

# 基于 Fisher 变换的多尺度图像识别方法及其车形识别应用<sup>1</sup>

刘怡光 游志胜 曹丽萍 \* 蒋欣荣

(四川大学东区计算机学院图形图像研究所 成都 610064)

\*(四川大学公共管理学院国情系 成都 610064)

**摘要:** 该文提出了一种图像识别方法。该方法首先对识别图像进行多尺度小波分解，把不同尺度的分解结果组织为分解向量，再对分解向量作 Fisher 变换。在 Fisher 变换域内依据最小绝对距离（或相对距离）识别图像。该方法主要依据小波分解低频分量进行识别运算，对噪声不敏感；同时识别结果已经融合多尺度的识别运算，故目标图像大小对识别结果影响较弱。实践证明，该方法正确识别率高，鲁棒性强。

**关键词:** 图像识别，小波，多尺度，Fisher 变换

**中图分类号:** TP391.4, TN911.73 **文献标识码:** A **文章编号:** 1009-5896(2003)12-1603-09

## A Multiresolution Image Recognition Method Using Fisher Transform and Its Application to Car Type Recognition

Liu Yi-guang You Zhi-sheng Cao Li-ping Jiang Xin-rong

(Institute of Image & Graphics, Sichuan University, Chengdu 610041, China)

**Abstract** This paper introduces a new multiresolution image recognition method. At first, it makes multi-wavelet division over the image, organizes the corresponding components of different resolution into a vector. Then, makes a Fisher transform over the vectors. Recognition is based on the sum of the absolute distance between the vector of the unknown object and the vector of the template or based on the relative distance which is defined as the absolute distance between the vector of the unknown object and that of the template divided by the distance between the vectors of the corresponding templates in the Fisher transformed domain. Because the recognition is mainly dependent on the low frequency component, the method is insensitive noise pixels in the images. Because the recognition procedure has included multiresolution recognizing computation, the right rate of recognition is in sensitive to the dimension size of the image in some degree. The practice of the method proves that the right rate of recognition is very high and the robustness of the method is strong.

**Key words** Image recognition, Wavelet, Multiresolution, Fisher transform

### 1 引言

小波变换在信号分析识别领域得到了广泛应用。C. Scott<sup>[1]</sup> 等在目标原子表示域（小波、Fourier 等正交变换得到）内利用模板匹配法 TEMPLAR (Template Learning from Atomic Representations) 进行图像识别。与本文算法相比，TEMPLAR 算法没有利用小波多尺度分析的优点，也没有利用 Fisher 变换增大类间距离，因此该算法的识别准确性低于本文算法。W. W. Bols 等<sup>[2]</sup> 采用三次样条小波的零交叉代表虹膜的特征并在此基础上进行人的身份识别，由于小波分解到较细尺度时，该表示法受到噪声严重干扰，特征只能采用少数较粗尺度的零交叉表示，因此文献 [2] 的方法识别准确率不高。在小波变换域内计算分形维数，利用分形的相似性

<sup>1</sup> 2002-06-07 收到， 2002-12-04 改回

也可进行信号识别或信号恢复<sup>[3]</sup>，该方法计算量大，识别结果相对需要的计算量而言，性能较低。在小波变换域内，S.C Matthew 等<sup>[4-8]</sup>利用隐马尔科夫模型（HMM），采用信号统计处理的方法对信号进行识别分类。该方法适用性广、扩展性较好、训练样本不需很多就可达到最优性能，但识别准确率不高，要提高识别准确率，HMM 的复杂性和训练样本数都需提高很多。

针对以上文献算法的不足，本文提出了一种在小波变换域内进行图像识别的算法。在小波变化域内，把不同尺度相应的小波分解分量组织为向量，故小波变换将得到一定尺度变换范围的低频向量、两个高频向量、一个超高频向量。对向量进行 Fisher 变换，在 Fisher 变换域内进行目标类型的识别。由于超高频向量、高频向量容易受到噪声干扰，识别运算主要依据低频向量进行，当高频向量对提高识别正确率有益时，也可引入高频向量参与识别运算。

