第 34 卷 第 9 期 自 动 化 学 报 Vol. 34, No. 9
2008 年 9 月 ACTA AUTOMATICA SINICA September, 2008

基于方向极傅里叶频谱 2DPCA 的尾迹检测

汪海洋 [1,2] 潘德炉 [1] 夏德深 [2] 毛志华 [1] 程 乾 [1,3]

摘 要 针对航空图像中的水面尾迹, 提出了一种基于方向极傅里叶频谱二维主成分分析 (Two-dimensional principal component analysis, 2DPCA) 的尾迹自动检测算法. 该方法根据子图像的纹理方向, 对傅里叶频谱进行极坐标变换, 使得到的方向极傅里叶频谱具有平移和旋转不变性. 相对于文献中对极频谱的直接划分作为纹理特征, 本文对它进行一次列二维主成分分析, 一次行二维主成分分析和两次二维主成分分析, 实验结果表明本文方法具有更高的分类识别率, 其中两次二维主成分分析的分类识别率最高. 对 40 幅图像的测试结果表明, 本文的方法能够有效地自动检测航空图像中的水面尾迹纹理.

关键词 二维主成分分析, 傅里叶频谱, 方向极傅里叶频谱
中图分类号 TP391.41

Wake Detection Using 2DPCA of Directional Polar Fourier Spectrum

WANG Hai-Yang[1,2] PAN De-Lu[1] XIA De-Shen[2] MAO Zhi-Hua[1] CHENG Qian[1,3]

Abstract A wake detection method is proposed for the water wake of airphotoes based on two-dimensional principal component analysis (2DPCA) of directional polar Fourier spectrum. This method improves the traditional principal components analysis to obtain the image direction from their Fourier power spectrum, and transforms the Fourier spectrum into the polar coordinates based on the image direction. The directional polar Fourier spectrum are translation and rotation invariant. Compared to the previous method of partitioning the polar spectrum to achieve texture features, the row 2DPCA, the column 2DPCA, and the improved 2DPCA are used to analysis the directional polar Fourier spectrum. From experimental results of 40 images, it is proved that the proposed algorithm can fetch the wake texture precisely.

Key words Two-dimensional principal components analysis (2DPCA), Fourier spectrum, directional polar Fourier spectrum

通过遥感对有权益之争的我国海域进行监测具有快速, 全天候, 实时等优点, 为维护我国海洋权益和国家安全提供了重要保障. 航空可见光遥感是遥感监测中一种非常重要的手段. 然而目前针对航空可见光图像中海洋目标进行自动识别的研究还很少, 为了提高我国的航空可见光遥感监测水平, 本文提出了一种基于方向极傅里叶频谱二维主成分分析 (Two-dimensional principal components analysis, 2DPCA) 的尾迹自动检测算法, 通过提取水下目标运动产生的尾迹实现对它的准确识别, 为可见光航空遥感自动监测提供了技术保障.

水下目标运动产生的尾迹纹理在图像上表现为明暗相间的条纹, 本文目的就是将条纹区域自动检测出来, 如同人脸检测一样[1], 我们将图像分成不同尺度的子块, 判断子块是不是含有条纹. 本文主要研究如何提取条纹子图的纹理特征, 从而有效地区分条纹区域和非条纹区域.

主成分分析 (Principal components analysis, PCA) 作为一种常用的特征提取方法[2], 被广泛地应用到人脸检测和识别中. 然而在用传统 PCA 方法进行图像分析时, 需要将图像转换成一维矢量再运算, 这样就不可避免地需要进行高维、大计算量的运算. 文献 [3] 定义了 2DPCA 并应用于人脸识别, 通过对二维图像数据直接进行列去相关运算, 有效地提高了识别效率与准确率. 但是, 2DPCA 没有考虑图像的行相关特性, 特征仍处在相当高维的空间中, 文献 [4] 对此进行了改进, 利用两次 2DPCA 同时消除行列之间的相关性.

由于航空可见光海洋图像容易受太阳耀斑、云阴影和海洋中噪音的影响, 直接在空域进行特征提取无法取得理想的效果, 我们将子图像变化到频域, 得到它的傅里叶频谱, 并把它转换到极坐标再进行特征提取. 基于条纹子图像纹理方向性比较强的特点, 通过改进传统的主成分分析求得条纹子图像准确的纹理方向, 并将该方向作为极坐标的起始方向, 使极坐标频谱和最终提取的纹理特征具有平移和旋

收稿日期 2007-05-30 收修改稿日期 2007-11-05
Received May 30, 2007; in revised form November 5, 2007
国家自然科学基金 (40576080) 资助
Supported by National Natural Science Foundation of China (40576080)
1. 国家海洋局第二海洋研究所卫星海洋环境动力学国家重点实验室 杭州 310012 2. 南京理工大学计算机系 南京 210094 3. 浙江工商大学旅游学院资源环境与城乡规划系 杭州 310035
1. State Key Laboratory of Satellite Ocean Environment Dynamics, Second Institute of Oceanography, State Oceanic Administration, Hangzhou 310012 2. Computer Department, Nanjing University of Science and Technology, Nanjing 210094 3. Department of Environmental Resources Management and City Planning, Collage of Tourism, Zhejiang Gongshang University, Hangzhou 310035
DOI: 10.3724/SP.J.1004.2008.01053

转不变性. 为了消除光照的影响, 在傅里叶变换前对子块图像进行直方图均衡化处理. 由于得到的极傅里叶频谱维数很高并存在很多冗余信息, 相对于文献 [5] 中对极频谱的直接划分作为纹理特征, 我们分别用一次列二维主成分分析, 一次行二维成分分析和两次二维主成分分析对它进行降维, 将降维后的特征作为各个子图像的纹理特征, 该特征具有平移和旋转不变性. 第 4 节的实验结果将证明本文的方法比文献 [5] 的方法大大提高了分类正确率.

