

文章编号:1004-4213(2010)06-1034-6

基于形态学成分分析的静态极光图像分类算法*

付蓉^{1,2}, 李洁¹, 高新波¹

(1 西安电子科技大学 电子工程学院, 西安 710071)

(2 西安工程大学 计算机科学学院, 西安 710048)

摘要:为了解决海量极光图像手工分类效率低下的问题,提出一种静态极光图像自动分类系统,使用形态学成分分析将极光纹理从复杂背景中分离出来,从纹理中提取特征并利用支持向量机进行分类.实验结果表明:该算法分类正确率较之于传统方法均提高约 10%,当分类器支持向量机+线性核函数时,分类速度最快,最适合于海量数据的处理.

关键词:图像分类;形态学成分分析;支持向量机;日侧冕状极光

中图分类号: TP391.4

文献标识码: A

doi: 10.3788/gzxb20103906.1034

0 引言

极光作为磁层磁力线在极区的“足迹”,反映了磁层和太阳风中的很多现象,因此人们早在 17 世纪就对极光观测研究表现出了浓厚的兴趣.不同形状的极光蕴含了不同的物理意义,这些形状、位置和亮度不同的极光结构对应不同的磁层边界动力学过程^[1].其中日侧冕状极光^[2]是磁正午附近出现的一种主要极光形态,能反映太阳风-磁层相互作用的各种动力学过程以及空间天气的活动情况.因此研究各类日侧冕状极光对分析电离层不均匀体的形态和动态变化特征具有重要意义.要深入研究日侧冕状极光,首先需要将冕状极光从日侧全天空极光观测序列中分离出来.

最初对极光的分类研究建立在肉眼观察的基础之上,使用手工完成标记和分类的工作.2004 年 Syrjäso^[3]开始利用图像处理技术对夜侧极光进行了自动分类研究.前期使用图像处理技术对极光进行分类的方式通常是直接对极光原图或者是只经过非常简单的预处理(例如缩放、裁剪、掩模等)后的极光图像提取纹理特征,然后利用特征进行分类,这种模式整体的分类效果并不是很理想.其主要原因在于:最能够代表极光特征的纹理部分湮没在了复杂的背景中,导致纹理受到了背景的干扰,纹理不清晰,特征描述也随之不够准确.因此将纹理从背景中剥离出来,单独对纹理部分提取特征,则其特征会更

具有代表性,分类正确率也会更高.

本文使用形态学成分分析(Morphological Component Analysis, MCA)^[4]的方法将极光的高频纹理部分与低频平滑部分相分离,得到的高频纹理图像比原图的纹理更清晰、特征更明显.使用支持向量机(Support Vector Machine, SVM)分类后得到的分类效果更好.

1 静态极光图像自动分类系统

早期极光图像的分类主要依靠专家的经验将极光图像标记为冕状、弧状等,如图 1.随着全天空摄影仪所捕捉图像数量的迅速增加,人工分类效率低下、客观性不足的缺点更加明显,因此设计一种客观、有效、可靠、能够迅速处理极光图像的自动分类系统变成的越发迫切.

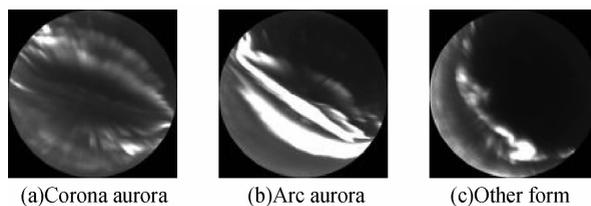


图 1 主要极光图像形态

Fig. 1 Main forms of aurora images

本文所提出的基于形态学成分分析的极光图像自动分类系统的流程图如图 2,该系统主要包括预处理、特征提取和分类器三个主要部分.