## 2 约定和术语

约定：大写字母  $X, Y$  等为图像的矩阵表示， $X(:, n)$  表示  $X$  的第  $n$  列值不变其余元素值变为零后得到的矩阵， $X(m, :)$  表示  $X$  的第  $m$  行值不变其余元素值变为零后得到的矩阵。小写字母一般表示标量。

车形识别 SR：依据外形对车辆进行识别。如公交大巴，小型面包车、中巴等分属不同外形车辆。在本文中，依据车外形，把车辆分为 6 类：1 类车为吉普车形，包括北京吉普、切诺基、三菱越野等车辆；2 类车为公共汽车形，包括大巴、中巴等；3 类车为轿车形，包括各种轿车；4 类为小型面包车；5 类为卡车；6 类为特殊外形车，包括各种工程用车（如挖掘车）及与前五类车的相似度都小于一定阈值的车。

车形模板向量：用  $T_{mn}^a, T_{mn}^h, T_{mn}^v, T_{mn}^d$  分别表示第  $m$  类外形车尺度为  $n$  的相似分量模板、水平细节模板、垂直细节模板、对角细节模板，则不同尺度下的  $T_{mn}^a, T_{mn}^h, T_{mn}^v, T_{mn}^d$  组成的车形模板向量  $\hat{T}_m^a, \hat{T}_m^h, \hat{T}_m^v, \hat{T}_m^d$  定义为

$$\hat{T}_m^a = [T_{m2^K}^a \ T_{m2^{K-1}}^a \ T_{m2^{K-2}}^a \ T_{m2^{K-3}}^a \ T_{m2^{K-4}}^a \ \dots], \quad m \in [1, 5] \quad (1)$$

$$\hat{T}_m^h = [T_{m2^K}^h \ T_{m2^{K-1}}^h \ T_{m2^{K-2}}^h \ T_{m2^{K-3}}^h \ T_{m2^{K-4}}^h \ \dots], \quad m \in [1, 5] \quad (2)$$

$$\hat{T}_m^v = [T_{m2^K}^v \ T_{m2^{K-1}}^v \ T_{m2^{K-2}}^v \ T_{m2^{K-3}}^v \ T_{m2^{K-4}}^v \ \dots], \quad m \in [1, 5] \quad (3)$$

$$\hat{T}_m^d = [T_{m2^K}^d \ T_{m2^{K-1}}^d \ T_{m2^{K-2}}^d \ T_{m2^{K-3}}^d \ T_{m2^{K-4}}^d \ \dots], \quad m \in [1, 5] \quad (4)$$

## 3 算法分析

小波分解可充分提取样本不同频率的图像特征，如果直接在由这些图像特征量构成的样本多维空间中进行模式识别，则计算量将非常繁重。充分利用 Fisher 变换降维的优点，把多模式多维样本空间转换为多模式低维空间，在多模式低维空间中进行模式识别有以下优点：（1）大大降低计算量；（2）把高维空间模式投影在具有最大区分程度的低维空间中，可减少高维空间中某一（些）维扰动对模式识别正确性的影响，从而提高识别算法的鲁棒性，识别正确率也可适当提高。

### 3.1 预处理

用  $Y$  表示含有车辆目标的图像， $X_z$  表示  $Y$  中含有车辆目标的矩形区域， $G(X_z)$  表示  $X_z$  转变为独立的图像， $Y - X_z$  表示  $Y$  剔除  $X_z$  后的区域组成的欧拉数为 0 的图像， $f(Y)$  表示  $Y$  像素的多少，用  $\text{Normal}(Z)$  表示把图像  $Z$  变为一定大小的正则化过程， $X$  表示预处理后的最终图像，则预处理过程可用式（5）、（6）描述。

具体处理的步骤为：首先拍摄一张无车辆的背景图像，把预处理涉及的图像灰度化后，用有车辆的图像减去背景图像，一般可得到车辆的轮廓图像，边缘提取后就可得到车辆轮廓。光照较弱或较强时，得到的车辆图像轮廓不清晰，可做拒识处理，也可依据先验知识从轮廓清晰