支持向量机方法 (Support vector machine, SVM)[6−7] 是建立在统计学习理论的 VC 维理论和结构风险最小原理基础上的, 根据有限的样本信息在学习精度和学习能力之间寻求最佳折衷, 以期获得最好的推广能力. SVM 在解决小样本, 非线性及高维模式识别问题中表现出许多特有的优势. 鉴于 SVM 良好的特性, 本文将采用其作为纹理特征的分类器. 同时由于本文主要研究对方向极傅里叶频谱进行直接划分, 主成分分析、一次二维主成分分析和两次二维主成分分析对分类性能的影响, 因此我们不对支持向量机本身对分类性能的影响进行讨论, 本文中核函数统一采用径向基核函数.

整个系统的流程图如图 1 所示. 由于尾迹条纹的大小会变化, 算法需要在不同的尺度检测移动窗口内是否含有条纹, 但由于尾迹是个面特征, 在每个尺度上不需要重叠移动窗口. 支持向量机作为分类器被用来判断窗口图像内是否含有条纹. 由此得到整幅图像的条纹波区域, 根据尾迹是个面特征, 消除可能被误判的孤立条纹波区域, 得到最后的检测结果.

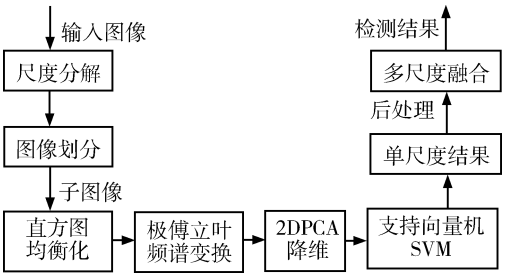

图 1 尾迹检测流程图

Fig. 1 Diagram of the wake detection system

1 条纹纹理方向

纹理方向在纹理分类中有着十分重要的作用, 因为在很多纹理分类应用问题中利用纹理方向能够实现准确的纹理分类. 人们提出了很多纹理方向提取的方法: 文献 [8] 通过分析图像的傅里叶能量谱, 利用主成分分析的方法来求纹理方向; 文献 [9] 提出了一种基于变量图的方法来求纹理的方向和周期等参数; 文献 [10] 通过自相关拟合来提取纹理方向; 文献 [11] 通过 radon 函数变换对纹理方向进行检测.

为了减少计算量, 同时根据尾迹纹理周期性较强的特点, 本文通过对主成分分析的方法[8] 进行改进, 准确地求得了尾迹纹理的方向. 文献 [8] 只考虑了能量谱较大点的坐标位置, 并没有考虑能量谱自身的值对方向的影响, 因此有时求出的尾迹方向和实际方向误差较大. 为了解决这个问题, 本文提出了加权协方差矩阵, 即通过用能量谱值对坐标进行加权求出协方差矩阵, 然后通过主成分分析得到尾迹方向. 求尾迹方向的算法由如下部分组成: 平滑和求能量谱、求尾迹方向和性能比较.

1.1 平滑和求能量谱

由于海洋图像中噪音比较多, 首先对图像进行高斯平滑[12], 然后进行傅里叶变换, 并得到尾迹图像的能量谱. 尾迹图像具有很强的方向性, 因此在尾迹方向的能量谱较大. 为了减少来自其他方向能量谱的干扰, 与文献 [8] 一样选取一个阈值, 将小于该阈值的能量谱赋值为 0. 阈值的选取采用如下算法: 将频率中心的能量谱赋值为零, 在剩下的能量谱中求最大值, 将 $0.3f_{\max}$ 作为阈值 (实验结果表明 $0.3f_{\max}$ 作为阈值能够取得很好的效果), 对能量谱图像进行以下运算

$$y=\begin{cases}0, & f_{i,j}<0.3f_{\max}\\ f_{i,j}, & \text{其他}\end{cases} \tag{1}$$