Step 1 预处理包括掩模和 MCA 分离两个子过程.第一个过程是对极光原图进行掩模等操作,去掉拍摄时周边物体影像的干扰;第二个过程是使用 MCA 将极光原图的纹理和平滑部分进行分离,方便后面对于纹理部分提取特征.预处理完成后,每幅极

* 国家自然科学基金(60702061、60402038)和中国气象局公益性行业(气象)科研专项经费(GYHY200706043)资助
Tel: 029-88204271 Email: angelinmay@126.com
收稿日期: 2008-12-29 修回日期: 2009-03-16

光原图得到两幅图像:纹理部分图像和平滑部分图像。

Step 2 针对纹理部分提取特征,使用均值、标准差、三阶距和熵等特征来描述每幅图像.将提取的

特征进行归一化处理,形成特征向量。

Step 3 对于特征向量,使用最近邻、SVM+RBF 核函数和 SVM+Linear 核函数三种分类方法对特征进行分类。

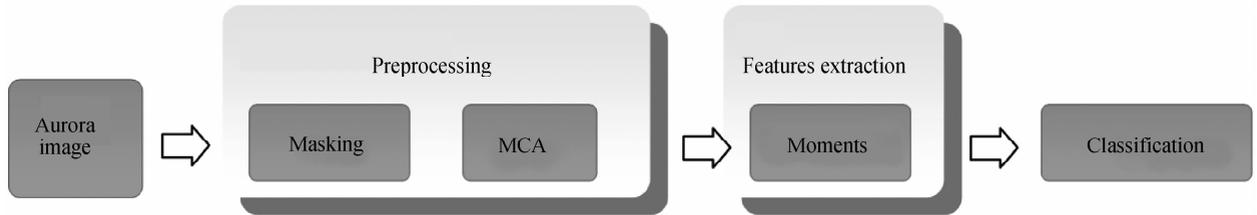


图 2 基于 MCA 的静态极光分类系统

Fig. 2 Flowchart of static aurora classification system based on MCA

2 MCA 预处理后图像特征提取

2.1 MCA 分离图像

MCA 的主要思想^[4-5]是假设要处理的图像 A 所包含的 M 个不同信号分别对应 M 个不同的形态 $\{A_i\}_{i=1,2,\dots,M}$,而这 M 个不同的信号线性组合形成了

图像 A,即 $A=A_1 + A_2 + \dots + A_M$.对图像来说,可以将这 M 个不同的信号分别对应成 M 个互不相同且背景透明的层,例如信号 A_i 对应第 i 层,将这些层叠加起来就构成了原始的图像 A,如图 3.图 3(a)是 Barbara 原图,该图可看作是织物纹理层(b)和背景平滑层(c)的叠加。

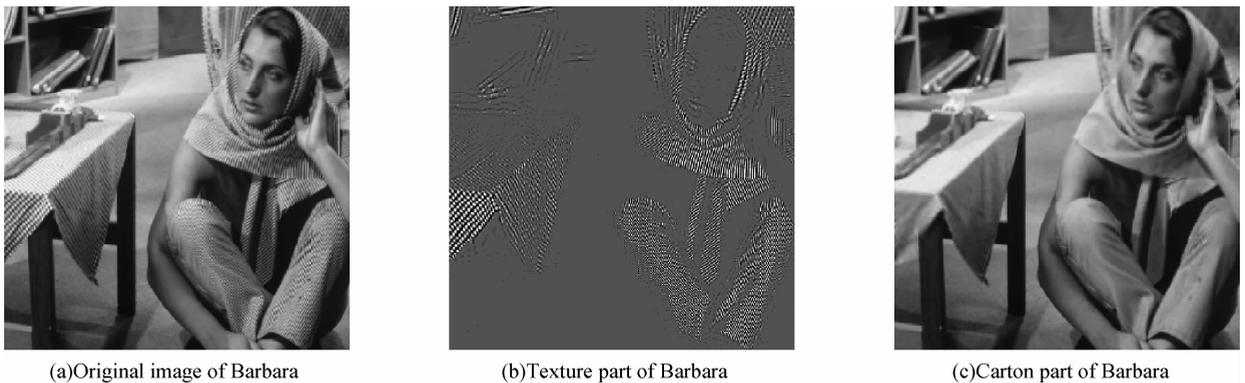


图 3 MCA 分离效果示意

Fig. 3 The demo of separated results through MCA

对于这 M 个层,MCA 使用一组完备的字典 $\{\Phi_1, \dots, \Phi_M\}$ 来描述^[5].因为这 M 个层的形态互不相同,因此 MCA 假设:对于每一层 A_i ,都可以用相应字典 Φ_i 的原子稀疏地表示出来,而其它字典 $\Phi_j (j \neq i)$ 则不能稀疏地表示 A_i 层.在这里,不同的字典描述了不同形态的信号,将各类形态的信息有效地分离开来。