的地方推断不清晰的地方。模糊图像提取的轮廓线一般较粗, 需做边缘细化处理。得到车辆轮廓后, 就可得到  $\mathbf{X}$ 。

$$\mathbf{X}_z \min = \max f(\mathbf{Y} - \mathbf{X}_z), \quad \mathbf{Y} \text{为常量} \quad (5)$$

$$\mathbf{X} = \text{Normal}(G(\mathbf{X}_z \ min)) \quad (6)$$

### 3.2 小波分解

利用 Mallat<sup>[9]</sup> 提出的滤波器组来实现可分离二维离散正交小波变换, 该滤波器组包括的高通滤波器  $G$  和低通滤波器  $H$  分别对应小波函数  $\phi_{k,l}(x)$  和尺度函数  $\psi_{k,j}(x)$ 。通过  $H$  和  $G$  对图像信号的逐级卷积, 得到不同分辨率下的细节分量和相似分量, 从而实现多分辨分析。当离散小波基双正交时,  $H$  和  $G$  满足式 (7)。用  $h(m), h(n)$  分别表示对二维信号逐行和逐列低通滤波, 类似的高通滤波运算定义为  $g(m), g(n)$ 。“\*”表示卷积, 则分辨率为  $2^k$  时的小波分解过程为式 (8)~(11)。

$$\sum_n h(n) = \sqrt{2}, \sum_n g(n) = 0, g(n) = (-1)^n h(1-n) \quad (7)$$

$$\text{相似分量: } \mathbf{X}_{2^K-1} = [\mathbf{X}_{2^K} * h(m)] * h(n) \quad (8)$$

$$\text{水平细节: } \mathbf{Y}_{2^K-1}^1 = [\mathbf{X}_{2^K} * g(m)] * h(n) \quad (9)$$

$$\text{垂直细节: } \mathbf{Y}_{2^K-1}^2 = [\mathbf{X}_{2^K} * h(m)] * g(n) \quad (10)$$

$$\text{对角细节: } \mathbf{Y}_{2^K-1}^3 = [\mathbf{X}_{2^K} * g(m)] * g(n) \quad (11)$$

令  $\hat{\mathbf{X}}, \hat{\mathbf{Y}}^1, \hat{\mathbf{Y}}^2, \hat{\mathbf{Y}}^3$  分别表示小波在不同尺度下分解后的相似分量、水平细节分量、垂直细节分量、对角细节分量组成的向量, 则  $\hat{\mathbf{X}}, \hat{\mathbf{Y}}^1, \hat{\mathbf{Y}}^2, \hat{\mathbf{Y}}^3$  可用式 (12)~(15) 表示。

$$\hat{\mathbf{X}} = [\mathbf{X}_{2^K} \ \mathbf{X}_{2^K-1} \ \mathbf{X}_{2^K-2} \ \mathbf{X}_{2^K-3} \ \mathbf{X}_{2^K-4} \ \cdots] \quad (12)$$

$$\hat{\mathbf{Y}}^1 = [\mathbf{Y}_{2^K}^1 \ \mathbf{Y}_{2^K-1}^1 \ \mathbf{Y}_{2^K-2}^1 \ \mathbf{Y}_{2^K-3}^1 \ \mathbf{Y}_{2^K-4}^1 \ \cdots] \quad (13)$$

$$\hat{\mathbf{Y}}^2 = [\mathbf{Y}_{2^K}^2 \ \mathbf{Y}_{2^K-1}^2 \ \mathbf{Y}_{2^K-2}^2 \ \mathbf{Y}_{2^K-3}^2 \ \mathbf{Y}_{2^K-4}^2 \ \cdots] \quad (14)$$

$$\hat{\mathbf{Y}}^3 = [\mathbf{Y}_{2^K}^3 \ \mathbf{Y}_{2^K-1}^3 \ \mathbf{Y}_{2^K-2}^3 \ \mathbf{Y}_{2^K-3}^3 \ \mathbf{Y}_{2^K-4}^3 \ \cdots] \quad (15)$$

