1}(n), w_{i2}(n), \dots, w_{iN}(n)]^T$ 为权值向量, $i = 1, 2, \dots, M$ 。 n 为迭代次数, N 为迭代总次数。选择学习速率的函数 $\eta(n)$ 。

第2步 初始化权值向量 $W_i(0)$ 及学习速率 $\eta(0)$ 。

第3步 从训练集中选取输入向量 X 。

第4步 通过欧氏距离最小的标准:

$$\|X - W_c\| = \min_i \|X - W_i\|, \quad i = 1, 2, \dots, M \quad (2)$$

寻找获胜神经元 c , 从而实现了神经元的竞争过程。

第5步 判断分类是否正确, 根据如下规则调整获胜神经元的权值向量:

用 L_{W_c} 代表与获胜神经元权值向量联系的类, 用 L_{X_i} 代表与输入向量相联系的类。

如果 $L_{X_i} = L_{W_c}$, 则

$$W_c(n+1) = W_c(n) + \eta(n)[X - W_c(n)] \quad (3)$$

否则, 当 $L_{X_i} \neq L_{W_c}$, 有

$$W_c(n+1) = W_c(n) - \eta(n)[X - W_c(n)] \quad (4)$$

对于其他神经元, 保持权值不变。

第6步 调整学习速率 $\eta(n)$


$$\eta(n) = \eta(0) \left(1 - \frac{n}{N}\right) \quad (5)$$

第7步 判断迭代次数是否超过 N , 如果 $n \leq N$ 就转到


第3步,否则结束迭代过程。

3 基于提升小波与 LVQ 网络的鉴别分析

先采用 ORL 人脸图像数据库进行鉴别分析实验。ORL 人脸图像数据库由 40 人,每人 10 幅,分辨率为 112×92 的灰度图像组成。从 ORL 人脸数据库中随机选取 10 人共 100 幅不同姿态的人脸图像,50 幅用于训练,50 幅用于测试。然后,换上 30 幅现实人脸图像进行了实验。对现实图像的训练与测试方法与用人脸库的方法是一样的,只是要先对这些图像进行预处理,如 RGB 图像到灰度图像的转换,灰度直方图变换,图像统一大小等。



(a) 用于训练的部分图像



(b) 用于测试的部分图像

图4 ORL 人脸图像库中的部分图像




图5 现实头肩图像



图6 用于训练与测试的部分现实人脸图像

输入向量和目标向量的设计。每幅图像的原始尺寸为 112×92 ,经过两次提升小波变换降维成 28×23 ,再经过行堆叠图像变成 1×644 的向量。由于参与训练的有 50 幅图像,因此输入向量为 644×50 。50 幅人脸图像分为 10 类,所以目标向量为 10×50 的向量,其中每一列中只有一个“1”,其余均为“0”。

网络创建、训练和测试。首先创建一个两层网络。网络有 644 个输入节点,10 个输出神经元。中间层节点数目的选择是一个复杂的问题。典型情况下,相同数量的中间层神经元连接到每个输出神经元,由于这里输出神经元有 10 个,于是可以初步设定中间层的神经元个数为 20,即每个类是两个子类的联合。

对连接权值初始化。在初始状态下,所有神经元都拥有

相同的权值,即为这些向量的中间值。学习速率反映了学习过程中连接权调整量的大小,初值设为 0.1。

期望误差的选取。在设计网络的训练过程中,期望误差值应当通过对比训练后确定一个合适的值,较小的期望误差值要靠增加隐含层的节点,以及训练时间来获得。本文期望误差取值为 0.1。学习函数用 $lvq1$,最大训练步数设为 1000,开始对网络进行训练。训练过程曲线如图 7 所示。从中可以看出,经过 20 次迭代就可达到误差要求。训练好的网络用 50 幅图像测试的结果是:当竞争层节点数为 10 时,不能有效识别;当竞争层节点数为 20 时,识别率为 94%;当竞争层节点数为 30 时,识别率为 96%。竞争层节点数再增加,对识别结果影响不大。训练样本的选取对测试结果影响非常大,若有目的地选取训练样本,识别率还可提高。对于现实的人脸图像,图像的偏转角度太大,也会影响判别结果。




图7 误差容限为 0.1 时的迭代次数—训练误差曲线

4 结语

本文提出了基于提升小波变换和学习矢量量化网络的鉴别分析方法。利用提升小波变换对图像进行预处理,抽取图像的低频小波特征,由于提升算法可以实现原位运算,小波变换后的系数是整数,因此特征抽取的速度大大提高。经过提升小波变换的图像低频特征被送到 LVQ 网络进行训练与测试。网络结构简单,它只通过内部单元的相互作用,就可以完成十分复杂的分类处理,也很容易将设计域中各种繁杂分散的设计条件收敛到结论上来。实验证明 LVQ 网络具有很好的模式分类特性,该网络表现出比 BP 网络更强的容错性和鲁棒性,而且实现简单、速度快。

参考文献:

- [1] DAUBECHIES I, SWELDENS W. Factoring wavelet transforms into lifting steps[J]. Journal of Fourier Analysis and Application, 1998, 4(3): 245-267.
- [2] BARUA S, CARLETTA JE, KOTTERI KA, et al. An efficient architecture for lifting-based two-dimensional discrete wavelet transforms[J]. Integration, the VLSI Journal, 2005, 38(3): 341-352.
- [3] STOER J, BULIRSCH R. Introduction to Numerical Analysis[M]. New York: Springer-Berlage Inc, 1998.
- [4] HAGAN MT, DEMUTH HB, BEALE MH. 神经网络设计[M]. 戴葵,译. 北京:机械工业出版社,2002.
- [5] 褚蕾蕾. 计算智能的数学基础[M]. 北京:科学出版社,2002.
- [6] 飞思科技产品研发中心. 神经网络理论与 MATLAB7 实现[M]. 北京:电子工业出版社,2005.
- [7] SANO K, MOMOSE S, TAKIZAWA H, et al. Efficient parallel processing of competitive learning algorithms[J]. Parallel Computing, 2004, 30(12): 1361-1383.