

# 结合样本选择和 AdaBoost 的 日侧冕状极光检测算法

高凌君 高新波 梁继民

(西安电子科技大学电子工程学院, 西安 710071)

**摘要** 日侧冕状极光是太阳风与地球磁层相互作用产生的典型电离层踪迹, 对其正确分类对研究空间天气活动尤为重要。根据冕状极光的形态特征, 提出了一种基于静态图像分类的日侧冕状极光检测算法。首先提取极光样本图像的 Gabor 特征, 利用  $K$  均值聚类算法进行基于有监督聚类的训练样本选择, 保证训练样本的多样性和代表性。然后引入 AdaBoost 算法进行特征选择并构建级联分类器实现日侧冕状极光的检测。在北极黄河站采集到的实测极光图像数据库上所做的分类实验结果表明了算法的有效性。

**关键词** 日侧冕状极光 Gabor 特征 AdaBoost 算法  $K$  均值聚类

中图分类号: TP391.4 文献标志码: A 文章编号: 1006-8961(2010)01-0116-06

## Dayside Corona Aurora Detection Based on Sample Selection and AdaBoost Algorithm

GAO Ling-jun, GAO Xin-bo, LIANG Jimin

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

**Abstract** Dayside corona aurora is the typical ionosphere track generated by the interaction of solar wind and magnetosphere, and the detection of corona aurora is significant to the study of space weather activity. According to the appearance feature of corona aurora, an algorithm based on static image classification is proposed to detect dayside corona aurora. At first, Gabor features are extracted from original aurora images. Then, supervised  $K$  means clustering is proposed to select training samples for the sake of their diversity and representative. AdaBoost algorithm is used to select features and build cascade classifiers to implement the detection of dayside corona aurora. The experimental results on the real aurora image database from Chinese Arctic Yellow River Station illustrate the effectiveness of the proposed algorithm.

**Keywords** dayside corona aurora, Gabor features, AdaBoost algorithm,  $K$  means clustering

## 0 引言

太阳喷射出的带电粒子形成的太阳风撞击地球磁场, 沿着地磁力线沉降, 进入地球的两极地区后会发出光芒, 从而形成极光现象。极光的色彩、亮度千变万化, 往往成片出现, 带有射线状、块状、帷幔状的小尺度

分离结构。这些形状、位置和亮度变化非常迅速的极光结构对应着各异的磁层边界层动力学过程, 对研究空间天气及太阳风-磁层耦合极为重要。

日侧冕状极光<sup>[1-2]</sup>是磁中午附近出现的一种主要极光形态, 能反映太阳风-磁层在日侧相互作用的各种动力学过程, 以及作为空间天气活动的指示器。因此研究各类日侧冕状极光对分析电离层不均匀体

基金项目: 国家自然科学基金项目 (60702061, 60872154); 中国气象局公益性行业 (气象) 科研专项经费资助 (GYHY200706043)

收稿日期: 2008-07-15 改回日期: 2008-08-24

第一作者简介: 高凌君 (1984—), 女。现为西安电子科技大学信号与信息处理专业硕士研究生。主要研究方向为智能信息处理、模式识别方向。E-mail: sally\_511@126.com

的形态和动态特征具有重要意义。要研究日侧冕状极光空时分布及其综观特征, 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, 实现日侧极光的自动分类。图 1 所示为几种常见的极光形态。

早期的极光分类研究只是建立在肉眼观察上的手工标记和分类: 1955 年, Stomer 将极光分成放射状结构、无放射状结构, 以及火焰状 3 个大类<sup>[3]</sup>, 同时对这 3 个大类进行了详细的划分, 开创了极光分类的先河。1964 年, Akasofu 将极光基于过程分为赤道向扩展、点亮、西行浪涌、赤道向恢复等不同的类型<sup>[4]</sup>。1999 年, 胡红桥等人将极光分为 4 个类型来进行分析, 分别为具有射线状结构的冕状极光、带状极光、极光浪涌以及向日极光弧等<sup>[5]</sup>。直到 2004 年, Syrjäsuo 才利用图像处理中的技术对夜侧极光进

行了自动分类研究<sup>[6]</sup>, 但其方法只是对有固定形状的极光图像 (例如弧状) 较为有效。目前, 对于形态、动态极为复杂、至今仍无清晰特征描述的日侧冕状极光的自动分类的研究尚未见报道。

