

文章编号:1001-9014(2011)01-0085-06

基于多尺度几何分析的目标描述和识别

潘泓, 李晓兵, 金立左, 夏良正
(东南大学 自动化学院, 江苏 南京 210096)

摘要:结合多尺度几何分析和局部二值模式算子,构造了一种新的多尺度、多方向局部特征描述子——局部 Contourlet 二值模式(LCBP). 通过对尺度内、尺度间及同一尺度不同方向子带内 LCBP 直方图统计分析,同时考虑到 LCBP 的四叉树结构特点和模型的简单性,用两状态 HMT 描述 LCBP 系数,得到 LCBP-HMT 模型. 在此基础上,提出了基于 LCBP-HMT 模型的目标识别算法,该算法提取 LCBP-HMT 模型参数作为特征,通过比较输入目标特征和各类标准目标特征的 Kullback-Leibler 距离进行分类. 实验结果表明,LCBP 特征比传统小波域特征和 Contourlet 域高斯分布模型特征更具鉴别能力.

关 键 词:多尺度几何分析;轮廓波变换;局部二值模式;目标识别

中图分类号:TP391 **文献标识码:**A

Object description and recognition using multiscale geometric analysis

PAN Hong, LI Xiao-Bing, JIN Li-Zuo, XIA Liang-Zheng
(School of Automation, Southeast University, Nanjing 210096, China)

Abstract: A novel local feature descriptor, called Local Contourlet Binary Pattern (LCBP), was developed in this paper. LCBP provides a multiscale and multidirectional representation for images since it integrates multiscale geometric analysis and local binary pattern operators. With the quadtree structure of LCBP and simplicity of the model itself, the LCBP coefficients were modeled by a two-state HMT that is in accordance with the intra-band, inter-band and inter-directional distributions of LCBP coefficients. Based on the LCBP-HMT model, an object classification method was further proposed to extract parameters of the LCBP-HMT model as features and classify the query samples by comparing the Kullback-Liebler distance between features of the query samples and that of the prototype objects. Experimental results illustrate the superiority of the LCBP over traditional wavelet features and Gaussian density function model features of contourlet coefficients in terms of the discrimination performance.

Key words: multiscale geometric analysis; contourlet transform; local binary pattern; object classification

PACS: 07.05. PJ

引言

由一维小波基通过张量积生成的二维可分离小波基是各向同性的,只具有有限的方向选择性,在表示二维或高维信号的奇异结构处(如图像边缘和轮廓)会产生大量小波系数,导致高维信号的非稀疏表示. 针对传统小波在高维空间中分析能力不足的缺点,人们相继提出了 Curvelet、Contourlet、Bandelet 和 Directionlet 等一系列多尺度几何分析(Multiscale

Geometric Analysis-MGA)方法. 这些 MGA 变换的共同特点在于: 基函数的支撑区间具有各向异性和多种方向选择性, 在描述高维信号时, 能以更少的系数、更优的逼近阶数逼近信号奇异处. MGA 优越的非线性逼近特性, 使其越来越多地被应用在特征提取、纹理分类^[1]、生物特征识别^[2] 和图像检索^[3] 等领域. 目前, MGA 理论体系刚建立, 在特征提取、目标识别等方面的应用还处于起步阶段, 仍有许多地方有待进一步研究.

收稿日期:2010-01-30,修回日期:2010-12-02

基金项目:国家自然科学基金(90820009, 60805002); 航空科学基金(20080169003); 东南大学优秀青年教师教学科研资助计划(4008001015); 国家留学基金委资助计划

作者简介:潘泓(1974-),男,江苏无锡人,副教授,博士,研究领域为模式识别,机器学习,计算机视觉,多媒体信号处理. E-mail: enhpan@seu.edu.cn.

Received date: 2010-01-30, revised date: 2010-12-02

本文结合多尺度几何分析和局部二值模式 (Local Binary Pattern-LBP) 算子, 构造了一种新的多尺度局部方向特征描述子-局部 Contourlet 二值模式 (Local Contourlet Binary Pattern-LCBP). 通过对尺度内、尺度间及同一尺度不同方向子带 LCBP 直方图的分析, 研究了 LCBP 特征的边缘和条件统计模型. 在此基础上, 用隐马尔可夫树模型对 LCBP 系数建模, 并提出了基于隐马尔可夫树模型的 LCBP 目标识别算法, 取得了较传统小波变换特征和 Contourlet 域高斯分布模型特征更好的识别结果.