1.2 求尾迹方向

设图像大小为 $N\times N$, 在第二步处理后能量谱中非零值的个数为 T, 能量谱值为 $F(i_p,j_p)$, $0\le p<T$, 令 X_{center}, Y_{center} 为非零点的中心, M_{convar} 为加权协方差矩阵, 则

$$S_x=\sum_{p=0}^{T-1}F(i_p,j_p)\times\left(i_p-\frac{N}{2}\right) \tag{2}$$

$$S_y=\sum_{p=0}^{T-1}F(i_p,j_p)\times\left(j_p-\frac{N}{2}\right) \tag{3}$$

$$S=\sum_{p=0}^{T-1}F(i_p,j_p) \tag{4}$$

$$X_{\text{center}}=\frac{S_x}{S} \tag{5}$$

$$Y_{\text{center}}=\frac{S_y}{S} \tag{6}$$

$$X=\sum_{p=0}^{T-1}F(i_p,j_p)\times(i_p-X_{\text{center}}) \tag{7}$$

$$Y=\sum_{p=0}^{T-1}F(i_p,j_p)\times(j_p-Y_{\text{center}}) \tag{8}$$

$$M_{\text{convar}}11=\frac{X\times X}{S} \tag{9}$$

$$M_{\text{convar}}12=\frac{X\times Y}{S} \tag{10}$$

$$M_{\text{convar}}21=\frac{X\times Y}{S} \tag{11}$$

$$M_{\text{convar}}11=\frac{Y\times Y}{S} \tag{12}$$

利用主成分分析的方法, 求出加权协方差矩阵 M_{convar} 的特征值 (λ_1,λ_2) 和特征向量 $(\boldsymbol{V}_1,\boldsymbol{V}_2)$, 其中 $\boldsymbol{V}_1$ 为最小特征值对应的特征向量, 则尾迹方向 $\phi_1=\arctan(V_12/V_11)$, 即图像中波条纹的方向, 如图 2 中白线所示; 尾迹纹理方向为 $\phi_2=\arctan(V_22/V_21)$, 即波条纹垂直的方向, 在傅里叶域表现为能量谱集中的方向.

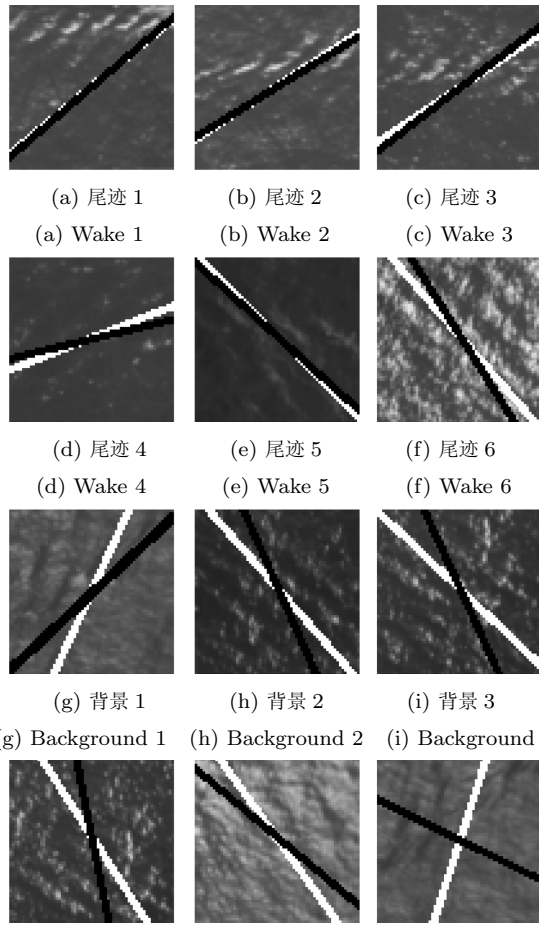

(a) 尾迹 1　(b) 尾迹 2　(c) 尾迹 3

(a) Wake 1　(b) Wake 2　(c) Wake 3

(d) 尾迹 4　(e) 尾迹 5　(f) 尾迹 6

(d) Wake 4　(e) Wake 5　(f) Wake 6

(g) 背景 1　(h) 背景 2　(i) 背景 3

(g) Background 1　(h) Background 2　(i) Background 3

(j) 背景 4　(k) 背景 5　(l) 背景 6

(j) Background 4　(k) Background 5　(l) Background 6

图 2　尾迹方向

Fig. 2　Directions of the wake

1.3　性能比较

为了验证本文的求尾迹方向算法的准确性, 我们对 70 幅尾迹纹理样本图像进行了实验, 用本文算法能够求得 68 幅图像的准确尾迹方向, 另外 2 幅由于方向性太差没能准确求得尾迹方向的图像; 而用文献 [8] 的算法只能求得 60 幅图像的准确尾迹方向. 图 2 给出了它们中有代表性的 12 幅图像, 图像中黑线为文献 [8] 方法求出的尾迹方向, 白线为本文方法求出的尾迹方向. 从图 2 可以看出, 大部分情况下文献 [8] 和本文算法求得的尾迹方向相差不大, 如图 2 (a) ∼ 2 (f), 但当背景噪音方向性较强的时候, 本文算法能够给出更准确的尾迹方向, 如图 2 (g) ∼ 2 (l).