众所周知, Gabor 小波<sup>[7]</sup> 具有良好的尺度和方向的分析性能, 能够较好地描述生物视觉神经元的感受视野, 还可以根据特定的视觉需要相应地调整它的空间频率特性。而冕状极光表现出大量的放射线状结构, 具有明显的尺度性和方向性, 因此, Gabor 小波适合用于类似于冕状极光的 multidirectional texture images 的分析与处理。为了保证训练样本的代表性和多样性, 提出了一种基于有监督聚类的样本选择方法, 并使用选择出的训练样本构建基于 AdaBoost<sup>[8-10]</sup> 算法的分类器以实现日侧冕状极光的自动检测。




图 1 常见的日侧冕状极光形态

Fig 1 Typical shapes of dayside aurora

## 1 极光图像的 Gabor 特征提取

为了实现极光图像的自动分类, 就需要提取图像的分类特征。这里利用 Gabor 变换提取极光图像的尺度和方向的纹理特征, 将每幅图像映射为特征空间中的一点。由于原始图片中边缘处有灯光等干扰, 所以需要原始图片进行适当的剪裁。此外, Gabor 特征在本质上依赖于图像灰度在空间上的分布, 因此需要对极光图像进行位置校准、光线归一化等预处理。从全天空摄像机中得到的原始极光图片的大小为  $512 \times 512$  像素, 保留最大可能的极光范围得到预处理后的图片大小为  $384 \times 384$  像素。

Gabor 滤波器具有良好的多尺度特性和方向特性, 能兼顾信号在时域和频域中的分辨能力, 所以近年来广泛应用于人脸识别<sup>[9-11]</sup>、纹理分割<sup>[12]</sup>、指纹鉴别<sup>[13]</sup>等领域。传统的 2 维 Gabor 滤波器在时间与频率上定义为

$$\phi_{u,v}(z) = \frac{\|k_{u,v}\|^2}{\sigma^2} \cdot \exp\left[-\frac{\|k_{u,v}\|^2 \|z\|^2}{2\sigma^2}\right] \times \left| \exp(ik_{u,v}z) - \exp\left[-\frac{\sigma^2}{2}\right] \right|$$

式中,  $k_{u,v} = k_v e^{i\phi_u}$ ,  $k_v = k_{\max} f_v$  表示 Gabor 滤波器的尺度,  $v$  控制着滤波器的尺度变换;  $\phi_u = u\pi/8$ ,  $\phi_u \in [0, \pi)$  表示滤波器的方向,  $u$  控制着滤波器的方向变换。

$v$  个尺度和  $u$  个方向所构成的所有滤波器组, 称为全局 Gabor 滤波器组。由上述可知, Gabor 滤波器特性由尺度  $v$  和方向  $u$  决定, 那么选取一系列尺度和方向就可以得到一组 Gabor 滤波器组。选取参数设置如下: 5 个尺度  $v \in \{0, 1, 2, 3, 4\}$ , 8 个方向  $u \in \{0, 1, 2, 3, 4, 5, 6, 7\}$ , 其他的参数设置<sup>[14]</sup> 为  $\sigma = 2\pi$ ,  $k_{\max} = \pi/2$  以及  $f = \sqrt{2}$ 。图 2 所示为此 5 个尺度, 8 个方向的 Gabor 滤波器组的实部。

预处理后的图像大小为  $384 \times 384$  像素, 那么使用 40 个 Gabor 滤波器对一幅极光图片滤波 (如图 3) 后得到的特征维数为  $40 \times 384 \times 384$  计算量很大。由于 Gabor 特征在相邻像素间是高度相关和冗




图 2 5×8 的 Gabor 滤波器组实部图

Fig. 2 Real parts of the Gabor filters with five scales and eight orientations




图 3 极光图像的 Gabor 特征

Fig. 3 Gabor feature for one aurora image

余的, 所以通常只要稀疏的提取部分节点上的 Gabor 特征即可。采用 11 行 11 列规则分布的采样点, 在采样点上提取各个滤波器输出的值, 联合起来组成列向量, 从而每一幅极光图像得到了  $40 \times 11 \times 11 = 4840$  维的 Gabor 特征向量。

## 2 基于 AdaBoost 的极光分类

基于 Gabor 特征的极光分类系统的流程如图 4 所示, 主要分为特征提取、样本选择以及分类器构建 3 个子过程。

### 2.1 样本选择

由于冕状和弧状两类极光样本的类内多样性大, 而且两类极光之间交叉分布, 可分性差。在这种情况下, 随机挑选训练样本就无法保证样本的代表性和多样性, 从而影响了分类器的泛化能力。为了解决这个问题, 提出一种基于有监督聚类的样本选择方法, 为