### 3.3 多类型区分的 Fisher 变换矩阵

假设 5 种确定外形车的训练样本集为  $M_p (p \in [1, 5])$ , 五类样本的相似、水平、对角均值向量分别为  $\hat{\mathbf{T}}^a_p, \hat{\mathbf{T}}^h_p, \hat{\mathbf{T}}^v_p, \hat{\mathbf{T}}^d_p$ (等价于图像目标识别时的模板)。由于  $\hat{\mathbf{T}}^h_p, \hat{\mathbf{T}}^v_p, \hat{\mathbf{T}}^d_p$  的 Fisher 变换处理过程与  $\hat{\mathbf{T}}^a_p$  完全类似, 并且在图像目标识别过程中只作为辅助依据, 因此本文只推导相似分量  $\hat{\mathbf{T}}^a_p$  的 Fisher 变换矩阵。则  $\hat{\mathbf{T}}^a_p$ , 样本类内离散度矩阵  $\hat{\mathbf{S}}_p$ ,  $p$  类和  $q$  类外形车的总样本类内离散度矩阵  $\hat{\mathbf{S}}_{W,pq}$ , 总样本类间离散度矩阵  $\hat{\mathbf{S}}_{b,pq}$  分别用式 (16)~(19) 表示。

$$\hat{\mathbf{T}}^a_p = \frac{1}{M_p} \sum_{i=1}^{M_p} \hat{\mathbf{X}}_p, \quad p \in [1, 5] \quad (16)$$

$$\hat{\mathbf{S}}_p = \frac{1}{M_p} \sum_{i=1}^{M_p} (\hat{\mathbf{X}}_p - \hat{\mathbf{T}}^a_p)(\hat{\mathbf{X}}_p - \hat{\mathbf{T}}^a_p)^T, \quad p \in [1, 5] \quad (17)$$

$$\hat{\mathbf{S}}_{W,pq} = \hat{\mathbf{S}}_p + \hat{\mathbf{S}}_q \quad (18)$$

$$\hat{\mathbf{S}}_{b,pq} = (\hat{\mathbf{T}}^a_p - \hat{\mathbf{T}}^a_q)(\hat{\mathbf{T}}^a_p - \hat{\mathbf{T}}^a_q)^T \quad (19)$$

则区分  $p, q$  两类外形车的最佳 Fisher 变换向量  $w_{pq}$  满足式 (20)，在式 (20) 中对  $J_F(w_{pq})$  求极大值解出  $w_{pq}$  并按式 (21) 正则化为  $w_{pq}^*$ 。

$$J_F(w_{pq}) = \frac{w_{pq}^T \cdot S_{b,pq} \cdot w_{pq}}{w_{pq}^T \cdot S_{w,pq} \cdot w_{pq}} \quad (20)$$

$$w_{pq}^* = w_{pq} / |w_{pq}| \quad (21)$$

显然  $p = q$  时， $w_{pq}^*$  是不存在的，用  $w_{pq}^* = \bar{\exists}$  表示； $w_{pq}^*$  对指标  $pq$  是对称的，即  $w_{pq}^* = w_{qp}^*$ 。各类外形车之间的 Fisher 变换向量  $w_{pq}^*$  组成的矩阵  $W$  用式 (22) 表述，显然  $W$  是对称阵。

$$W = \begin{bmatrix} \bar{\exists} & w_{12}^* & w_{13}^* & w_{14}^* & w_{15}^* \\ w_{21}^* & \bar{\exists} & w_{23}^* & w_{24}^* & w_{25}^* \\ w_{31}^* & w_{32}^* & \bar{\exists} & w_{34}^* & w_{35}^* \\ w_{41}^* & w_{42}^* & w_{43}^* & \bar{\exists} & w_{45}^* \\ w_{51}^* & w_{52}^* & w_{53}^* & w_{54}^* & \bar{\exists} \end{bmatrix} \quad (22)$$

### 3.4 Fisher 变换域下的类间距离矩阵 $D$

据式 (19) 在  $p = q$  时  $S_{b,pq} = 0$ ，因此 Fisher 变换前的类间距离矩阵  $D_0$  可用式 (23) 表述：

$$D_0 = \begin{bmatrix} 0 & S_{b,12} & S_{b,13} & S_{b,14} & S_{b,15} \\ S_{b,21} & 0 & S_{b,23} & S_{b,24} & S_{b,25} \\ S_{b,31} & S_{b,32} & 0 & S_{b,34} & S_{b,35} \\ S_{b,41} & S_{b,42} & S_{b,43} & 0 & S_{b,45} \\ S_{b,51} & S_{b,52} & S_{b,53} & S_{b,54} & 0 \end{bmatrix} \quad (23)$$