2　极傅里叶频谱

傅里叶变换被广泛地应用在图像处理领域, 被人们认为是图像的第二种语言. 本文通过傅里叶变换来提取尾迹图像的纹理特征, 这是因为如果图像中存在某个方向的尾迹, 那么在频域中那个方向的频谱必然会比较大; 如果图像是背景 (即不含有某个方向的尾迹), 那么在频域中不会存在哪个方向的频谱明显比较大, 即使有一定的方向性, 绝大部分情况下频谱的方向性都没有尾迹图像的方向性强. 图 3 和图 4 (见下页) 展示了尾迹图像与背景图像和它们对应的频谱, 其中白线为第 1 节中的算法求出的图像纹理方向, 即频谱集中的方向. 从图 3 中可以看出当某个方向的尾迹波越规则, 那么在频域中那个方向的频谱越大, 并且越集中在某个频谱范围内; 从图 4 中可以看出由于背景图像不具备很强的方向性, 频谱不像尾迹图像那样比较集中在某个方向, 即使有的背景图像有一定的方向性, 如图 4 (e), 但通常情况下它与尾迹图像频谱集中的频段不一样, 一般来说, 尾迹图像的频谱集中在中频, 背景图像的频谱集中在低频. 所以从子图像的傅里叶频谱提取它的纹理特征, 就是分析不同角度频谱的相关性和不同半径频谱之间的相关性, 为了方便计算, 我们首先把频谱转换到极坐标系.

设 $f(x,y)$ 为样本子图像, N 为图像的宽度和高度, $F(u,v)$ 为它的傅里叶变换, $R(u,v),I(u,v)$ 为 $F(u,v)$ 的实部和虚部, $P(u,v)$ 为傅里叶频谱, 以傅里叶频谱中包含的最大圆为采样区域, 半径为 $R=N/2-2$, 将圆周 S 等分, 进行径向采样, 得到傅里叶频谱的极坐标系 $P(r,\theta)$.

$$P(u,v)=R^2(u,v)+I^2(u,v) \tag{13}$$

$$P(r,\theta)=P\left(\frac{N}{2},(r+2)\cos(\phi_2+\theta),\right.$$
$$\left.\frac{N}{2}+(r+2)\sin(\phi_2+\theta)\right)$$

$$r = 0, 1, \cdots, R-1;\ \theta = 0, \frac{\pi}{S}, \cdots, \frac{\pi \times (S-1)}{S} \tag{14}$$

其中 ϕ_2 为第 1 节中求出的图像纹理方向, 如图 3 和图 4 中的白线方向.

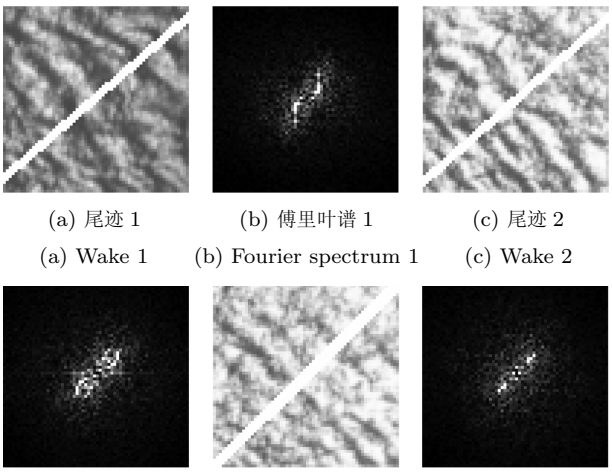

(a) 尾迹 1 (b) 傅里叶谱 1 (c) 尾迹 2

(a) Wake 1 (b) Fourier spectrum 1 (c) Wake 2

(d) 傅里叶谱 2 (e) 尾迹 3 (f) 傅里叶谱 3

(d) Fourier spectrum 2 (e) Wake 3 (f) Fourier spectrum 3

图 3 尾迹图像频谱

Fig. 3 Power spectrum of wake images

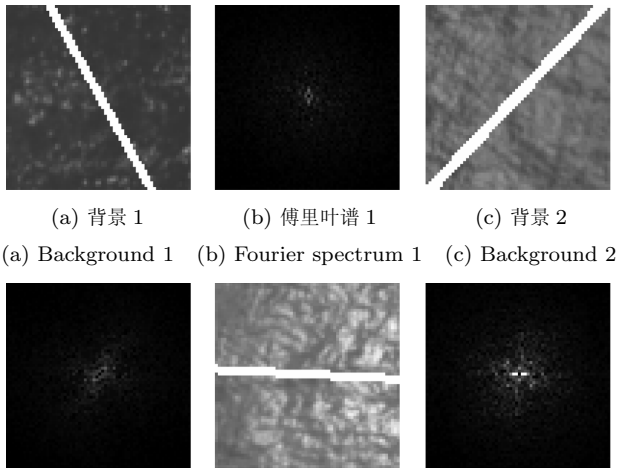

(a) 背景 1 (b) 傅里叶谱 1 (c) 背景 2

(a) Background 1 (b) Fourier spectrum 1 (c) Background 2

(d) 傅里叶谱 2 (e) 背景 3 (f) 傅里叶谱 3

(d) Fourier spectrum 2 (e) Background 3 (f) Fourier spectrum 3

图 4 背景图像频谱

Fig. 4 Power spectrum of background images

3 二维主成分分析

PCA 通过对数据样本的各个维度进行去相关在正交空间中选择统计意义上的主要成分, 从而降低数据维数. 若将样本描述为空间矢量, PCA 变换即为坐标平移与旋转后, 去掉数据散度较小的坐标轴, 得到低维数据表示.