对极光图像而言,最能够表征极光图像类型的就是极光的纹理,因此根据需要将极光图像分解成

两个不同的形态:纹理部分和去掉纹理后的平滑部分,即令 $M=2$,设 A_1 对应极光的高频纹理部分, A_2 对应低频平滑部分,如图 4.要用 Φ_i 中的原子最稀疏的表示 A_i ,即得到 A_i 的最优解,要满足

$$\min_{A_1, A_2} \|\Phi_1^T A_1\|_1 + \|\Phi_2^T A_2\|_1 \text{ s. t. } A=A_1+A_2 \quad (1)$$

式(1)等价于

$$\{A_1^{opt}, A_2^{opt}\} = \text{Arg} (\min_{A_1, A_2} \|\Phi_1^T A_1\|_1 + \|\Phi_2^T A_2\|_1) + \lambda \|A - A_1 - A_2\|_2^2 \quad (2)$$

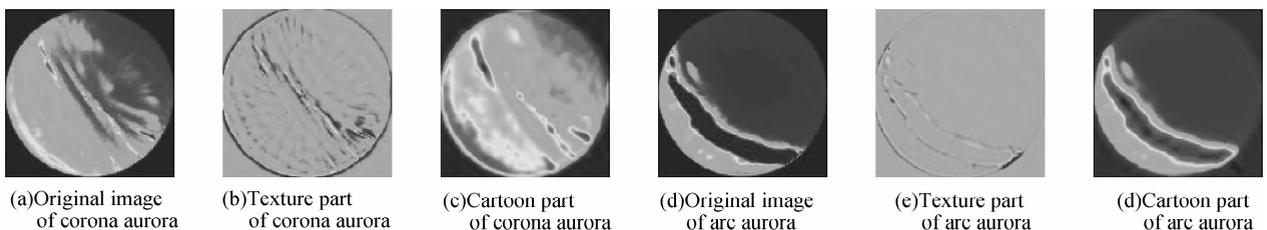


图 4 冕状极光和弧状极光 MCA 分离效果伪彩图

Fig. 4 The pseudocolor image of separated results of corona and arc aurora images through MCA

用于描述纹理的字典有 Gabor 变换、小波包、局部离散余弦变换等,用于描述平滑部分有小波变换、曲线波变换、脊波变换、轮廓波变换等^[5]. 由于纹理在频域上具有周期性,所以本文采用局部离散余弦变换描述极光纹理,而背景平滑部分都是由曲线构成的,所以使用曲线波^[6]描述极光平滑部分.

经过 MCA 分离后的冕状极光的高频纹理部分和低频平滑部分的伪彩图如图 4(a)~(c);弧状极光分离结果如图 4(d)~(f).

2.2 MCA 分离后纹理的特征提取

冕状极光(如图 1(a))与其它类型的极光(如图 1(b)、(c))的纹理有非常大的不同,主要表现在

1)纹理平均亮度:在弧状极光中有大片非常亮的带状区域,冕状极光的纹理的亮度明显低于弧状极光.

2)纹理粗糙程度:对整幅图来说,冕状极光的纹理有一定规则、变化相对平滑,而弧状极光的纹理变化较大,比较粗糙.

3)规则性:从冕状极光的静态图像中可看出,它的纹理像层叠的窗帘,比较有规则性.

4)随机性:冕状极光的纹理较规则,随机性较低;而弧状极光中纹理出现并没有什么规律,随机性较高.

