

文章编号:1001-9081(2006)05-1037-03

基于加权 Fisher 准则的线性鉴别分析及人脸识别

郭娟,林冬,戚文芽

(信息工程大学 信息工程学院,河南 郑州 450002)

(dove79@163.com)

摘要:提出了一种基于加权 Fisher 准则线性鉴别分析的人脸识别方法。该方法引入了一种新的权函数对 Fisher 准则加权,以提高样本在低维线性空间中的可分性,然后探讨了高维、奇异情况下如何降低运算量的问题,并给出了一个简单高效的算法。在 ORL 标准人脸库上进行测试,由该算法抽取的特征在最近邻分类器和最小距离分类器下均达到 96% 的正确识别率,这一结果优于经典的特征脸和 Fisher 脸方法在该库上的识别结果。

关键词:线性鉴别分析;加权 Fisher 准则;特征抽取;人脸识别

中图分类号: TP391.41 文献标识码:A

Linear discriminant analysis based on weighted Fisher criteria and face recognition

GUO Juan, LIN Dong, QI Wen-ya

(College of Information and Engineering, Information Engineering University, Zhengzhou Henan 450002, China)

Abstract: A novel method based on weighted discriminant analysis for face recognition was proposed in this paper. First, the Fisher criterion was redefined by introducing a weighting of the contributions of individual class pairs to the overall criterion. Then, to deal with the high dimensional and singular case in face recognition problems, a simple and efficient algorithm was developed. Finally, the proposed algorithm was tested on ORL face database, and a recognition rate of 96% was achieved by using either a common nearest neighbor classifier or a minimum distance classifier. The experimental results show our method is superior to the classical Eigenfaces and Fisherfaces.

Key words: LDA (Linear Discriminant Analysis); weighted Fisher criterion; feature extraction; face recognition

0 引言

特征抽取是模式识别研究的关键问题^[1],Fisher 线性鉴别分析(LDA)能有效提取最能反映不同类别之间差异的特征,是特征抽取中最经典的方法之一,目前仍然被广泛地应用在人脸等模式识别领域。

然而,最近的研究表明^[2],在一个多类识别问题中,Fisher 准则函数定义的样本类间离散度并不是最优的,该定义使得所有样本均值和各个类均值尽可能的分开,却可能造成各个类均值互相接近,导致实现降维的变换矩阵过分强调了那些本来已经较好分开的类别,却造成了相邻类的大量样本的重叠。为此,文献[2]采用权函数对类间散布矩阵进行修正,提出了一种逐对加权 Fisher 准则。

人脸识别属于典型的小样本问题,即待识别图像矢量的维数较高,难以找到或根本不可能找到足够多的训练样本来保证类内散布矩阵的可逆性。传统的解决方法主要分为两类:一类是从模式样本出发,通过事先降低样本向量的维数来达到消除奇异性的目的。如通过降低图像的分辨率实现降维^[3],以及通过 K-L 变化降维^[4],但都是以鉴别信息的损失为代价,因此无法保证所抽取的特征是最优的。另一类是从算法本身入手,发展直接针对于小样本问题的算法。如 Hong 的扰动法,Liu 的正交补空间法,Chen 的零空间法,Yang 的 D-LDA 方法等,但这些算法都存在着需要在原始维数空间中求解最优鉴别矢量集导致计算量太大的弱点。

本文借鉴逐对加权 Fisher 准则和 Yang 压缩变换的思想^[5],提出一种新的线性鉴别分析法,首先在不损失任何有

效鉴别信息的前提下,使得最优鉴别矢量的求解只需在低维的欧氏空间 R^m 中进行(m 表示总体散布矩阵的秩);然后在原始 Fisher 准则定义的基础上增加一个由类间距离决定的可变权函数;最后以此准则为目标函数进行特征抽取。该方法以样本类别的可分性最好为目标,并解决了类内散布矩阵奇异情况下的最优鉴别特征的抽取问题。在 ORL 人脸库上的试验表明,该方法所抽取的特征在普通的最近邻分类器和最小距离分类器下的正确识别率优于经典的特征脸和 Fisher 脸方法。