以样本的方向极傅里叶频谱图像为例, 将 M 幅 $R \times S$ 维极频谱图像序列 $P_j\,(j = 0, 1, \cdots, M-1)$ 为样本, 首先将方向极频谱图像重新排列为 $R \times S \times 1$ 维列向量序列 $I_j\,(j = 0, 1, \cdots, M-1)$, 然后对列向量序列进行 PCA 分析, 以消除各个像素之间的相关性. 文献 [3] 提出了 2DPCA 的思想, 其本质不同于 PCA 的各个像素之间去相关, 而是仅仅去除图像各列之间的相关性. 定义图像散度矩阵为

$$G_t = \frac{1}{M} \sum_{j=0}^{M-1} (P_j - \overline{P})^{\mathrm{T}} (P_j - \overline{P}) \tag{15}$$

其中 $\overline{P}$ 为图像均值, 则其前 l $(l \le \min(R, S))$ 个最大特征值对应的特征向量 $\boldsymbol{u}_i\,(i = 0, 1, \cdots, k-1)$ 组成变换矩阵 U_2, 定义

$$B_j = P_j U_2, \quad j = 0, 1, \cdots, M-1 \tag{16}$$

为样本极傅里叶频谱 $P_j\,(j = 0, 1, \cdots, M-1)$ 的 2DPCA 变换, 每个样本极傅里叶频谱均由维特征矩阵表示. 显而易见, 如果想消除行之间的相关性, 只需将矩阵转置用上面方法进行处理.

经过式 (16) 变换消除了列之间的相关性, 即方向极频谱中角度的相关性, 但并没有消除行之间的相关性, 即方向极频谱中半径的相关性, 影响了分类性能并且得到的特征维数还很高. 为了解决这个问题, 文献 [4] 对式 (16) 变换后的特征矩阵, 再次进行 2DPCA 变换以消除极频谱中行之间的相关性, 并进一步降低特征维数. 容易证明, 对图像行进行 2DPCA, 可以通过对图像矩阵的转置在水平方向上用式 (16) 代替的方法来进行. 给定方向极傅里叶频谱图像 $P_j\,(j = 0, 1, \cdots, M-1)$, 它的两次二维主成分分析, 可由下式定义

$$F = VPU = (V(PU)) = ((PU)^{\mathrm{T}} V^{\mathrm{T}})^{\mathrm{T}} \tag{17}$$

即由式 (16) 先求得第一次变换 $F_1 = PU$ 中的列去相关矩阵 U 和变换结果 F_1, 再求得 F_1^{T} 的列去相关矩阵 V^{T}, 由式 (17) 可知 V 为原样本极频谱 P 的行去相关矩阵, 其中 U 为 $S \times q$ 维矩阵, V 为 $p \times R$ 维矩阵, 则经两次二维主成分分析降维后的特征矩阵的维数为 $p \times q$, 远小于 $R \times S$.

4 实验结果

4.1 性能比较

为了使提取的极傅里叶频谱特征具有一定的尺度不变性, 我们选取不同尺度下样本子图像 1 500 幅, 并将它们的大小归一化为 64×64 像素. 所有样本子图像中含有条纹纹理图像的数量为 750 幅, 不含条纹纹理图像为 750 幅. 图 5 是两种样本的 12 个

例子: 图 5 (a) ∼ 5 (f) 为包含尾迹条纹的样本子图像; 图 5 (g) ∼ 5 (l) 为不含尾迹条纹的样本子图像. 从图 5 中可以看出尾迹条纹由于海洋环境的不同, 数量会有所不同, 例如图 5 (c) 只含有 2 个条纹, 而图 5 (f) 含有 10 个条纹; 同时可以看出, 由于天气的变化, 外界光照变化大, 图像的亮度变化也很大, 例如图 5 (j) 和图 5 (k). 所以为了消除光照的影响, 在提取图像的极傅里叶频谱特征前首先要进行亮度直方图均衡化.