分类器提供有效多样化的学习样本。

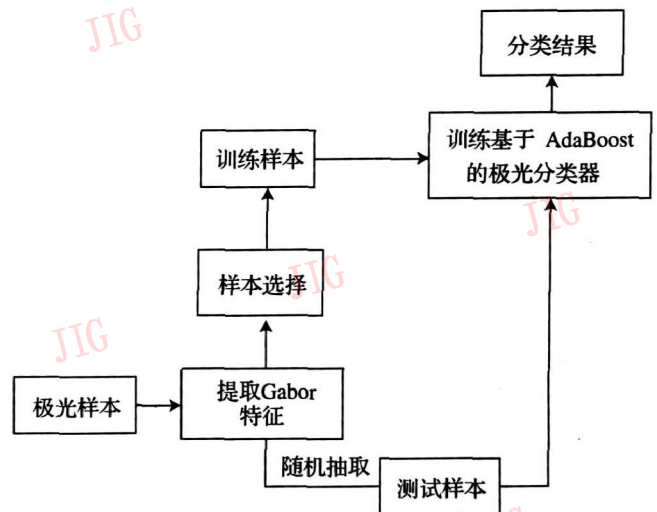


图 4 基于 Gabor 特征的极光分类系统的流程

Fig. 4 Flow chart of Gabor-based aurora classification system

基于有监督的样本选择算法概括如下:

1) 利用原子聚类方法, 如  $K$  均值算法对训练样本集  $T_s = T_s^c \cup T_s^a$  (其中  $T_s^c$  和  $T_s^a$  分别为冕状和弧状极光子集) 进行  $K$  划分。

$$T_s = T_s^1 \cup T_s^2 \cup \dots \cup T_s^K$$

$$T_s^i \cap T_s^j = \emptyset, i \neq j$$

2) 分别统计每个子集  $T_s^i (i = 1, 2, \dots, k)$  中冕状和弧状极光的样本数

$$n_c^i = |T_s^i \cap T_s^c|$$

$$n_a^i = |T_s^i \cap T_s^a|$$

其中,  $|\bullet|$  表示集合的势, 即集合中元素的个数。

3) 在每个子集中随机抽取  $p\%$  的样本作为分类器的学习样本  $L_s^i$ ,  $\gamma$  为常数抽取比例因子 ( $\gamma \in [0, 100]$ ), 用于控制实际训练样本数的选取。

$$p = \gamma \cdot \frac{\min\{n_c^i, n_a^i\}}{\max\{n_c^i, n_a^i\}}$$

4) 得到最终的学习样本集  $L_s = \bigcup_{i=1}^K L_s^i$ 。

如果某个子集  $T_s^i$  中有两类极光样本的数目相当时, 说明此集中样本区分难度大, 则应该选择更多的学习样本, 即对应得到的算法第 3) 步中的  $p$  值较大。反之, 如果某类极光样本较多, 那么说明此集中样本区分难度不大, 则选择相对较少的学习样本就可以了, 对应计算得到的  $p$  值较小。从算法中得知, 为了保证每个子集的样本的均质性,  $K$  需要取比较大的值 (比如  $K = 20$ )。

### 2.2 训练基于 AdaBoost 的极光分类器

AdaBoost 算法是利用大量的分类能力较弱的分类器通过集成的方法提升为分类能力很强的强分类器。所谓弱分类器, 就是只要其分类性能达到大于 50% 就可以了。理论证明, 只需每个弱分类器分类能力比随机猜测要好, 当弱分类器的数目趋向于无穷时, 强分类器的错误率将趋于零, 并具有很好的泛化能力。其基本思想为给训练集中的每个样本对应的权重, 初始时各样本的权重相同, 每一轮循环在弱分类器中选出在当前权重分布下具有最好分类效果的分器 (特征), 然后根据其分类结果更新权重 (将被分错的样本权重增加, 那么下一轮训练的重点就在于挑选可以把前几轮中分错的样本分对的分器), 再进入下一轮训练。最后将每一轮中选择出的弱分类器按照一定的权重结合, 构建出强分类器。

将 AdaBoost 算法用于极光分类中时, 从大量的训练样本中抽取一维简单特征构建弱特征分类器。这些弱特征分类器都有一定的冕状极光与弧状极光

的区分性。那么最后构建出的强分类器就可以进行最终的极光分类。概括起来, 基于 AdaBoost 的阶段分类器训练过程如下:

1) 给定训练集  $L = \{(x_i, y_i)\}, i = 1, \dots, N, y_i \in \{1, 0\}$  是  $x_i$  的表示;

2) 初始化权值:  $w_{1i} = \frac{1}{N}$ , 其中  $N$  是样本的总数;

3) For  $t = 1, \dots, T$  ( $T$  为最终选择的特征总数):

$$\text{规范化权值: } w_{ti} \leftarrow \frac{w_{ti}}{\sum_{j=1}^n w_{tj}}$$

针对每一个特征  $j$  训练  $h_j$ , 其错误率

$$\epsilon_j = \sum w_i |h_j(x_i) - y_i|$$

更新权值:  $w_{t+1i} = w_t \beta_t^{-|h_j(x_i) - y_i|}$ , 其中

$$\beta_t = \frac{\epsilon_t}{1 - \epsilon_t}$$

4)  $T$  个特征弱分类器构造的强分类器:

$$h(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{其他} \end{cases}$$

其中,  $\alpha_t = \log \frac{1}{\beta_t}$ 。

## 3 实验结果与分析

首先, 为了测试本文提出的日侧冕状极光检测的有效性, 设计一个测试实验。选用来自北极黄河站采集的实测极光数据中的 3 233 幅样本进行实验。在选择训练样本时,  $K$  均值聚类中的聚类中心个数  $K$  值分别取  $\{5, 10, 15, 20, 25, 30, 40, 50\}$ , 也就是把整个样本集聚成了  $K$  类, 然后按照聚类所得的  $K$  个簇进行有监督训练样本选择。此外, 在 3 233 幅图片中随机抽取对比训练样本, 样本数为上面得到的样本数的平均值。测试样本为在 3 233 幅图片中随机选取的 500 幅极光图片。比较 10 次实验的平均识别率。实验运行环境为 Pentium 4 2.8GHZ 的 PC 机。

为了验证 AdaBoost 算法构建的分类器的有效性, 采用  $k$ -NN ( $k$ -nearest neighbor) 在同样的样本集上进行分类。其中,  $k$ -NN 分类器使用的距离测度分别为街区 (Cityblock) 距离和欧几里德 (Euclidean) 距离, 这里选取的  $k$  值分别为  $\{1, 3, 5, 7\}$ 。表 1 比较了这两种分类器对样本的 Gabor 特征的分类效果。

表 1 采用不同算法得到的分类效果

Tab 1 Classification results using different methods

		K								/%
		Random	5	10	15	20	25	30	40	
AdaBoost		78.06	81.62	81.36	81.90	82.46	81.98	80.44	80.04	78.58
	1	68.70	71.58	72.36	72.44	73.60	71.48	70.20	70.60	69.38
Euclidean	3	58.14	60.60	61.42	60.82	61.56	60.12	59.54	59.48	58.46
	5	53.88	55.42	55.72	55.42	57.22	55.92	55.70	54.38	54.68
	7	51.84	52.66	53.50	52.70	54.78	53.62	53.66	51.84	52.68
k-NN	1	70.48	71.66	73.60	72.32	73.78	70.80	71.06	69.78	69.76
	3	59.66	60.22	62.52	60.66	62.48	59.96	60.26	59.66	59.34
Cityblock	5	55.84	56.54	58.44	56.54	59.06	56.10	56.88	55.44	57.48
	7	53.82	55.66	57.08	54.72	56.24	54.42	55.54	53.94	54.92

从表 1 中可以看出,使用街区距离构建的  $k$ -NN 分类器的分类效果略好于使用欧氏距离构建的  $k$ -NN 分类器,而且这两种测度最好的分类效果都是  $k=1$ ,也就是最近邻得到。而由 AdaBoost 算法构建的分类器的分类正确率比  $k$ -NN 分类器设置在最佳分类状态 (Cityblock,  $k=1$ ) 时高了近 10 个百分点,这说明 AdaBoost 在 4 840 维的特征中可以挑选出有效的特征,构建出有着较高分类性能的分类器。

聚类中心个数为 20 的时候,AdaBoost 极光分类器获得了最好的分类正确率,达到了 82.46%,比随机选取训练和测试样本的分类正确率多了 4 个多百分点。同时,当  $K = \{5, 10, 15, 25, 30, 40, 50\}$  时的分类正确率比随机选取训练和测试样本的分类正确率平均高了 2 个多百分点。这说明使用  $K$  均值聚类挑选样本可以比较有效地保证训练和测试样本的多样性,从而使得分类器的构造更加适用于复杂的样本分布情况。