1 加权 Fisher 线性鉴别分析

1.1 基本概念

设 $\omega_1, \omega_2, \dots, \omega_c$ 为 c 个模式类, $X = \{x_i | i = 1, 2, \dots, N\}$ 为 n 维训练样本集, $x_i \in \omega_j, j = 1, 2, \dots, c$, 训练样本的类内散布矩阵 S_w 、类间散布矩阵 S_b 和总体散布矩阵 S_t , 分别定义为:

$$S_w = \sum_{i=1}^c P(\omega_i) E\{(X - m_i)(X - m_i)^T / \omega_i\} \quad (1)$$

$$S_b = \sum_{i=1}^c P(\omega_i) (m_i - m)(m_i - m)^T \quad (2)$$

$$S_t = S_w + S_b = E\{(X - m)(X - m)^T\} \quad (3)$$

其中, $P(\omega_i)$ 为第 i 类样本的先验概率, $m_i = E(X/\omega_i)$ 为第 i 类样本的均值, $m = E(X) = \sum_{i=1}^c P(\omega_i) m_i$ 为总体样本的均值。

由式(1)、式(2) 和式(3) 的定义可知, S_w, S_b, S_t 均为非负定矩阵。

收稿日期:2005-11-03;修订日期:2006-01-09

作者简介:郭娟(1979-),女,云南玉溪人,硕士研究生,主要研究方向:图像处理、模式识别;林冬(1975-),男,河北秦皇岛人,讲师,主要研究方向:图像处理、嵌入式系统;戚文芽(1968-),女,浙江余姚人,副教授,主要研究方向:图像处理、嵌入式系统。

Fisher 鉴别准则函数定义为:

$$J_f(\boldsymbol{\varphi}) = \frac{\boldsymbol{\varphi}^T \mathbf{S}_b \boldsymbol{\varphi}}{\boldsymbol{\varphi}^T \mathbf{S}_w \boldsymbol{\varphi}} \quad (4)$$

其中 $\boldsymbol{\varphi}$ 为任一 n 维列矢量。Fisher 线性鉴别分析就是选取使得 $J_f(\boldsymbol{\varphi})$ 达到最大值的矢量 $\boldsymbol{\varphi}^*$ 作为投影方向, 其物理意义是投影后的样本具有最大的类间离散度和最小的类内离散度。

在 Fisher 思想的基础上, 文献[6]提出了鉴别矢量集, 即通过最优化下面的准则函数找到由一组最优鉴别矢量构成的投影矩阵 \mathbf{W}_{opt} 。

$$J_c(\mathbf{W}) = \frac{|\mathbf{W}^T \mathbf{S}_b \mathbf{W}|}{|\mathbf{W}^T \mathbf{S}_w \mathbf{W}|} \quad (5)$$

以原始样本在投影矩阵 \mathbf{W}_{opt} 的投影作为鉴别特征用于识别, 该方法称为经典的 Fisher 线性鉴别分析。可以证明, 当 \mathbf{S}_w 非奇异时, 最优投影矩阵 \mathbf{W}_{opt} 的列向量恰为下列广义特征方程

$$\mathbf{S}_b \boldsymbol{\varphi} = \lambda \mathbf{S}_w \boldsymbol{\varphi} \quad (6)$$

的 d 个最大的特征值所对应的特征向量^[7], 且最优投影轴的个数 $d \leq c - 1$ 。

为了讨论 Fisher 准则的分类性能, 可将类间散布矩阵改写成^[2]:

$$\mathbf{S}_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c P(\omega_i)P(\omega_j)(\mathbf{m}_i - \mathbf{m}_j)(\mathbf{m}_i - \mathbf{m}_j)^T \quad (7)$$

因此, 在计算 \mathbf{S}_b 时, 式(7)对所有类别均赋予相同的权值。如图 1 所示, 考虑一个 n 维的样本模型投影到一维空间, 假定有一个类 4 与其他的类 1, 2, 3 分隔很远, 称其为边缘类, 则传统 LDA 算法获得的最佳投影方向 A 会将边缘类 4 与其他类别尽可能地分开, 即夸大了类间距离较大的、可分性很好的类别 4, 但却造成了类间距离本来就小的类别 1, 2, 3 的彼此重叠。因此, 就分类性而言, 基于 Fisher 准则得到的鉴别方向并不是最优的。