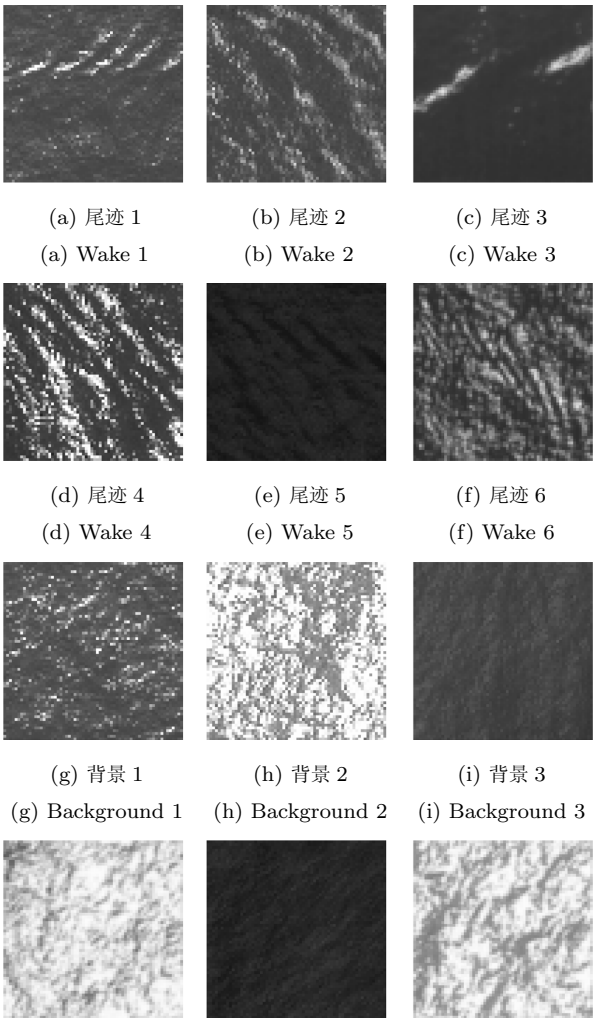

(a) 尾迹 1　(b) 尾迹 2　(c) 尾迹 3
(a) Wake 1　(b) Wake 2　(c) Wake 3

(d) 尾迹 4　(e) 尾迹 5　(f) 尾迹 6
(d) Wake 4　(e) Wake 5　(f) Wake 6

(g) 背景 1　(h) 背景 2　(i) 背景 3
(g) Background 1　(h) Background 2　(i) Background 3

(j) 背景 4　(k) 背景 5　(l) 背景 6
(j) Background 4　(k) Background 5　(l) Background 6

图 5　样本图像

Fig. 5　Sample images

分别随机选取两类图像中各自的 250 幅图像作为训练样本, 剩下的作为测试样本, 即训练样本为 500 个, 测试样本为 1 000 个. 对每幅子图像经直方图均衡化, 方向极傅里叶频谱特征提取, 其中 $R = 30$, $S = 30$, 分别用一次列二维主成分分析, 一次行二维成分分析和两次二维主成分分析降维, 并将降维后的纹理特征作为支持向量机的输入. 在 SVM 的实际应用中参数设置对于分类性能的好坏非常关键, 本文采用交叉验证的方法选取有关参数.

我们进行三个方面的实验: 1) 比较本文的方法与文献中对极频谱直接划分的, 目的是说明通过二维主成分分析的方法对极频谱进行特征提取, 能够取得更高的识别率; 2) 比较相同维数的一次列 2DPCA 特征, 一次行 2DPCA 特征的分类性能, 目的是说明不同频率半径的频谱信息含有更多的分类信息; 3) 比较两次 2DPCA 和一次 2DPCA 的分类性能, 目的是说明相对于一次 2DPCA, 两次 2DPCA 消除了行列两个方向的冗余信息, 不仅降低了特征维数, 并且提高了分类正确率.

对极频谱直接划分的方法及如图 6 所示, 分别对半径和角度进行等分, 分别计算不同圆环区域内的频谱和与不同锲形区域内的频谱和, 将它们作为图像的纹理特征.

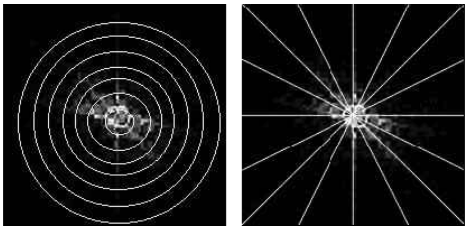

图 6　样本图像

Fig. 6　Sample images

表 1 给出了不同的几个极频谱划分的对训练样本和测试样本的正确识别率, 其中 m 表示半径被等分的数量, n 表示角度被等分的数量. 表 2 (见下页) 给出了两次 2DPCA 降维后不同维数特征对训练样本和测试样本的正确识别率, 其中 s 表示列 2DPCA 降维后的维数, 代表频谱方向信息; r 表示行 2DPCA 降维后的维数, 代表频谱频率半径信息. 从表 1 和表 2 可以明显看出相对于文献对频谱直接划分的方法, 通过两次 2DPCA 的方法训练样本和测试样本的正确识别率大大提高. 这是因为通过两次 2DPCA 的方法消除了频谱方向和频谱频率半径间的冗余信息, 去除了对分类无用的冗余特征信息, 得到了更有利于样本条纹子图像分类的频谱特征. 而文献中的方法只是简单地对频谱角度和半径划分提取图像的频谱方向和频率大小信息.

表 1　文献中的正确分类率

Table 1　Classification accuracy of the literature

	$m = 6,\ n = 6$	$m = 10,\ n = 10$	$m = 30,\ n = 30$
训练样本 (%)	82.8	95.6	95.6
测试样本 (%)	77.0	80.1	80.6

表 2 两次 2DPCA 的正确分类率

Table 2 Classification accuracy of twice 2DPCA

	$r=8,\ s=8$	$r=12,\ s=8$	$r=16,\ s=15$
训练样本 (%)	100	100	100
测试样本 (%)	87.4	86.3	82

表 3 和表 4 分别给出了对极傅里叶频谱列和行进行一次 2DPCA 降维后 (即分别消除不同频谱角度和不同频率半径之间的相关性), 不同维数特征对训练样本和测试样本的分类正确率. 从表 3 可以看出当 s 较大时, 分类正确率较低, 这说明很多方向的极频谱信息不包含有用的分类信息, 不消除这些冗余信息会降低分类正确率. 相反, 从表 4 可以看出当 r 较大时, 分类正确率较高, 这说明大部分频率的极频谱信息都包含有用的分类信息. 由于不同频率半径的频谱信息包含了更多的分类信息, 所以当分别进行一次列和行 2DPCA 降维后, 取相等的维数特征, 列 2DPCA(即消除不同方向频谱冗余信息) 取得了更高的识别率, 如表 3 和表 4 的第 1 列和第 2 列. 而当维数比较高时, 特征中含有比较多的冗余信息, 对分类性能影响比较大, 如表 3 和表 4 的第 3 列.