1 Contourlet 变换

Contourlet 变换^[4,5]是一种多尺度、多方向的二维图像表示方法, 与其它 MGA 方法相比, Contourlet 变换在不同尺度上的方向分解数目灵活可调, 可以用较精细的角度分辨率捕获图像的方向信息. Contourlet 变换将多尺度分析和方向分析分开进行: ①通过拉普拉斯金字塔 (Laplacian Pyramid-LP) 进行多尺度分解, 捕获图像中的点奇异性. 一次 LP 分解将原始图像分解为低频分量和高频分量, 低频分量由原始图像通过二维低通滤波和隔行隔列二采样得到, 高频分量由原始图像和低频分量的差分得到. ②使用方向滤波器组 (Directional Filter Bank-DFB) 对高频分量进行方向变换. DFB 将同方向上的奇异点连接成线性结构, 并合并为一个 Contourlet 变换系数, 从而捕获图像中的轮廓. 若 DFB 的个数为 1, DFB 将频域分解成 2^l 个楔型方向子带.

2 局部二值模式 (LBP)

LBP^[6,7]是 Ojala 等人提出的一种纹理描述算子, 反映了纹理的空间结构关系. 原始 LBP 算子定义在像素的 3×3 邻域中, 以中心像素灰度值 g_c 为阈值, 对每个邻域点灰度值 g_p ($p = 0, 1, \dots, 7$) 与中心像素灰度值 g_c 作式(1)所示的二值化运算 $S(g_p - g_c)$, 得到一组顺时针排列的二值数字, 即为中心像素点 LBP 算子的二进制表示, 将这组二值数字分别赋予不同的权系数 2^p 可得该中心像素点的 LBP 值.

$$S(g_p - g_c) = \begin{cases} 1, & g_p \geq g_c \\ 0, & g_p < g_c \end{cases}, \quad (1)$$

$$LBP = \sum_{p=0}^7 2^p \times S(g_p - g_c), \quad (2)$$

由定义可见, 灰度值的单调变化不改变相邻像素灰度的相对大小, 也不会引起 LBP 值的变化. 在此基础上, Ojala 通过圆形采样和双线性插值, 将 LBP 算

子推广到任意大小的邻域中得到 $LBP_{P,R}$, 其中 P, R 分别表示邻域内包含采样点的个数和圆形邻域半径.

对一个像素点而言, 图像旋转导致其 LBP 值的改变 (对应 LBP 二进制串的循环移位). 在不同旋转角度下取到的所有 LBP 值中, 最小 LBP 值是固定的, 不随角度变化而变化, 即具有旋转不变性, 将该 LBP 值称为旋转不变性 LBP, 记作 $LBP_{P,R}^r$. 此外, 对实际图像的 LBP 表示中, 有些 LBP 值出现频率很低, 而另一些 LBP 值则包含了图像中大部分纹理模式, 出现的频率超过 90% 以上, 如二进制表示中 0, 1 间转变次数不超过两次的 LBP 值, Maenpaa 等人将这类模式称为均匀模式, 记作 $LBP_{P,R}^{ru2}$. 对均匀模式 $LBP_{P,R}^{ru2}$, 将其旋转到最小值, 可得具有旋转不变性的均匀模式 $LBP_{P,R}^{rin2}$.

3 局部 Contourlet 二值模式描述子 (LCBP)

结合 Contourlet 变换的多尺度、多方向分析性能和 LBP 算子的局部纹理抽取能力, 我们构造了一种 Contourlet 域的局部特征描述子-局部 Contourlet 二值模式 (LCBP). LCBP 不仅提供了图像多尺度、多方向的局部纹理描述, 同时对图像灰度值单调变化和旋转具有不变性. LCBP 计算步骤如下:

1. 对图像 $I(x,y)$ 作多尺度、多方向的 Contourlet 分解, 得到变换域图像 $I'(x,y)$.
2. 对 $I'(x,y)$ 各方向子带和低频子带中每个像素点 $C_{band}(x,y)$ (其中 $band$ 为该像素点所在子带, (x,y) 为像素点在子带中坐标), 令 $sgn = \text{sign}[C_{band}(x,y)]$ ($\text{sign}[\cdot]$ 表示取符号), 对每个像素点取幅值 $mag[C_{band}(x,y)] = |C_{band}(x,y)|$. 对 $mag[C_{band}(x,y)] \geq Threshold$ 的点 (x,y) , 根据其 8 邻域像素点的幅值计算均匀旋转不变性 LBP 算子 $LBP_{8,1}^{rin2}[mag_{band}(x,y)]$, 对 $mag[C_{band}(x,y)] < Threshold$ 的点 (x,y) , 令 $LBP_{8,1}^{rin2}[mag_{band}(x,y)] = mag_{band}(x,y)$. 经过对各种不同属性图像的 Contourlet 系数研究发现:i). 对最低频子带, 阈值 Threshold 取子带系数最大幅值的 40%; ii). 对其它各子带, 阈值取子带系数最大幅值的 10%, 能较好提取目标局部特征, 又能保证 LCBP 特征的稀疏性. 对每个子带像素, 计算 $LBP_{8,1}^{rin2} = sgn \times LBP_{8,1}^{rin2}[mag_{band}(x,y)]$, 得到 $LBP_{8,1}^{rin2}$.
3. 将各子带所有系数的 $LBP_{8,1}^{rin2}$ 算子组合起来, 得到 $I(x,y)$ 的 LCBP 特征.

图 1 给出了对 ‘Barbara’ 图像 (见图 3(b)) 进行 Contourlet 变换后 (3 个尺度级, 各尺度级方向分解数分别为 16, 8, 4) 提取得到的 LCBP 图像.

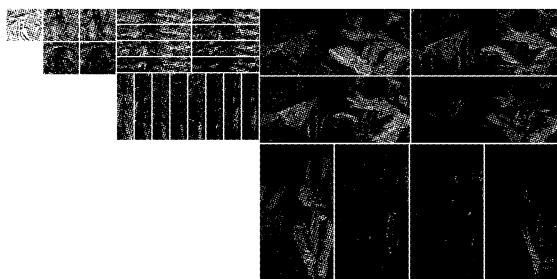


图 1 Barbara 图像的 LCBP 特征描述

Fig. 1 The LCBP representation of ‘Barbara’ image

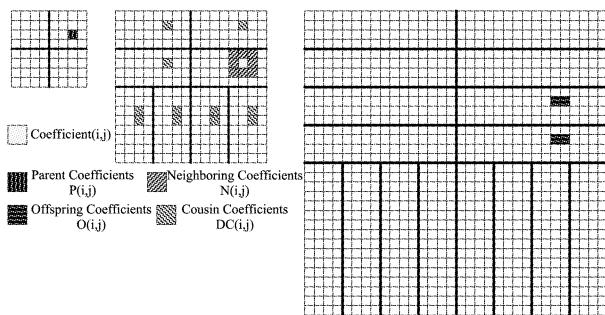


图 2 LCBP 系数间相关性关系

Fig. 2 Correlation of LCBP coefficients

3.1 LCBP 特征的统计特性

Vo 和 Po 等人的工作表明^[3,5],对图像建立合理的模型,有助于准确描述图像,模型参数不仅刻画了图像的本质特征,也能有效降低特征维数。通过对 LCBP 特征建立统计模型,并比较不同目标 LCBP 统计模型参数能快速有效地识别目标。为了建立 LCBP 特征的统计模型,需要研究不同子带间 LCBP 系数的联系。

如图 2 所示,对每个 LCBP 系数,将同一子带中 8 个相邻系数称为邻系数(neighboring coefficients),将上一层同一位置处的系数称为父系数(parent coefficients),将相邻下一层同一位置处的系数称为子系数(children coefficients),所有小尺度级中相同位置处的系数称为后代系数(offspring coefficients),将相同尺度级、不同方向子带中相同位置处的系数称为兄弟系数(cousin coefficients)。邻系数 $N(i, j)$ 、父系数 $P(i, j)$ 、子系数(后代系数) $O(i, j)$ 关系体现了 LCBP 系数尺度内和尺度间的关联,而兄弟系数 $DC(i, j)$ 关系则描述了不同方向间的联系。将邻系数、父系数和兄弟系数组成的集合 $GN(i, j) = \{N(i, j), P(i, j), DC(i, j)\}$ 称作 $LCBP(i, j)$ 的广义邻域集合,这些系数决定了 LCBP 特征的统计模型。