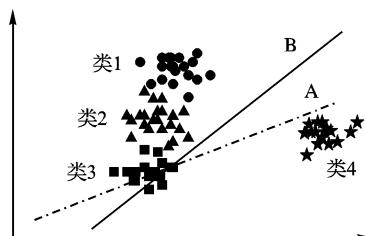


图 1 不同定义的 \mathbf{S}_b 导出不同的投影方向

1.2 加权 Fisher 准则

为了进一步提高 LDA 算法的鉴别能力, 削弱边缘类在特征分解过程中的主导作用, 文献[2]提出构建加权类间散布矩阵, 对类间距离不同的类间赋予不同的权重, 得到加权 Fisher 准则的表达式:

$$\tilde{J}_f(\boldsymbol{\varphi}) = \frac{\boldsymbol{\varphi}^T \tilde{\mathbf{S}}_b \boldsymbol{\varphi}}{\boldsymbol{\varphi}^T \mathbf{S}_w \boldsymbol{\varphi}} \quad (8)$$

其中,

$$\tilde{\mathbf{S}}_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c P(\omega_i)P(\omega_j)\omega(\Delta_{ij})(\mathbf{m}_i - \mathbf{m}_j)(\mathbf{m}_i - \mathbf{m}_j)^T \quad (9)$$

$$\omega(\Delta_{ij}) = \frac{1}{2\Delta_{ij}^2} \operatorname{erf}\left(\frac{\Delta_{ij}}{2\sqrt{2}}\right) \quad (10)$$

$$\Delta_{ij} = \sqrt{(\mathbf{m}_i - \mathbf{m}_j)^T \mathbf{S}_w^{-1} (\mathbf{m}_i - \mathbf{m}_j)} \quad (11)$$

Δ_{ij} 表示类别 i 和类别 j 之间的马氏距离。

$\operatorname{erf}(\cdot)$ 为错误函数, 表示为:

$$\operatorname{erf}(z) = \frac{2}{\sqrt{\pi}} \int_0^z e^{-t^2} dt \quad (12)$$

相应地, 基于加权 Fisher 准则(8)得到的鉴别向量集为下列广义特征方程的所有非零特征值对应的单位特征向量。

$$\tilde{\mathbf{S}}_b \boldsymbol{\varphi} = \lambda \mathbf{S}_w \boldsymbol{\varphi} \quad (13)$$

但是, 由于式(10)是在假定各类分布为具有相同方差的正态分布时使得贝叶斯错误率取得最小值的估计值, 需要同时计算类内散布矩阵的逆矩阵以及错误函数, 计算比较复杂。为减轻复杂度, 本着对高维空间中类间距离较小的类别之间应赋予较高的权重的原则, 本文采用较为简单的类间 Euclidean 距离取代马氏距离定义 Δ_{ij} , 重新定义加权函数如下:

$$\Delta_{ij} = \sqrt{(\mathbf{m}_i - \mathbf{m}_j)^T (\mathbf{m}_i - \mathbf{m}_j)} \quad (14)$$

$$\omega(\Delta_{ij}) = \frac{1}{\Delta_{ij}^{2\alpha}}, \quad \alpha = 2, 3, \dots \quad (15)$$

在图 1 中, B 为基于加权 Fisher 准则得到的最优投影方向, 在判别能力上该方向优于从传统 LDA 方法导出的投影方向 A 。

2 高维小样本情况下的处理

人脸识别是一类典型的小样本问题, 该问题的特点是: 图像矢量的维数较高; 训练样本较少。这就导致了 \mathbf{S}_w 常常是高阶的、奇异的。以 92×112 分辨率的图像为例, 图像矢量的维数高达 10304, 对应的 \mathbf{S}_w 是一个 10304×10304 的矩阵。若按常规方法直接求解 \mathbf{S}_w 的特征向量, 再从中寻找满足条件的投影方向, 其计算量是可想而知的。同时, 当 \mathbf{S}_w 奇异时, 必然存在零特征值, 这就导致了(8)式的准则函数失效。在该情况下, 如何选取投影轴, 有效地提取判别信息是本文要解决的另一问题。