在 Fisher 变换矩阵  $W$  作用下，类间距离  $D$  为式 (24)。

$$D = \sum_{i=1}^5 W(i,:) \cdot \text{diag}(D_0(i,:)) \cdot \text{diag}(W(i,:)) \quad (24)$$

### 3.5 图像目标识别

含有车辆目标的图像经预处理后得到  $X_u$ ，小波分解及向量构造后得到向量  $\hat{X}_u, \hat{Y}^1_u, \hat{Y}^2_u, \hat{Y}^3_u$ 。 $\hat{Y}^1_u, \hat{Y}^2_u, \hat{Y}^3_u$  是高频分量，反映图像细节，易受噪声干扰。用权值  $\rho_x, \rho_{y1}, \rho_{y2}, \rho_{y3}$  分别表示识别过程对各向量的依赖程度。

权值的具体分配可由识别结果的正确率反馈得到。一般首先令  $\rho_x$  为 1，得到检验样本的识别正确率，再适当减小  $\rho_x$ ，增大  $\rho_{y1}$ ，再次得到检验样本的识别正确率；如果识别正确率提高，则再次减小  $\rho_x$ ，减小  $\rho_{y1}$ ，增大  $\rho_{y2}$ ，计算检验样本的识别正确率，直到识别正确率不再提高为止；得到的一组  $\rho_x, \rho_{y1}, \rho_{y2}, \rho_{y3}$  为所需权值分配。当然追求识别正确率的同时，也应考虑计算量。

$$\rho_x + \rho_{y1} + \rho_{y2} + \rho_{y3} = 1, \quad \rho_x, \rho_{y1}, \rho_{y2}, \rho_{y3} \in [0, 1] \quad (25)$$

依据式 (23)， $\hat{X}_u$  与各类外型车模板  $\hat{T}^a_p$  之间的类间距离矩阵  $D_{0u}$  为式 (26)。

$$D_{0u} = \begin{bmatrix} 0 & S_{b,u2} & S_{b,u3} & S_{b,u4} & S_{b,u5} \\ S_{b,u1} & 0 & S_{b,u3} & S_{b,u4} & S_{b,u5} \\ S_{b,u1} & S_{b,u2} & 0 & S_{b,u4} & S_{b,u5} \\ S_{b,u1} & S_{b,u2} & S_{b,u3} & 0 & S_{b,u5} \\ S_{b,u1} & S_{b,u2} & S_{b,u3} & S_{b,u4} & 0 \end{bmatrix} \quad (26)$$

依据式(24)得到  $\hat{\mathbf{X}}_u$  与各模板向量  $\hat{\mathbf{T}}^a_p$  之间在 Fisher 变换矩阵  $\mathbf{W}$  作用下的类间距矩阵  $\mathbf{D}_u$  为

$$\mathbf{D}_u = \sum_{i=1}^5 \mathbf{W}(i,:) \cdot \text{diag}(\mathbf{D}_{0u}(i,:)) \cdot \text{diag}(\mathbf{W}(i,:)) \quad (27)$$

由式(24), (27) 得到判定矩阵  $\mathbf{D}_d$ ,  $\mathbf{D}_d$  的主对角线元素值令为 0.  $\mathbf{D}_d$  的每列中非零最小模元素组成判定矩阵  $\hat{\mathbf{D}}$ . 依据式(29) 进行的判定过程如式(30).

$$\mathbf{D}_d = [d_{u,ij}/d_{ij}], \quad (i \neq j, \quad i, j \in [1, 5]) \quad (28)$$

$$\hat{\mathbf{D}} = [\min d_{d,i1} \ \min d_{d,i2} \ \min d_{d,i3} \ \min d_{d,i4} \ \min d_{d,i5}], \quad i \in [1, 5] \quad (29)$$