3.1.1 LCBP 特征的边缘分布

用各子带 LCBP 系数直方图近似拟合其边缘分

布,实验发现除了低频子带之外,各尺度下不同方向子带系数具有相似的边缘分布。以最精细尺度下子带系数为例,给出了不同性质图像的 LCBP 特征在最精细尺度下(第 3 个尺度级)第 16 个方向子带的直方图(见图 3)。其中,‘Lena’属于平滑区域为主的图像,而‘Barbara’和‘Mandrill’分别属于边缘为主和纹理为主的图像。由图可见,对各种性质的图像,LCBP 系数集中分布在 0 附近,两端有较长的“拖尾”,具有典型的非高斯分布特性。按式(3)分别计算这些图像 LCBP 最高分辨率下各个子带系数的峰度(kurtosis),与均值、方差一样,峰度是反映系数分布的重要统计参数。对各种不同性质图像,这些峰度值分布在 16.05 ~ 29.13 之间,和高斯分布峰度相差较大(高斯分布峰度为 3)。

$$kurtosis = \frac{\sum_{i=1}^N (X_i - \bar{X})^4}{(N - 1)\sigma^4}, \quad (3)$$

式中, X_i 和 \bar{X} 分别表示子带 LCBP 系数和均值, N 为子带系数个数, σ 为子带系数方差。

3.1.2 LCBP 特征的条件分布

通过计算‘Lena’、‘Barbara’和‘Mandrill’的 LCBP 系数 X 相对于父系数、左邻域系数、上邻域系数和兄弟系数的条件分布 $P(X|.)$,我们发现这些条件分布形状相似:当条件概率较小时,系数方差也较小;条件概率较大时,系数方差也较大。这表明:1) LCBP 系数非独立,但其条件分布的数学期望近似为 0,即 $E[X|.] \approx 0$,消除了 LCBP 系数的相关性;2) LCBP 系数分布随其广义邻域系数变化而改变,LCBP 系数间相互依赖。因此,LCBP 系数具有不相关但非独立的统计特性。我们还进一步研究了 LCBP 系数随其广义邻域集合中单个系数变化时的条件直方图分布。实验发现,这些条件直方图分布和高斯分布非常相近,其峰态度值分布在 3.0 附近。这说明 LCBP 系数的条件分布近似符合高斯分布。

结合边缘分布特性,我们认为 LCBP 系数具有以下统计性质:(1)边缘分布具有非高斯分布特性;(2)条件分布满足高斯分布;(3)系数方差和广义邻域系数幅值成正比。因此,理论上可用高斯混合模型来准确描述 LCBP 统计特性,但高斯混合模型较为复杂,参数需通过 EM 算法迭代求得,计算量巨大。考虑到相邻尺度间 LCBP 系数满足四叉树结构,一种简化而有效的方法就是用隐马尔可夫树模型(Hidden Markov Tree-HMT)近似代替高斯混合模型描述 LCBP 统计特性。

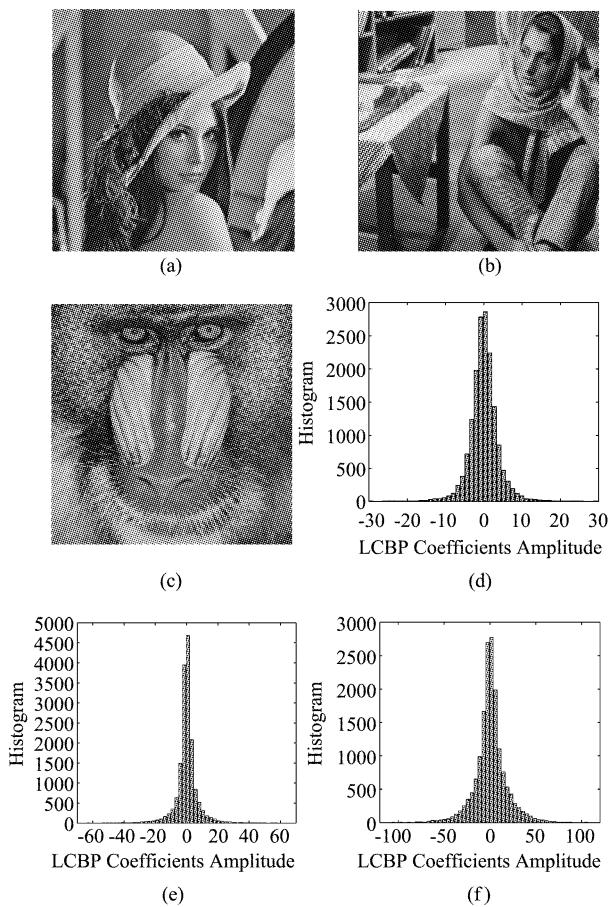


图3 不同性质图像 LCBP 系数在第3个尺度级, 第16个方向子带的直方图 (a) ‘Lena’ (b) ‘Barbara’ (c) ‘Mandrill’ (d) ‘Lena’ 图像 LCBP 子带系数直方图 (e) ‘Barbara’ 图像 LCBP 子带系数直方图 (f) ‘Mandrill’ 图像 LCBP 子带系数直方图