2.1 利用压缩变换进行降维

本文的方法是借鉴 Yang 在文献[5]中提出的压缩变换思想, 以总体散布矩阵为产生矩阵, 求得 \mathbf{S}_t 的非零特征值所对应的特征向量 $\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_m$, 令 $\mathbf{P} = (\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_m)$, 进行同构变换 $\mathbf{Y} = \mathbf{P}^T \mathbf{X}$, 将高维的原始样本压缩为 m 维 (m 表示 \mathbf{S}_t 的秩); 在变换空间 \mathbf{R}^m 内, $\mathbf{S}'_w = \mathbf{P}^T \mathbf{S}_w \mathbf{P}$ 降为 m 阶, 由于 $m \leq N - 1 \ll n$, 故比传统的 LDA 方法降低了计算量, 有效避免了在高维的图像矢量空间内计算 \mathbf{S}_w 的特征向量的难题。

2.2 最优鉴别矢量的抽取

在变换空间 \mathbf{R}^m 内, \mathbf{S}'_w 的秩满足关系式:

$$\operatorname{rank}(\mathbf{S}'_w) = \operatorname{rank}(\mathbf{S}_w) = N - c = m + 1 - c > m$$

因此, \mathbf{S}'_w 是奇异的。当鉴别向量 \mathbf{w} 在 \mathbf{S}'_w 的零空间 $\Phi'_{\mathbf{w}}^{\perp}$ 中选取时, 有 $\mathbf{w}^T \mathbf{S}'_w \mathbf{w} = 0$, 即在 \mathbf{w} 上投影后类内离散度为零, 若此时有 $\mathbf{w}^T \mathbf{S}'_b \mathbf{w} > 0$, 则 $J_f(\mathbf{w}) = +\infty$ 。由 Fisher 准则的物理意义, \mathbf{w} 是一个有效的投影方向; 否则, 若 $\mathbf{w}^T \mathbf{S}'_b \mathbf{w} = 0$, 则样本在 \mathbf{w} 上投影后完全重叠在一起, 不含有任何鉴别信息。

因此, 在 \mathbf{S}'_w 奇异的情况下, 有效的投影方向可分为两类: 第一类满足条件 $\mathbf{w}^T \mathbf{S}'_w \mathbf{w} = 0$ 和 $\mathbf{w}^T \mathbf{S}'_b \mathbf{w} > 0$; 第二类满足条件 $\mathbf{w}^T \mathbf{S}'_w \mathbf{w} > 0$ 和 $\mathbf{w}^T \mathbf{S}'_b \mathbf{w} > 0$, 并优先选择第一类投影方向。对于第一类投影方向, (8)式无法判别哪一个更优, 改用以下准则进行判别^[8]:

$$J_b(\mathbf{Y}) = \mathbf{Y}^T \mathbf{S}'_b \mathbf{Y}, \quad \|\mathbf{Y}\| = 1 \quad (16)$$

该准则函数等价于以下 Rayleigh 商函数:

$$J_b^R(\mathbf{Y}) = \frac{\mathbf{Y}^T \mathbf{S}'_b \mathbf{Y}}{\mathbf{Y}^T \mathbf{Y}} \quad (17)$$

根据 Rayleigh 商的极值性质^[9], 最优鉴别向量取为特征方程 $\mathbf{S}'_b \mathbf{Y} = \lambda \mathbf{Y}$ 的前 d 个最大的特征值所对应的特征向量。结合前面的论述, 这里的 \mathbf{S}'_b 是指新定义的加权类间离散度(9)。

当鉴别向量 \mathbf{w} 在 \mathbf{S}'_w 的非零空间 $\Phi'_{\mathbf{w}}$ 中选取时, 采用新

的加权 Fisher 准则(8)为目标函数可求解得到 k 个最优鉴别向量。

3 实现算法

(1) 计算 S_t 的非零空间 Φ_t , 并用于降维

由 K-L 变换求得 S_t 的非零特征值所对应的标准正交特征向量 $\beta_1, \beta_2, \dots, \beta_m$, 其对应的特征值为 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m > 0, m = \text{rank}(S_t)$ 。

(2) 利用权函数重新定义类间离散度

$$S_b = \sum_{i=1}^{c-1} \sum_{j=i+1}^c P(\omega_i)P(\omega_j)\omega(\Delta_{ij})(\mathbf{m}_i - \mathbf{m}_j)(\mathbf{m}_i - \mathbf{m}_j)^T$$

(3) 计算变换空间 R^m 中的 S'_w, S'_b

令 $P = (\beta_1, \dots, \beta_m)$, 则 R^m 中 $S'_w = P^T S_w P, S'_b = P^T S_b P$ 。