利用先验知识确定阀值  $\tau$ .  $\tau$  的确定原则为, 模式误识率尽量低, 同时也不能把人眼能显著识别的 5 种类型车之一的预处理图像  $\mathbf{X}$  总认为第 6 种外形车. 具体确定办法为, 首先取  $\tau$  为较小的值, 此时模式误识率会较高, 认为是第 6 种外形车的识别结果较少. 逐渐提高  $\tau$  值, 当模式误识率较低, 认出是第 6 种外形车的识别结果正确或人眼都不能显著区分预处理图像  $\mathbf{X}$  的车型时, 此时的  $\tau$  值可认为是较好的.

$$\left. \begin{array}{l} \text{if } \hat{d}_i > \tau, \quad (i \in [1, 5], \hat{d}_i \in \hat{\mathbf{D}}) \\ \text{then 图像目标属于第 6 种外形车} \\ \text{else if } \hat{d}_m = \min \hat{d}_i, \quad (i, m \in [1, 5]) \\ \text{then 图像目标属于第 } m \text{ 种外形车} \end{array} \right\} \quad (30)$$

### 3.6 鲁棒性讨论

式(5), (6) 描述的预处理过程是图像目标识别的基础, 提取  $\mathbf{X}$  的准确性将直接影响算法输出结果的正确性. 由先验知识确定的  $\tau$  对算法输出结果正确性也有重要影响. 如  $\tau$  过小, 将会把大量车误认为特殊类型的车, 识别正确性降低. 预处理过程和  $\tau$  出现异常, 本算法将会失稳. 因此, 不同条件下, 预处理过程具有不同的处理方法,  $\tau$  具有不同大小.

如图 1, 已知三类样本模板  $\mathbf{T}_1, \mathbf{T}_2, \mathbf{T}_3$  及模板间的 Fisher 变换向量  $w_{12}, w_{32}, w_{31}, DT_{mn,pq}$  表示未知样本与样本模板  $T_m, T_n$  在  $w_{pq}$  方向投影后的距离,  $\mathbf{T}_u$  为未知样本. 式(30) 采用式(28) 表示的相对距离  $DT_{mn,pq}/DT_{pq,pq}$ , 既消除了不同 Fisher 变换域对距离的影响, 也充分考虑了不同类别样本模板间固有距离对识别结果的影响. 如果直接用不同变换域下未知样本与样本模板间最小距离之和  $\bar{\lambda}$  进行识别, 则忽略了样本模板间固有距离对识别结果的影响. 式(30) 充分考虑了样本间的先验距离, 识别正确率较高, 但其计算量比计算  $\bar{\lambda}$  略大. 利用  $\bar{\lambda}$  和式(30) 进行识别的性能差别在实践中也得到证实. 两种方法都是稳定的, 在  $\tau$  等参数确定合适时, 不会出现失稳现象.

## 4 实验步骤及结果

### 4.1 实验环境描述

实验环境如图 2 所示, 摄象机镜头垂直于车辆行驶方向, 由埋地地感线圈触发摄象机进行拍摄 (此方式可保证车辆目标在图像中的相对位置固定), 每次拍摄一张  $768 \times 576$  图片.