Fig. 3 Histograms of LCBP coefficients at scale 3, band 16 for images with various characteristics (a) ‘Lena’ (b) ‘Barbara’ (c) ‘Mandrill’ (d) histogram of LCBP coefficients for ‘Lena’ (e) histogram of LCBP coefficients for ‘Barbara’ (f) histogram of LCBP coefficients for ‘Mandrill’

3.2 基于 HMT 的 LCBP 描述

每个 LCBP 系数的非高斯边缘分布可看作由一个具有尖峰值的小方差高斯分布和另一个具有长拖尾的大方差高斯分布混合而成, 为减少模型参数、降低模型复杂度, 我们使用两状态 HMT 模型描述 LCBP 系数的统计特性, 即

$$P(X) = \sum_{m=1}^2 p_S(m) P(X|S=m), \quad \sum_{m=1}^2 p_S(m) = 1, \quad (4)$$

其中, $P(X)$ 表示 LCBP 系数 X 的边缘分布, S 表示节点的隐状态变量, $S=1$ 和 $S=2$ 分别对应节点系数 X 的两种状态: “大”和“小”, 对应图像中边缘部分和平滑区域. $p_S(m)$ 表示系数 X 的隐状态变量 S 取 m 的概率. $P(X|S=m)$ 为系数 X 状态变量 S 确定

时 X 的条件分布.

对 LCBP 图像, 最高尺度级各个方向子带中的系数组成了 LCBP-HMT 模型的根节点, 每个根节点和各个低尺度级下、同一方向子带中相应位置处的后代节点构成一个 HMT 模型. HMT 模型中不同节点通过式(5)所示的状态转移概率矩阵 $A_{j,k}$ 联系起来.

$$A_{j,k} = \begin{pmatrix} a_{j,k}^{11} & a_{j,k}^{12} \\ a_{j,k}^{21} & a_{j,k}^{22} \end{pmatrix}, \quad (5)$$

其中, j, k 分别表示第 j 个尺度级第 k 个子带, 矩阵中元素 $a_{j,k}^{mn}$ 表示第 $(j+1)$ 个尺度级中状态为 n 的父节点转移到第 j 个尺度级中状态为 m 的子节点的概率. 将 $A_{j,k}$ 表示成矢量形式 $A_{j,k} = \vec{p}_{j,k} = [p_{j,k}^1 \quad p_{j,k}^2]$, 则 $A_{j,k}$ 可分解为 $A_{j,k} = \vec{p}_{j,k} A_{J-1,k} A_{J-2,k} \cdots A_{j,k}$ ($\forall j = 1, 2, \dots, J$), 其中 $\vec{p}_{J,k} = [p_{J,k}^1 \quad p_{J,k}^2]$ 表示最高尺度级下根节点的状态概率矢量.

对每个根节点, HMT 模型包含如下参数: (1) $p_{J,k}$ ($k = 1, 2, \dots, d_J$): 最高尺度级各方向子带中根节点状态概率矢量; (2) $A_{j,k}$ ($j = J-1, J-2, \dots, j; k = 1, 2, \dots, d_j$): 第 $(j+1)$ 尺度级中父节点到第 j 级尺度、第 k 个方向子带中子节点的状态转移概率矩阵; (3) $\sigma_{j,k}$ ($j = J, J-1, \dots, 1; k = 1, 2, \dots, d_j$): 第 j 个尺度、第 k 个方向子带中高斯分布标准差组成的矢量.