同时,使用  $K$  均值聚类挑选样本对于  $k$ -NN 构建的分类器的有效性也有明显的提高。只考虑效果最好的最近邻情况,当  $K = \{5, 10, 15, 20, 25, 30, 40, 50\}$  时,使用欧氏距离的  $k$ -NN 分类器效果均好于未使用  $K$  均值聚类的  $k$ -NN 分类器;当  $K = \{5, 10, 15, 20, 25, 35, 40\}$  时,使用街区距离的  $k$ -NN 分类器效果好于未使用  $K$  均值聚类的  $k$ -NN 分类器。其中聚类中心为 20 时的  $k$ -NN 分类器比随机选择样本时提高了 5 个 (Euclidean) 和 3 个 (Cityblock) 百分点的识别率。进一步的说明了本文所提出的基于有监督聚类的样本选择的有效性。

## 4 结 论

本文提出了一种基于 Gabor 特征的日侧极光分类算法。大量测试实验获得了不错的分类效果。目前对极光的分类仍处于探索阶段,对于冕状极光的分类更是在尝试的过程当中。后续工作包括将静态极光图片的分类算法及流程应用于动态极光视频序列,并提高算法的实时性。本文中提出的分类算法及流程也可以推广到海洋大气的数据分析中。

## 参考文献 (References)

- [1] Yang H G, Sato N, Makita K, et al. Synoptic observations of auroras along the postnoon oval: A survey with all-sky TV observations at Zhongshan, Antarctica [J]. Journal of Atmospheric and Solar-Terrestrial Physics, 2000, 62(9): 787-797.
- [2] Hu Z J, Yang H G, Ai Y, et al. Multiple wavelength observation of dayside auroras in visible range-A preliminary result of the first wintering aurora observation in Chinese Arctic 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]
- [3] Stomer C. The Polar Aurora [M]. Oxford, United Kingdom: Clarendon Press, 1955.
- [4] Akasofu S I. The development of the auroral substorm [J]. Planetary and Space Science, 1964, 12(4): 273-282.
- [5] Hu H Q, Liu R Y, Wang J F, et al. Statistic characteristics of the aurora observed at Zhongshan Station, Antarctica [J]. Chinese

- Journal of Polar Research, 1999, 11(1): 8-18 [胡红桥, 刘瑞源, 王敬芳等. 南极中山站极光形态的统计特征 [J]. 极地研究, 1999, 11(1): 8-18 ]
- [ 6 ] Syrjäsuo M T, Donovan Q in X, et al Automatic classification of auroral images in substom studies [ C ] // Proceeding of the 8th International Conference on Substoms Calgary, Alberta Canada University of Calgary, 2007: 309-313
- [ 7 ] Lee T S Image representation using 2D Gabor wavelets [ J ]. IEEE Transactions on Patten Analysis and Machine Intelligence, 1996, 18(10): 959-971
- [ 8 ] Viola P, Jones M. Robust real-time object detection [ J ]. International Journal of Computer Vision, 2002, 57(2): 137-154
- [ 9 ] Yang P, Shan S G, Gao W, et al Face recognition using adaboosted Gabor features [ C ] // Proceeding of the 6th IEEE International Conference on Automatic Face and Gesture Recognition Seoul Korea, 2004: 356-361.
- [ 10 ] Zhou M, Wei H. Face verification using Gabor wavelets and adaboost [ C ] // Proceeding of the 18th IEEE International Conference on Patten Recognition Hong Kong China, 2006: 404-407.
- [ 11 ] Liu C J Gabor based kernel PCA with fractional power polynomial models for face recognition [ J ]. IEEE Transactions on Patten Analysis and Machine Intelligence, 2004, 26(5): 572-581.
- [ 12 ] Krnizinga P, Petkov N, Grigorescu S. Comparison of texture features based on Gabor filters [ J ]. IEEE Transactions on Image Processing, 2002, 11(10): 1601-1671.
- [ 13 ] Chen D H, Guo L, Li H. Gabor filter enhancement algorithm based on binarization fingerprint image [ J ]. Computer Engineering and Applications, 2007, 43(29): 4-7. [陈大海, 郭雷, 李海. 基于二值指纹图像的 Gabor 滤波增强算法 [ J ]. 计算机工程与应用, 2007, 43(29): 4-7.]
- [ 14 ] Wiskott L, Fellous J, Krüger N, et al Face recognition by elastic bunch graph matching [ J ]. IEEE Transactions on Patten Analysis and Machine Intelligence, 1997, 19(7): 775-779.