(4) 求 S'_w 的零空间 Φ'^{\perp}_w 和非零空间 Φ'^+_w

求 S'_w 的 m 个对应特征值递减的标准正交特征向量 $\gamma_1, \gamma_2, \dots, \gamma_q, \dots, \gamma_m, q = \text{rank}(S'_w)$, 则 $\Phi'^{\perp}_w = \text{span}\{\gamma_{q+1}, \dots, \gamma_m\}, \Phi'^+_w = \text{span}\{\gamma_1, \dots, \gamma_q\}$ 。

(5) 在 S'_w 的零空间 Φ'^{\perp}_w 中求最优鉴别矢量集

令 $P_1 = (\gamma_{q+1}, \dots, \gamma_m)$, 则 Φ'^{\perp}_w 中类间散布矩阵为: $\bar{S}_b = P_1^T S'_b P_1$, 而 $\bar{S}_w = P_1^T S'_w P_1 = 0$, 求解方程 $\bar{S}_b w = \lambda w$ 得到前 d 个最大特征值所对应的特征向量 v_1, \dots, v_d , 则 Φ'^{\perp}_w 上的最优鉴别向量集 $D_0 = P_1 * [v_1, \dots, v_d]$ 。

(6) 在 S'_w 的非零空间 Φ'^+_w 中求最优鉴别矢量集

令 $P_2 = (\gamma_1, \dots, \gamma_q)$, 则 S'_w 的非零空间 Φ'^+_w 中有 $\bar{S}_b = P_2^T S'_b P_2$ 和 $\bar{S}_w = P_2^T S'_w P_2$, 求解方程 $\bar{S}_b w = \lambda \bar{S}_w w$ 得到前 k 个最大特征值所对应的特征向量 v_{d+1}, \dots, v_{d+k} , 则 Φ'^+_w 上的最优鉴别向量集 $D_0^{\perp} = P_2 * [v_{d+1}, \dots, v_{d+k}]$ 。

(7) 特征抽取

将子空间 $\Phi'^{\perp}_w, \Phi'^+_w$ 上的最优鉴别向量组合得到 $A = [D_0 D_0^{\perp}]$, 进一步得到 R^n 上的最优鉴别向量集 $B = P * A$, 则基于加权函数的最优特征抽取为: $Z = B^T X$ 。

4 试验与分析

ORL 人脸库由 40 人, 每人 10 幅 92×112 的图像组成, 其中有些图像拍摄于不同的时期; 人脸表情与脸部细节有着不同程度的变化, 如笑或不笑、眼睛睁或闭、戴或不戴眼镜; 人脸姿态也有相当程度的变化, 深度旋转与平面旋转可达 20° ; 人脸的尺度也有多达 10% 的变化。图 2 是 ORL 人脸库中某一个人的 5 幅图像。



图 2 ORL 人脸库中的 5 幅图像

(1) 在整个 ORL 人脸库上做试验, 以每人的前 5 幅图像作为训练样本, 后 5 幅作为测试样本, 这样训练样本和测试样本的总数均为 200, 属于典型的高维小样本识别问题。首先求出 S_t, S_w, S_b 的秩分别为 199, 160 和 39, S_t 的非零特征值所对应的 199 个标准正交的特征向量构成变换矩阵 P , 然后求出 $S'_w = P^T S_w P$ 的 199 个标准正交的特征向量, 其中零特征值对应的特征向量共 $c-1 = 39$ 个。选取(15)式中 $\alpha = 2$, 以给出的加权 Fisher 准则为目标函数抽取 31 ~ 44 维的鉴别特征, 变换后的样本分别采用最近邻分类器和最小距离分类器进行分类, 结果见表 1。

表 1 在两种分类器下的错误识别数

维数	最近邻	最小距离	维数	最近邻	最小距离
31	14	14	38	8	8
32	13	13	39	8	8
33	13	13	40	11	14
34	11	11	41	12	13
35	11	11	42	15	17
36	10	10	43	16	18
37	9	9	44	15	17

由表可见, 当投影轴取为 38 或 39 个(样本类别数 $c-1$)时, 所得的投影矢量在两种不同的分类器下, 均达到 96% 的正确识别率。当维数小于 39 时, 随着投影轴个数的增加识别率稳步提高; 当维数超过 39 时, 即增加了第二类的投影方向后, 识别率开始下降同时稳定性降低。可能的原因是, 样本在第二类投影轴上投影后得到的特征分量中含有较多的干扰信息。故一般情况下, 维数取 $c-1$ 较为合适。