表 3 一次列 2DPCA 的正确分类率

Table 3 Classification accuracy of column 2DPCA

	$r=30,\ s=8$	$r=30,\ s=12$	$r=30,\ s=16$
训练样本 (%)	99.8	100	99.4
测试样本 (%)	87	85.7	82.9

表 4 一次行 2DPCA 的正确分类率

Table 4 Classification accuracy of row 2DPCA

	$r=8,\ s=30$	$r=12,\ s=30$	$r=16,\ s=30$
训练样本 (%)	100	99.8	100
测试样本 (%)	84.3	84.6	85.2

从表 2～4 可以看出两次 2DPCA 由于有效消除了两个方向的冗余信息, 不仅获得了更少的特征维数, 并且取得了更高的识别率, 如表 2 特征维数为 64 ($r=8$, $s=8$), 测试样本的识别率为 87.4 %; 表 3 特征维数为 240 ($r=30$, $s=8$), 测试样本的识别率为 87 %, 表 4 特征维数为 240 ($r=8$, $s=30$), 测试样本的识别率为 84.3 %.

4.2 性能比较

从 4.1 节的分析, 可知只需用比较小的维数两次 2DPCA 特征就就能取得很好的分类效果. 为了验证这一点, 我们取 $r=8$, $s=8$, 利用两次 2DPCA 特征进行尾迹检测试验. 为了说明尾迹检测算法的有效性, 对 40 幅图像进行尾迹检测, 其中含有尾迹 35 幅、不含尾迹 5 幅. 图 7 给出了算法实验结果的四个例子, 其中图 7 (a), (c), (e), (g) 为原始图像; 图 7 (b), (d), (f), (g) 为提取的纹理区域图像 (黑色表示尾迹区域), 图像的大小为 448×448 像素. 从图 7 (b), (d), (h) 可以看出, 包含尾迹纹理的区域基本都能够正确识别出来, 即使被错分为背景区域, 通过它周围正确识别为尾迹区域的子图像, 利用算法的后处理仍然可以将其提取出来. 同理如图 7 (f) 即使有个别背景子图像错分为尾迹区域, 通过算法的后处理也能够将其噪音点排除掉. 尾迹的正确检测率为 94.3%、误检率为 0%: 35 幅含有尾迹的图像有 34 幅能够被准确地提取出来, 5 幅不含尾迹的图像全部识别为不含尾迹, 2 幅没有被检测尾迹图像是由于尾迹纹理信息太弱. 实验结果证明本文

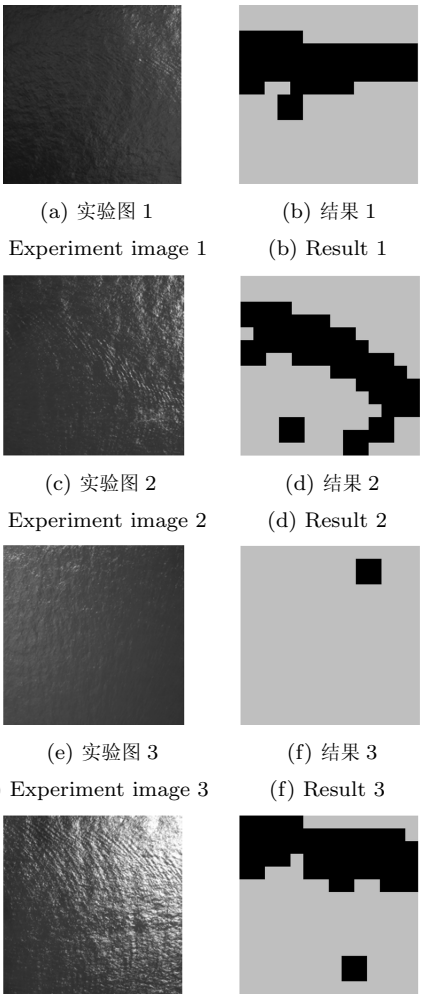

(a) 实验图 1 (b) 结果 1

(a) Experiment image 1 (b) Result 1

(c) 实验图 2 (d) 结果 2

(c) Experiment image 2 (d) Result 2

(e) 实验图 3 (f) 结果 3

(e) Experiment image 3 (f) Result 3

(g) 实验图 4 (h) 结果 4

(g) Experiment image 4 (h) Result 4

图 7 样本图像

Fig. 7 Sample images

提出的尾迹检测框架能够准确地检测航空图像中水下目标运动产生的尾迹, 具有很强的实用价值.