两状态 HMT 模型中, 模型参数要满足一定约束条件, 如 $a_{j,k}^{11} + a_{j,k}^{21} = 1$; $a_{j,k}^{12} + a_{j,k}^{22} = 1$ 等. 将上述条件带入模型中, 则每组 $p_{J,k}$, $A_{j,k}$ 及 $\sigma_{j,k}$ 中分别只有 1 个、2 个和 2 个独立参数需确定. 将这些独立参数组合起来, 可得到描述该根节点 HMT 模型的特征向量 $\theta = [p_{J,k} \ A_{j,k} \ \sigma_{j,k}]^T$. 可以发现, 同一子带内 LCBP 系数根节点对应的 HMT 模型具有相近的特征向量. 为减少特征维数、降低模型复杂度, 本文假设同一子带内所有 LCBP 系数具有相同模型参数, 因此, 整个子带系数可用一组 HMT 模型特征 θ 描述. 对一幅 LCBP 图像, 若最高尺度下方向子带数为 d_J , 将各方向子带 HMT 模型特征组合起来, 可得到整个 LCBP-HMT 模型特征向量 $\Theta = [\theta^1, \theta^2, \dots, \theta^{d_J}]$. 一个两状态 LCBP-HMT 模型中, 最高尺度级中每个子带需 3 个参数描述, 其余各尺度下每个子带需 4 个参数描述. 对一个 J 尺度级, 每个尺度含 d_j 个方向子带的 LCBP 图像, 若用两状态 LCBP-HMT 模型描述, 特征向量 Θ 维数 = $3 \times d_J + 4 \times d_j$ ($j = 1, 2, \dots, J-1$). 这些模型参数可通过 EM 算法训练得到.

4 基于 LCBP-HMT 模型的目标识别

在提取 LCBP-HMT 模型参数作为目标特征的基础上,利用文献[8]给出的快速算法计算 Kullback-Leibler 距离(Kullback-Leibler Distance-KLD)测度进行目标识别。图 4 给出了本文设计的目标识别算法框图。对输入图像 f ,首先进行尺度、位移归一化,作多尺度、多方向 Contourlet 分解;计算 LCBP 系数,建立 LCBP-HMT 模型,提取 LCBP-HMT 模型参数 Θ_f ;比较 Θ_f 和各类标准目标图像 LCBP-HMT 模型参数 Θ_k ($k = 1, 2, \dots, K$) 的 KLD,若 $KLD(\Theta_f, \Theta_k) = \min KLD(\Theta_f, \Theta_k), \forall k = 1, 2, \dots, K$,则将其分入第 k' 类。

5 实验结果和分析

为了检验本文提出的基于 LCBP-HMT 模型的目标识别算法,我们利用该算法识别图 5 所示的 6 类飞机目标。整个数据库共有 600 幅飞机图像,每类飞机由 100 个样本组成,其中 66 个样本包含尺度、角度和位移变化,另外 34 个样本为部分被遮挡样本。作为比较,我们还采用基于传统小波域特征(WT-CMI)和基于 Contourlet 子带系数高斯分布模型特征(Gaussian Density Function Model-GDFM)的目标识别算法。其中,WT-CMI 特征是 Rube 等人^[9]提出的基于小波变换的边界曲率矩不变量,WT-CMI 对仿射变换和轻度边界变形具有不变性,是一种有效的小波形状描述算法;而 Contourlet 子带系数的 GDFM 是 Mosleh 等人^[10]最近提出的,他们认为 Contourlet 子带系数统计特性符合正态分布,可用高斯模型近似描述,并提取各子带系数的均值、方差、最大和最小值作为特征向量。为验证 LCBP-HMT 特征的优越性,对上述 3 类特征,我们都采用最近邻分类器进行分类。实验中,先对各类飞机样本随机抽取 40% 的样本进行训练,取余

下的 60% 样本进行测试。考虑到训练样本选择的随机性,分别取 10 次、20 次、30 次、40 次和 50 次循环的平均值作为识别结果。然后逐步减少训练样本数,依次取各类目标 30%、20% 和 10% 样本进行训练。图 6 给出了各种情况下不同算法对测试集识别率的平均值和方差。