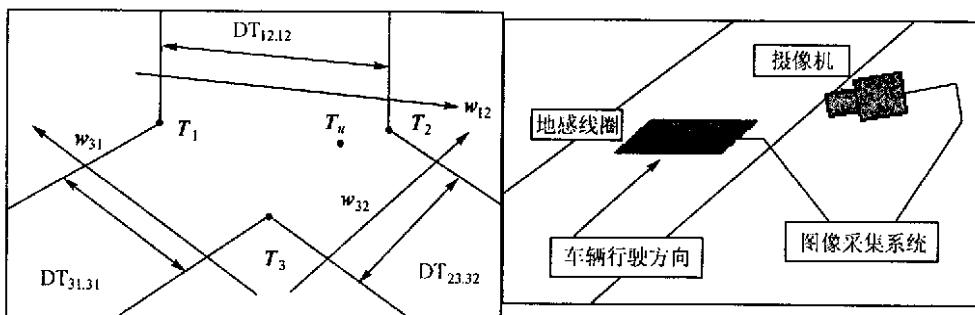


图 1 多类别 Fisher 变换域

图 2 实验环境示意图

#### 4.2 预处理

图像经过抽帧、边缘提取等处理后得到只包含车辆轮廓线信息的二值图，对 5 类外形车，每类采集 50 张图片作为样本。样本轮廓提取图像及预处理结果如图 3 所示。

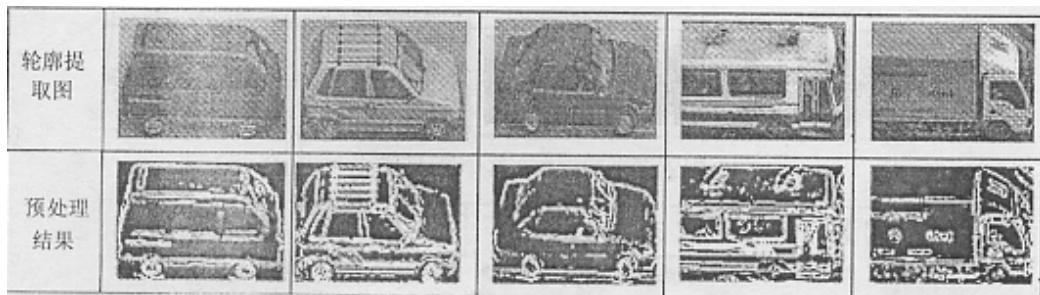


图 3 样本及预处理结果

#### 4.3 训练样本预处理结果及其小波变换、模板向量构造

对 5 类外形车的训练样本预处理结果按式 (16) 得到各外形车模板 (图 4)。采用 Daubechies 四阶小波，在 VC6.0 环境中编程实现各模板的四级小波分解，得到不同尺度分量 (显示尺寸相同，图像加亮显示，以后显示图像时进行类似处理)，按照式 (12)~(15) 构成识别向量 (图 5~图 9)。



图 4 各外形车样本预处理后的模板

向量	预处理	分量一	分量二	分量三	分量四
$\hat{X}$					
$\hat{Y}^1$					
$\hat{Y}^2$					
$\hat{Y}^3$					

图 5 小型面包车车形样本小波分解及向量构成

向量	预处理	分量一	分量二	分量三	分量四
$\hat{X}$					
$\hat{Y}^1$					
$\hat{Y}^2$					
$\hat{Y}^3$					

图 6 轿车形样本小波分解及向量构成

#### 4.4 识别权值分配、Fisher 变换和目标识别

从 4.3 节看出: 对各类外形车而言,  $\hat{X}$  的分量四比较难区分;  $\hat{Y}^1$  的分量三分量四差别较弱;  $\hat{Y}^2$  和  $\hat{Y}^3$  比较接近。向量  $\hat{X}$  去除分量四得到向量  $\bar{\hat{X}}$ ,  $\hat{Y}^1$  除去分量三分量四得到向量  $\bar{\hat{Y}}^1$ , 用  $\bar{\hat{X}}$  和  $\bar{\hat{Y}}^1$  进行车形识别。由于只有向量  $\bar{\hat{X}}$  和  $\bar{\hat{Y}}^1$  参与识别运算, 所以  $\rho_{y2} = 0$ ,  $\rho_{y3} = 0$ ,  $\rho_x$ ,  $\rho_{y1}$  取值由识别效果反馈及约束式(25)决定, 本实验中分别取 0.4, 0.6。

得到模板向量  $\bar{\hat{X}}$ ,  $\bar{\hat{Y}}^1$  后, 依据式(16)~(20)进行 Fisher 变换, 用式(30)识别目标。在同一实验环境下, 对各类型车得到 200 个清晰检验样本, 识别结果均正确。但采集检验样本环境如果与采集模板样本的环境改变较大, 如光照过强、过弱, 则发现输出识别正确率下降, 分析表明预处理提取  $X$  不准是主要原因。

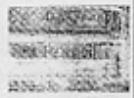
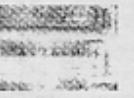
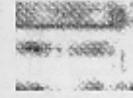
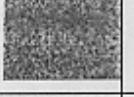
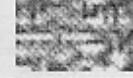
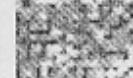
向量	预处理	分量一	分量二	分量三	分量四
$\hat{X}$					
$\hat{Y}^1$					
$\hat{Y}^2$					
$\hat{Y}^3$					