5 总结

本文提出了航空图像中水下运动目标的尾迹自动检测算法, 实验结果证明该算法能够有效地自动检测水下目标运动产生的尾迹, 填补了国内在航空可见光海洋图像中目标自动识别方面的空白, 为加强我国航空监测水平提供了技术支持. 本文的贡献主要有以下几点: 1) 根据尾迹条纹方向性强的特点, 改进了文献中的方法, 提高了尾迹方向的精度, 提出了方向极傅里叶频谱, 使提取的纹理特征具有旋转不变性, 减少了算法的复杂度; 2) 相对于文献中直接对频谱半径和角度划分提取纹理特征, 本文提出了通过两次 2DPCA 的方法提取极傅里叶频谱的特征, 大大提高了分类正确率; 3) 分析了一次列 2DPCA 和一次行 2DPCA 的分类性能, 证明了不同频率半径的频谱信息含有更多的分类信息; 4) 比较两次 2DPCA 和一次 2DPCA 的分类性能, 证明了两次 2DPCA 的方法能够更有效地降低特征维数, 提高识别率.

References

1 Yang M H, Kriegman D J, Ahuja N. Detecting faces in images: a survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(1): 34−58

2 Turk M, Pentland A. Eigenfaces for recognition. *Journal of Cognitive Neuroscience*, 1991, **3**(1): 71−86

3 Yang J, Zhang D, Frangi A F, Yang J Y. Two-dimensional PCA: a new approach to appearance-based face representation and recognition. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2004, **26**(1): 131−137

4 Li Qiang, Qiu Zheng-Ding, Sun Dong-Mei, Liu Lu-Lu. Online palmprint identification based on improved 2DPCA. *Acta Electronica Sinica*, 2005, **33**(10): 1886−1889
(李强, 裘正定, 孙冬梅, 刘陆陆. 基于改进二维主成分分析的在线掌纹识别. 电子学报, 2005, **33**(10): 1886−1889)

5 Li Wen-Xin, Zhang Da-Peng, Xu Zhuo-Qun. Palmprint recognition based on Fourier transform. *Journal of Software*, 2002, **13**(5): 879−886
(李文新, 张大鹏, 许卓群. 基于傅里叶变换的掌纹识别方法, 软件学报, 2002, **13**(5): 879−886)

6 Burges C J C. A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 1998, **2**(2): 121−167

7 Chang C C, Lin C J. Libsvm: a library for support vector machines [Online], available: http://www.csie.ntu.edt.tw/~cjlin/libsvm/, November 6, 2007

8 Josso B, Burton D R, Lalor M J. Texture orientation and anisotropy calculation by Fourier transform and principal component analysis. *Mechanical Systems and Signal Processing*, 2005, **19**(5): 1152−1161

9 Sanz R T. A texture orientation estimator for discriminating between forests, orchards, vineyards, and tilled fields. In: Proceedings of IEEE International Geoscience and Remote Sensing Symposium. New York, USA: IEEE, 2005. 1277−1280

10 Sourice A, Plantier G, Saumer J L. Autocorrelation fitting for texture orientation estimation. In: Proceedings of IEEE International Conference on Image Processing. Barcelona, Spain: IEEE, 2003. 14−17

11 Sun Wen-Fang, Zhao Yi-Gong. Texture orientation detection based on radon transform. *Journal of Computer Applications*, 2005, **25**(z1): 233−234
(孙文方, 赵亦工. 基于有限 Radon 变换的图像纹理方向的检测. 计算机应用, 2005, **25**(z1): 233−234)

12 Duda R O, Hart P E, Stork D G [Author], Li Hong-Dong, Yao Tian-Xiang [Translator]. *Pattern Classification (Second Edition)*. Beijing: China Machine Press, 2003
(Duda R O, Hart P E, Stork D G [著], 李宏东, 姚天翔 [译]. 模式分类 (第二版). 北京: 机械工业出版社, 2003)

汪海洋 博士研究生. 主要研究方向为图像处理, 计算机视觉和模式识别. 本文通信作者.
E-mail: why_haiyang@126.com
(**WANG Hai-Yang** Ph. D. candidate. His research interest covers image processing, computer vision, and pattern recognition. Corresponding author of this paper.)

潘德炉 教授. 主要研究方向为海洋水色遥感, 卫星遥感, 模式识别.
E-mail: pandelu@sio.hzcnc.net
(**PAN De-Lu** Professor. His research interest covers remote sensing of ocean color, satellite remote sense image analyzing, and pattern recognition.)

夏德深 教授. 主要研究方向为图像处理, 卫星遥感, 模式识别.
E-mail: deshen_x@263.net
(**XIA De-Shen** Professor. His research interest covers image processing, satellite remote sense image analyzing, and pattern recognition.)

毛志华 教授. 主要研究方向为卫星海洋遥感.
(**MAO Zhi-Hua** Professor. His main research interest is satellite remote sense image analyzing.)

程 乾 博士. 主要研究方向为卫星海洋遥感.
(**CHENG Qian** Ph. D.. His main research interest is satellite remote sense image analyzing.)