在此基础上, 我们进一步比较了本文算法和经典的特征脸、Fisher 脸方法在最近邻分类器下的识别率, 结果见图 3。由图 3 可见, 本文提出的方法在各个维度上均优于经典的特征脸和 Fisher 脸方法。

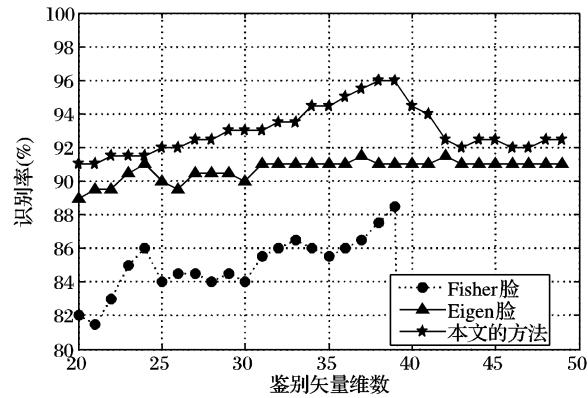


图 3 在最近邻分类器下的识别率

(2) 以每人的前 k 幅图像作为训练样本, 后 $(10-k)$ 幅作为测试样本, k 的取值分别为 2, 3, 4, 5, 采用最小距离分类器进行分类, 正识别率见表 2。表 2 表明, 与经典的特征脸方法、Fisher 脸相比, 无论训练样本数在 2 ~ 5 之间怎样变动, 所提出的加权鉴别法的识别结果都是最好的。

表 2 几种方法在最小距离分类器下的识别率

训练样本数	Eigenfaces	Fisherfaces		本文方法
		识别率	m	
2	84.4%	82.5%	40	86.9%
3	85.4%	87.5%	80	91.4%
4	86.7%	88.7%	120	95.4%
5	90%	88.5%	160	96%

注: m 表示 PCA 阶段所取的主要特征的个数

5 结语

本文引入了一种由类间距离决定的可变权函数, 进而提出一种新的基于加权 Fisher 准则的鉴别分析方法, 并将其用于人脸识别。该方法利用权函数提高了相邻类别间的可分性, 同时借鉴了 Yang 的压缩变换思想, 使得最优鉴别矢量的求解只需在低维的欧氏空间内进行, 并解决了奇异情况下有效抽取最优鉴别特征的问题。在 ORL 人脸库上的试验结果表明, 该方法在普通的分类器(最近邻和最小距离)下的识别率优于经典的特征脸方法、Fisher 脸方法。

(下转第 1049 页)

$$B = -2 * [(0 * m[0]) + (1 * m[1]) + (2 * m[2]) + (3 * m[3]) + \dots + ((k-1) * m[k-1])]$$

在JPEG2000中进入最终压缩编码器的都是正整数,在量化后,如果系数是负数,则要取绝对值,当然符号要通过其他的机制保存。当然,可以先取绝对值,然后再量化。由于量化后的系数都经过了取绝对值,所以A是正数。根据数学知识可知,SUM有最小值,当且仅当 $p = -B/(2 * A)$ 时,SUM取最小值;这里的p必定是个正数。设定p向下取整后为z,

```

zhi 1 = p - z
zhi 2 = z + 1 - p
if (zhi 1 > zhi 2) p = z + 1
else p = z

```

通过以上的计算方法,可以得到一个正整数p,使得SUM最小,即可以使图像经过有损压缩后,保留更多的图像细节。

由于求p值是在图像压缩时进行的,而该值起作用的地方是在解压缩时,因此必须把p值在图像压缩时保留,以便在解压缩时使用。由于JPEG2000的核心算法中,并没有计算 δ 或p的算法,所以JPEG2000中并没有办法传输该值,那么就必须修改JPEG2000的文件格式;在文件中增加一项以便传输该值,文件大小上也只需要增加几个字节。