由实验结果可见,本文提出的基于 LCBP-HMT 模型特征的识别算法都取得了最好的识别结果。与传统小波域 WT-CMI 算法以及基于 Contourlet 域高斯分布模型特征的算法相比,本文算法的识别率分别提高了 7.34% 和 2.62%。随着训练样本数量的减少,基于 LCBP-HMT 算法优势更加明显。可见在小样本情况下,基于 LCBP-HMT 依然能获得较好的识别效果。本文算法的主要优点可归纳为:(1) Contourlet 变换有效检测并捕获了目标在任意方向的多尺度几何结构,这些多尺度几何结构恰好表征了目标的本质属性。(2) LCBP-HMT 进一步提取目标在 Contourlet 域的局部特征,并准确描述了同一方向不同尺度间、同一子带内和同一尺度不同方向间 LCBP 系数的相互联系;而 GDFM 模型只考虑了单个子带内的统计特征,不能有效描述不同尺度和不同方向间子带系数的相关性。这也是本文算法优于 Contourlet GDFM 特征方法的原因。另一个有趣的现象是,相比传统小波变换仅能提取目标在水平、垂直和对角三个方向的特征,Contourlet 变换具有更丰富的方向选择性,这使得基于 Contourlet 域特征的识别算法都取得了比基于传统小波特征识别算法更好的识别效果。在各种算法中,错分类样本大多属于局部被遮挡的样本。

算法复杂度方面,用 VC++ 6.0 在 PIII770MHz + 1.0G 内存平台上实现本文算法,每个样本平均分类时间为 3.531s,其中 Contourlet 变换(256 × 256 图像,3 个尺度级,每尺度级方向分解数分别为 8、8、

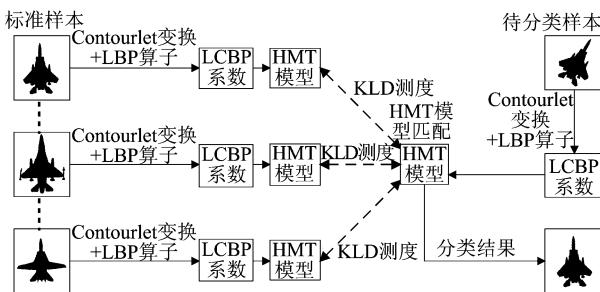


图 4 基于 LCBP-HMT 模型参数的目标识别算法框图

Fig. 4 Framework of object recognition algorithm based on the LCBP-HMT model

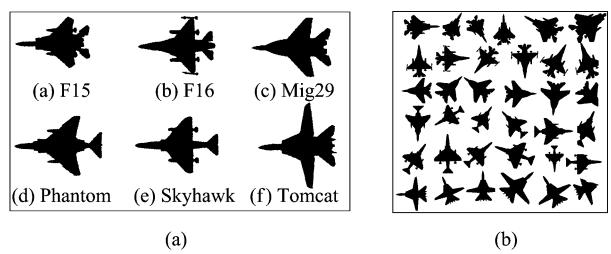


图 5 实验图像 (a) 各类标准目标图像 (b) 数据库中部分图像

Fig. 5 Test images (a) prototype image of all targets (b) some test images in database