这四个特征用图像直方图的统计矩^[7]进行描述,亮度对应均值、粗糙度对应标准偏差、纹理的规则程度对应三阶矩、随机性则对应熵^[7-8],如表 1. 其中, m 表示平均灰度, L 表示不同灰度的总数, z_i 代表灰度级, $p(z_i)$ 表示灰度级为 z_i 的点的百分比, σ 表示方差, μ_3 表示三阶矩, e 表示熵.

表 1 纹理特征的数学表达式

Table 1 Mathematical expressions of texture features

Texture measures	Moments	Expressions
The average luminance of texture	Mean	$m = \sum_{i=0}^{L-1} z_i p(z_i)$
Relative smoothness	Standard deviation	$\sigma = \left(\sum_{i=0}^{L-1} (z_i - m)^2 p(z_i) \right)^{\frac{1}{2}}$
The regularity of texture	Third moment	$\mu_3 = \sum_{i=0}^{L-1} (z_i - m)^3 p(z_i)$
Variability of texture	Entropy	$e = - \sum_{i=0}^{L-1} p(z_i) \log_2 p(z_i)$

由于 MCA 将纹理从复杂背景中分离出来,所以从纹理部分所提取的四个特征构成的特征向量来自于原图的特征向量更具有代表性. 实验中每组 500 幅图像分别对应生成:原图特征向量矩阵和纹理部分特征向量矩阵,对这两个特征向量矩阵分别使用三种分类器进行对比实验.

3 分类器

3.1 最近邻算法

定义:设模式类别有 C 个: $\omega_1, \omega_2, \dots, \omega_c$, 每类标明类别的训练样本有 N_i 个 ($i=1, 2, \dots, C$). 最近邻分类器是将各个类中所有的样本与未知样本 x 逐个进行比较,最后判别样本 x 与距离它最近的样本同类. 设 ω_i 类的判别函数为

$$g_i(x) = \min_k \|x - x_i^k\|, k=1, 2, \dots, N_i \quad (3)$$

x_i^k 表示第 ω_i 类中的第 k 个样本. 因此,如果

$$g_m(x) = \min_i (g_i(x)), i=1, 2, \dots, C, \quad (4)$$

则判定: $x \in \omega_m$, 即 x 属于第 m 类.

3.2 SVM

SVM 的主要思想是建立一个超平面,使两类样本之间距离分类面间隔最大^[9].

SVM 分类算法:设线性可分样本集

$$(x_i, y_i), i=1, 2, \dots, N, x_i \in R^d$$

有 N 个样本点,其中 x_i 是 d 维的特征向量, $y_i \in \{1, -1\}$ 表示 x_i 的类别,如果样本点 x_i 属于第一类,则 $y_i=1$;否则 $y_i=-1$.

d 维空间线性判断函数的一般形式为 $g(x) = w \cdot x + b$,用于分类的分类线方程为

$$g(x) = wx + b = 0 \quad (5)$$

即分类线上的样本点带入上式值为 0;若集中的类 1 和类 2 线性可分,则存在 (w, b) , w 为权向量, b 为分类阈值,使得

$$wx_i + b > 0, \forall x_i \in \text{类 1}$$

$$wx_i + b < 0, \forall x_i \in \text{类 2}$$

为了使分类间隔达到最大,令两类样本都满足 $|g(x)| = 1$,则分类间隔为

$$d = \frac{2}{\|w\|_2} \quad (6)$$

求分类间隔 d 最大化等价于求下式的最小值

$$\min G(w) = \|w\|_2^2 \quad (7)$$

使 $y_i(w \cdot x + b) - 1 \geq 0, i=1, 2, \dots, N$, 其中满足式 $y_i(w \cdot x + b) - 1 = 0$ 的训练样本就是支持向量,构造拉格朗日函数,将上式转化成二次规划问题以利于求解

$$L(w, b, a) = \|w\|_2^2 - \sum_i a_i (y_i [(w \cdot x_i) + b] - 1) \quad (8)$$

式(8)中的 a_1, a_2, \dots, a_N 是拉格朗日乘子,对式中的 w 和 a 分别求偏导,转化为式(7)的对偶问题,求函数 $\Phi(a)$ 的极大值

$$\Phi(a) = \sum_{i=1}^N a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j (x_i \cdot x_j) \quad (9)$$