图 7 吉普车形样本小波分解及向量构成

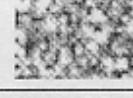
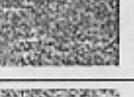
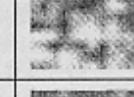
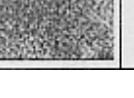
向量	预处理	分量一	分量二	分量三	分量四
$\hat{X}$					
$\hat{Y}^1$					
$\hat{Y}^2$					
$\hat{Y}^3$					

图 8 公共汽车形样本小波分解及向量构成

## 5 结 论

把图像进行小波多尺度分解的对应分量组成样本向量，再对样本向量进行 Fisher 变换，在 Fisher 变换域内提出了相对距离和最小距离的识别方法。在方法实现过程中，本文得到了区分多类别样本的 Fisher 变换矩阵。该矩阵能使得多类样本中的任意两类样本在矩阵内相应元素的投影方向上得到最好程度的区分。由于对各向量在识别过程中的作用引进权系数进行控制，该方法既考虑了样本间的整体差别，也考虑了样本间的细节差别，因此该方法适应性广；由于样本向量是由不同尺度的分量组成，因此预处理之后的正则化图像大小对识别结果正确性影响不明显。实践证明，在预处理结果良好时，本方法能最大程度地正确认别车形，是一种鲁棒性强的方法。

向量	预处理	分量一	分量二	分量三	分量四
$\hat{X}$					
$\hat{Y}^1$					
$\hat{Y}^2$					
$\hat{Y}^3$					

图 9 卡车形样本小波分解及向量构成

## 参 考 文 献

- [1] Scott C, Nowak R. Template learning from atomic representations: A wavelet-based approach to pattern analysis. Proc. IEEE Workshop on Statistical and Computational Theories of Vision, (published on the web), Vancouver, BC, July 2001.
- [2] Boles W W, Boashash B. A human identification technique using images of the iris and wavelet transform. *IEEE Trans. on Signal Processing*, 1998, 46(4): 1185–1188.
- [3] Chen B S, Lin C W. Multiscale Wiener filter for the restoration of fractal signals: Wavelet filter bank approach. *IEEE Trans. on Signal Processing*, 1994, 42(11): 2972–2982.
- [4] Choi H, Baraniuk R G. Image segmentation using wavelet-domain classification, Proc. SPIE Technical Conference on Mathematical Modeling, Bayesian Estimation, and Inverse Problems, Denver, July 1999: 306–320.
- [5] Matthew S C, Robert D N, Richard G B. Wavelet-based statistical signal processing using hidden Markov models. *IEEE Trans. on Signal Processing*, 1998, 46(4): 886–902.
- [6] Romberg J K, Choi H, Baraniuk R G. Bayesian tree-structured image modeling using wavelet-domain hidden Markov models, Proc. SPIE Technical Conference on Mathematical Modeling, Bayesian Estimation, and Inverse Problems, Denver, July 1999: 31–44.
- [7] Crouse M S, Baraniuk R G. Contextual hidden Markov models for wavelet-domain signal processing. in Proc. 31st Asilomar Conf. on Signals, Systems and Computers, Pacific Grove, Nov. 1997. <http://www.dsp.ece.rice.edu/publications/pub/wcontext.ps.gz>
- [8] Romberg J K, Choi H, Baraniuk R G. Bayesian wavelet domain image modeling using hidden Markov trees. in Proc. IEEE International Conference on Image Processing-ICIP'99, Kobe, Japan, October 1999: 1–5.
- [9] Mallat S G. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Trans on PAMI*, 1989, 11(6): 674–693.

刘怡光: 男, 1972 年生, 博士生, 研究兴趣: 图像处理、神经网络、计算方法、ITS。

游志胜: 男, 教授, 博士生导师, 图像图形研究所所长, 中国图像图形学会副理事长, 主要研究领域: 数据融合、图像处理与模式识别、神经网络、ITS 等。

曹丽萍: 女, 1976 年生, 硕士生, 研究兴趣: 信息检索技术。

蒋欣荣: 男, 1972 年生, 讲师, 研究兴趣: 图像处理、模式识别。