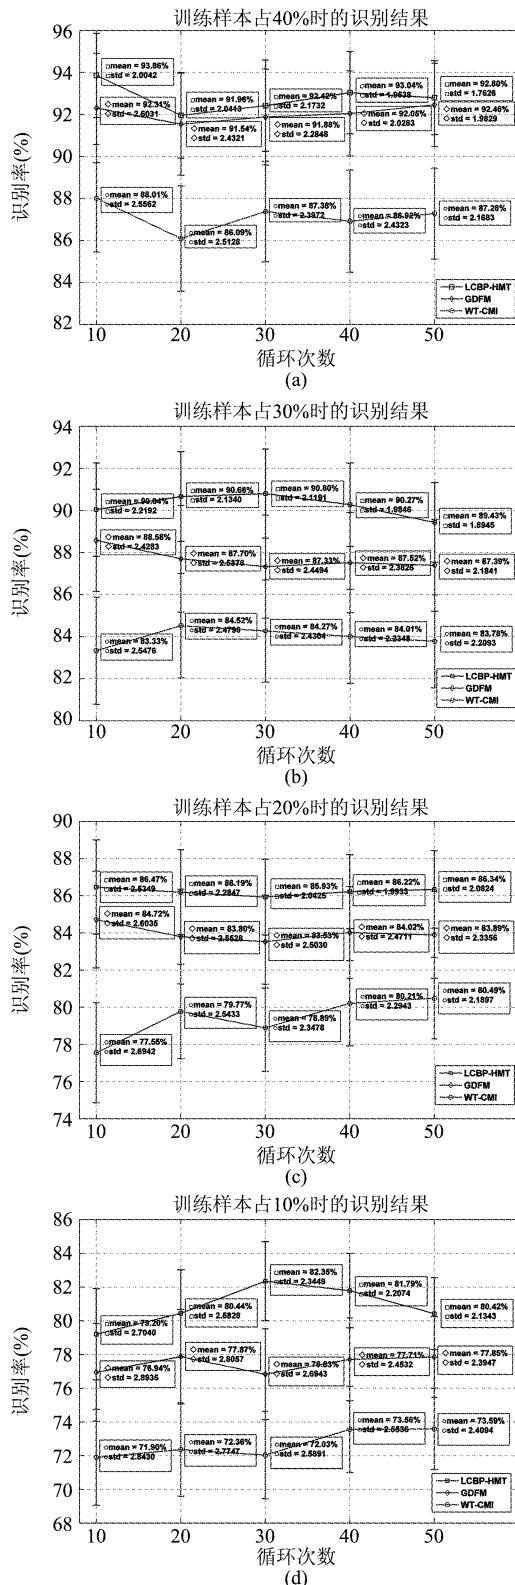


图 6 不同训练样本情况下各种算法识别结果的比较 (a) ~ (d) 训练样本占 40% ~ 10% 时的识别结果

Fig. 6 Comparison of classification performance for various algorithms using different number of training samples (a) ~ (d) classification results in terms of average and standard deviation when number of training samples varies from 40% to 10% of the total sample number

4) 时间开销为 1.783s, 计算 LCBP 系数需 0.260s, 得到 LCBP-HMT 模型参数需 0.843s, 采用 KLD 快速算法^[9]进行比对需 0.645s. 可见, Contourlet 变换时间占据了整个算法时间的一半, 要提高算法的实时性, 需要有效降低 Contourlet 变换时间.

6 结论

结合 MGA 和 LBP 描述, 提出了一种新的多尺度局部方向特征描述子-局部 Contourlet 二值模式 (LCBP). LCBP 具有与 Contourlet 变换相似的统计分布特性: 边缘分布具有非高斯特性, 条件分布满足高斯分布; 系数方差和广义邻域系数幅值成正比. 针对 LCBP 特征的统计分布特性, 采用两状态 HMT 描述 LCBP 系数, 得到 LCBP-HMT 模型. 在此基础上, 提取 LCBP-HMT 模型参数作为特征, 设计了基于 LCBP-HMT 模型的目标识别算法. 实验结果表明, 由于有效捕获了目标局部方向特性, LCBP 特征比传统小波域特征和 Contourlet 域高斯分布模型特征更具鉴别能力.

REFERENCES

- [1] Arivazhagan S, Ganesan L, Kumar S. Texture classification using curvelet statistical and co-occurrence features [C]. *ICPR*, Atlanta, 2006, 2: 938—941.
- [2] Boukabou R, Bouridane A. Contourlet-based feature extraction with PCA for face recognition [C]. *NASA/ESA Conference on Adaptive Hardware and Systems*, Noordwijk, 2008, 1: 482—486.
- [3] Vo N, Oraintara S, Nguyen T. Statistical image modeling using von Mises distribution in the complex directional wavelet domain [C]. *ISCAS*, Seattle, 2008, 1: 2885—2888.
- [4] Do M N, Vetterli M. The contourlet transform: an efficient directional multiresolution image representation [J]. *IEEE Trans. Image Processing*, 2005, 14(12): 2091—2106.
- [5] Po D, Do M N. Directional multiscale modeling of image using the contourlet transform [J]. *IEEE Trans. Image Processing*, 2006, 15(6): 1610—1620.
- [6] Ojala T, Pietikäinen M, Mäenpää T. Multiresolution grayscale and rotation invariant texture classification with local binary patterns [J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2002, 24(7): 971—987.
- [7] Ahonen, Hadid, Pietikäinen. Face description with local binary patterns: application to face recognition [J]. *IEEE Trans. Pattern Analysis and Machine Intelligence*, 2006, 28(12): 2037—2041.
- [8] Do M N. Fast approximation of Kullback-Leibler distance for dependence trees and hidden Markov models [J]. *IEEE Signal Processing Letters*, 2003, 10(4): 115—118.
- [9] Rube E, Kamel M, Ahmed M. Wavelet approximation-based affine invariant 2-D shape matching and classification [C]. *ICIP*, Singapore, 2004, 4: 2139—2142.
- [10] Mosleh A, Zargari F, Azizi R. Text image retrieval using contourlet transform [C]. *International Symposium on Signal, Circuit and Systems*, Lasi, 2009, 1: 1—4.