式(9)的约束条件为

$$\sum_{i=1}^N y_i a_i = 0, a_i \geq 0, i = 1, 2, \dots, N \quad (10)$$

若 a^* 是最优解,则

$$\omega^* = \sum_{i=1}^N a^* y_i x_i \quad (11)$$

由式(11)得到最优分类函数为

$$f(x) = \text{sgn} \{ (\omega^* \cdot x) + b^* \} = \text{sgn} \left\{ \sum_{i=1}^N a^* y_i (x_i \cdot x_j) + b^* \right\} \quad (12)$$

这里所述均为线性可分的情况,对于非线性可分的情况,使用非线性函数 φ 将低维非线性可分的样本点映射到高维线性可分的特征空间,在高维线性可分特征空间中做线性分类即可.用 $(\varphi(x_i) \cdot \varphi(x_j))$ 代替内积 $(x_i, x_j)^{[10]}$,令 $K(x_i, x_j) = (\varphi(x_i) \cdot \varphi(x_j))$, K 称为核函数,则式(12)用核函数表示为

$$f(x) = \text{sgn} \left\{ \sum_{i=1}^N a^* y_i K(x_i \cdot x_j) + b^* \right\} \quad (13)$$

常用核函数包括线性核函数、径向基核函数、多项式核函数和 Sigmoid 核函数,本文采用线性核函数(用 SVM+Linear 表示)和径向基核函数(用 SVM+RBF 表示)作为分类器分别对极光图像进行分类实验.

4 实验设计与分析

为测试本文提出的基于 MCA 的极光分类算法的有效性,本节设计了测试实验.选用从北极黄河站采集到的实测数据构成的极光样本数据库中 2003 年 12 月 18 日到 2004 年 1 月 14 日的 13,225 幅样本进行实验.极光样本数据库中的极光图像都经过两位以上的专家进行人工分类、标记,构成了实验用的标准数据库.从中随机选择样本后,使用三种分类器根据极光图像提取的特征对图像进行自动分类、标记,并把分类标记的结果与专家标记的类别进行对比,得到分类正确率.

4.1 预处理与样本选择

样本库中的极光图像是由全天空数码照相机拍摄的,由于在拍摄时将旁边的山和基地的灯光也照了下来,对特征的提取有一定干扰,所以需要图像进行掩模,去掉周围一圈噪声.实验设计为每组 500 个样本,样本数量较大,为提高速度,将 512×512 的图像缩小为 128×128 . 随机从样本库中选择 6 组样本,每组 500 个样本,共 3 000 幅图像.因为是随机选取,其中有少部分重复.

4.2 原图特征的分类结果

提取原图的均值、标准方差、三阶矩和熵四个特征构建特征向量,每组 500 副图像,构成的特征向量矩 500×4 . 使用最近邻法、SVM+RBF 和 SVM+Linear 三种方法进行自动分类、标记.分类后与专家

标记的极光图像类型进行比对,正确率如表 2.

表 2 6 组原始图像特征分类正确率对比 (%)

Table 2 Accuracy of original images classification (%)

Group	NN	SVM+RBF	SVM+Linear
1	64.75	75.05	73.21
2	63.75	79.20	75.47
3	61.00	87.61	75.26
4	60.50	80.22	77.07
5	62.00	82.83	80.86
6	64.75	75.47	73.28
Average	62.79	80.06	75.86

从实验结果可看出,对于从原图直接提取的特征来说,使用 SVM+RBF 方法进行分类的效果最好、达到 80.06%,6 组数据的平均分类正确率要比最近邻法高出约 17 个百分点,比 SVM+Linear 高出约 4 个百分点.

4.3 MCA 分离后纹理部分特征的分类结果

对于 MCA 剥离出来的高频纹理部分再次提取特征构建特征向量矩阵.三种分类器的分类结果如表 3.