3 试验结果

对很多图像进行了试验,下面给出其中两幅试验图像ct1.dcm和ct2.dcm的试验结果。

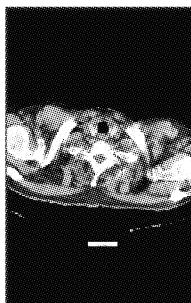


图1 图像ct1

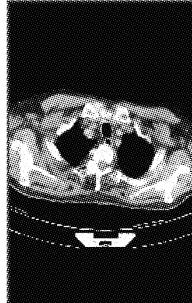


图2 图像ct2

对同一幅图像,如果 Δ 值相等,那么压缩比是相同的;p值为0表示不对反量化进行修正;p值为 $1/2 * \Delta$ 表示典型的反量化修正;另外一个p值是按本文方法计算的;通过大量试验和上面的试验数据可以看出,通过本文计算的p值来反量化修正,在压缩比相同时,能保留更多的图像细节。上面都是对整个图像使用同一种量化系数,在实际中,我们往往对小波分解后的不同子带使用不同的量化系数;同样也可以使用本文的方法计算不同子带的反量化修正值。

(上接第1039页)

参考文献:

- [1] 边肇祺,张学工.模式识别[M].第2版.北京:清华大学出版社,1999.176-177.
- [2] LOOG M, DUIN RPW, HAEB-UMBACH R. Multiclass linear dimension reduction by weighted pairwise Fisher criteria[J]. IEEE Transactions on Pattern Analysis And Machine Intelligence, 2001, 23(7):762-766.
- [3] JIN Z, YANG JY, HU ZS, et al. Face recognition based on uncorrelated discriminant transformation[J]. Pattern Recognition, 2001, 34(7):1405-1416.
- [4] BELHUMEUR V, HESPANHA J, KRIEGMAN D, et al. Eigenfaces vs. Fisherfaces: Recognition using class specific linear projection

4 结语

使用本文介绍的方法,可以求得近似最优的解压缩反量化修正参数;使用此参数,在 Δ 值一定的情况下,即图像的有损压缩比一定时,能够保留更多的图像细节。经过大量的试验证明,该方法能在相同的压缩比下,明显提高其PSNR,并且实现简单,是一种有效,可行的方法。

表1 ct1的试验数据

图像	Δ 值	p值	PSNR
ct1	10	3	52.3098
ct1	10	$1/2 * 10$	51.3176
ct1	10	0	49.4295
ct1	20	3	46.8759
ct1	20	$1/2 * 20$	45.5675
ct1	20	0	44.5466
ct1	100	8	33.5468
ct1	100	$1/2 * 100$	32.5237
ct1	100	0	32.5656

表2 ct2的试验数据

图像	Δ 值	p值	PSNR
ct2	10	4	52.7843
ct2	10	$1/2 * 10$	51.8654
ct2	10	0	49.9845
ct2	20	3	47.4879
ct2	20	$1/2 * 20$	46.1256
ct2	20	0	44.8475
ct2	100	9	34.6542
ct2	100	$1/2 * 100$	33.2648
ct2	100	0	32.9835

参考文献:

- [1] TAUBMAN DS, MARCELLIN MW. JPEG2000图像压缩基础、标准和实践[M].魏江力,译.北京:电子工业出版社,2004.
- [2] LONG M, TAI HM, YANG S. Quantisation step selection schemes in JPEG2000[J]. ELECTRONICS LETTERS, 2002, (6): 547-548.
- [3] 候文生,吴小鹰,彭承琳.一种基于小波变换的医学图像量化编码算法的研究[J].中国生物医学工程学报,2002,19(4),657-659.
- [4] 黄战华,谢洪波,郁道银,等.医学内窥镜图像自适应量化压缩编码方法研究[J].医学信息,2000,19(3):308-312.

[J]. IEEE Transactions on Pattern Analysis And Machine Intelligence, 1997, 19(7):711-720.

- [5] 杨健,杨静宇,叶晖,等.Fisher线性鉴别分析的理论研究及其应用[J].自动化学报,2003,29(4):482-493.
- [6] DUDA R, HART P. Pattern Classification and Scene Analysis[M]. New York: Wiley, 1973. 113-120.
- [7] FUKUNAGA KS. Introduction to Statistical Pattern Recognition [M]. New York: Academic Press, 1990.
- [8] CHEN LF, MARK LIAO HY, KO MT, et al. A new LDA-based face recognition system which can solve the small sample size problem[J]. Pattern Recognition, 2000, 33(10):1713-1726.
- [9] 程云鹏.矩阵论[M].西安:西北工业大学出版社,1989. 294-302.