表 3 MCA 分离后高频纹理部分的分类正确率 (%)

Table 3 Accuracy of texture part classification (%)

Group	NN	SVM+RBF	SVM+Linear
1	68.25	86.44	83.85
2	75.50	88.06	87.67
3	72.25	87.63	85.49
4	82.75	90.87	88.68
5	88.00	93.68	92.45
6	68.00	88.04	84.27
Average	75.79	89.12	87.07

MCA 分离后的高频纹理部分所提取的特征使用三个分类器分类后比较发现:SVM+RBF 和 SVM+Linear 的分类结果都很好,二者大概相差两个百分点,但都要比最近邻法高出约十几个百分点.

4.4 对比实验结果

表 4 说明对原图提取的特征和经过 MCA 分离后纹理部分提取的特征在使用相同的三种分类器进行实验比较后,发现同一种分类器的分类正确率都提高了约 10 个百分点.对照图 4(a)~(c)和(d)~(f)可以很明显的看出,经过 MCA 分离后的图像纹理(见图 4(b)、(e))明显比原图(见图 4(a)、(d))的

表 4 原图分类正确率与 MCA 分离后分类正确率比较 (%)

Table 4 Accuracy comparison between original image and texture part using MAC (%)

	Original image	MCA	Increase
NN	62.79	75.79	13.00
SVM+RBF	80.06	89.12	9.06
SVM+Linear	75.86	87.07	11.21

纹理更加清晰,也更加利于特征的提取,分类效果也更加好.三种分类器对比实验结果说明 SVM+RBF 和 SVM+Linear 分类效果都明显优于最近邻法.

4.5 SVM+RBF 与 SVM+Linear 分类耗时比较

由于全天空摄像机每年捕捉到大量的极光图像,为了确定更适合于海量极光图像的分类器,还需要比较 SVM+RBF 和 SVM+Linear 的其他性能,最重要的一项就是分类耗时.在硬件设备 CPU 是 Intel Pentium4 主频 3.06 GHz、内存 1 G 的计算机上对 6 组数据分别使用 SVM+RBF 和 SVM+Linear 进行分类,这两个分类器完成分类所需时间如表 5.

表 5 SVM+RBF 和 SVM+Linear 分类耗时比较(s)

Table 5 Classification time elapsed of SVM+RBF and SVM+Linear(s)

Group	SVM+RBF	SVM+Linear
1	85.25	2.15
2	69.36	2.84
3	71.01	3.87
4	63.62	2.92
5	45.50	2.56
6	88.44	3.81
Average	70.53	3.03

虽然 SVM+RBF 的分类正确率略比 SVM+Linear 要高一些,但是从表 5 可看出 SVM+RBF 的分类耗时明显比 SVM+Linear 高出很多.用公式(正确率/分类耗时)来衡量,SVM+Linear 的整体性能最好.

5 结论

本文提出了一种基于 MCA 和 SVM 的静态极光图像分类算法.该算法根据静态极光图像由纹理和平滑这两种不同的形态所组成这一特点,使用 MCA 将极光原图分离成形态不同的两个部分.

为验证实验的有效性,对原图与经过 MCA 分离后得到的纹理分别提取特征形成特征向量.使用三种不同分类器对每组 500 个样本、共 6 组实验数据进行分类比较,对比分类正确率和分类器分类耗时等指标,实验证明:与传统方法比较,使用 MCA 分离后的图像的分类正确率均提高约 10 个百分点;另外,与 SVM+RBF 相比,SVM+Linear 分类器的

耗时最少,更适合于海量极光图像的分类.

后续工作包括将静态冕状极光图片进行聚类及聚类有效性分析、动态极光视频序列的语义分析等,这些工作都是建立在本文静态极光图像自动分类的基础之上的.

参考文献

- [1] HU Z J, YANG H G, AI Yong, *et al.* Multiple wavelengths observation of dayside auroras in visible range—a preliminary result of the first wintering aurora observation in Chinese Station at Ny-(A) lesund [J]. *Chinese Journal of Polar Research*, 2005, **17**(2):107-114.
胡泽骏,杨惠根,艾勇,等.日侧极光卵的可见光多波段观测特征-中国北极黄河站首次极光观测初步分析[J]. *极地研究*, 2005, **17**(2):107-114.
- [2] STORMER C. *The polar aurora*[M]. Oxford:Clarendon Press, 1955.
- [3] SYRJASUO M T, DONOVAN E F, QIN X, *et al.* Automatic classification of auroral images in substorm studies[C]//Proc Eight International Conference on Substorms (ICS8), University of Calgary, Alberta, Canada, 2007:309-313.
- [4] BOBIN J, STARCK J-L, FADILI J, *et al.* Morphological component analysis: an adaptative thresholding strategy[J]. *IEEE Transactions on Image Processing*, 2007, **16**(11):2675-2681.
- [5] STARCK J-L, ELAD M, DONOHO D L. Image decomposition via the combination of sparse representation and a variational approach[J]. *IEEE Transaction on Image Processing*, 14, 10, 2005, **14**(10):1570-1582.
- [6] LIU Sheng-peng, FANG Yong. A contourlet domain image denoising method based on mathematical morphology[J]. *Acta Photonica Sinica*, 2008, **37**(1):197-201.
刘盛鹏,方勇.基于数学形态学的 Contourlet 变换域图像降噪方法[J]. *光子学报*, 2008, **37**(1):197-201.
- [7] GONZALEZ R C, WOODS R E. *Digital Image Processing*[M]. 2nd ed. Prentice Hall, 2002:666-668.
- [8] ZHANG Zhi-an, FENG Hong-wei. A new retrieval algorithm based on the texture-spatial feature[J]. *Acta Photonica Sinica*, 2008, **37**(2):400-404.
张志安,冯宏伟.一种新的基于纹理和空间分布特征的图像检索[J]. *光子学报*, 2008, **37**(2):400-404.
- [9] XIONG Yu-hong, WEN Zhi-yu, CHEN Gang, *et al.* Spectral multi-component analysis based on wavelet transform and support vector machine[J]. *Acta Photonica Sinica*, 2005, **34**(10):1514-1517.
熊宇虹,温志渝,陈刚,等.基于小波变换和支持向量机的光谱多组分分析[J]. *光子学报*, 2005, **34**(10):1514-1517.
- [10] BAI Peng, LI Yan, ZHANG Bin, *et al.* Key technologies research of mixture gas infrared spectrum analysis based on SVM[J]. *Acta Photonica Sinica*, 2008, **37**(3):566-572.
白鹏,李彦,张斌,等.基于 SVM 的混合气体红外光谱分析关键技术研究[J]. *光子学报*, 2008, **37**(3):566-572.

Static Aurora Images Classification Based on Morphological Component Analysis

FU Rong^{1,2}, LI Jie¹, GAO Xin-Bo¹

(1 School of Electronic Engineering, Xidian University, Xi'an 710071, China)

(2 School of Computer Science, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract: In order to resolve the problem incurred by low efficient manual classification of tremendous aurora images, an automatic aurora images classification system for huge dataset application is proposed. First, static aurora images are decomposed into texture part and cartoon part with a method called Morphological Component Analysis (MCA). Then features extracted from texture part are classified by three classification methods: nearest neighbor (NN), Support Vector Machine (SVM) with RBF kernel and SVM with linear kernel. The experiment results exhibit that the classification accuracy improved by 10%, of which, the SVM with linear kernel is much faster and is therefore suitable for massive data processing.

Key words: Image classification; Morphological Component Analysis (MCA); Support Vector Machine (SVM); Diurnal corona aurora



FU Rong was born in 1977. She is currently pursuing the Ph. D. degree, and her research interests focus on image processing and pattern recognition.



GAO Xin-bo was born in 1972. He is a professor of pattern recognition and intelligent system, and his research interests focus on computational intelligence, machine learning, computer vision, pattern recognition and artificial intelligence.