一种基于形态特征的极光自动分类方法

杨秋菊^{1*}, 胡泽骏²

1. 陕西师范大学物理学与信息技术学院, 西安 710119;

2. 中国极地研究中心国家海洋局极地科学重点实验室, 上海 200136

* E-mail: yangqiuju@snnu.edu.cn

收稿日期: 2016-08-14; 接受日期: 2016-10-09; 网络版发表日期: 2017-01-06

国家自然科学基金项目(批准号: 41504122, 41274164, 41431072)、陕西省自然科学青年人才项目(编号: 2016JQ4001)、陕西省高校科协青年人才托举计划项目(编号: 20160211)、中央高校基本科研业务费专项基金项目(编号: GK201503020)、南北极环境综合考查与评估专项项目(编号: CHINARE2016-02-03, CHINARE2016-04-01)和浦东新区科技发展基金项目(编号: PKJ2013-z01)资助

摘要 极光是磁层与电离层-热层复杂相互作用的直观表现, 对极光进行合理分类有助于了解极光发生机制及其与磁层边界层动力学过程之间的相互关系. 面对逐年增长的海量极光数据, 亟需自动的极光分类方法. 本文基于韦伯局部描述符(WLD)提出了一种极光图像描述方法, 该方法能表征全天空极光图像的纹理、形状和亮度等形态特征. 基于该方法, 对2003~2009年北极黄河站越冬观测的4种日侧极光类型进行自动分类. 在2003年8001幅典型极光图像上, 与人工标记对比分类准确率高达94.8%, 高于其他同类方法; 对2004~2009年越冬观测数据进行自动识别, 获得4种极光类型的发生分布与日侧极光的多波段能量分布一致. 实验结果表明本文方法能有效用于极光图像表征, 为海量极光图像自动分类提供了一种新方法.

关键词 全天空极光, 形态特征, 自动分类

1 引言

极光现象集中体现了太阳风能量粒子在极区注入的过程, 是日地能量耦合系统中一个重要的物理现象. 极光的形态、光谱、强度和运动等特征与磁层边界层的各种动力学过程紧密相连, 通过对极光现象的观测来研究对应的磁层动力学过程及其极区电离层响应一直是磁层/电离层物理研究中的一种重要手段. 中国不仅在南极中山站、北极黄河站都安装了CCD极光成像仪, 分别对不同尺度和不同波段的极光结构进行观测(刘瑞源和杨惠根, 2011); 近年来还分别与挪

威、冰岛建立了联合观测台站, 实现了极光立体成像观测和夜侧极光观测等. 随着极光观测的常规化和系统化, 由极光图像反演其背后的日地能量耦合过程和地球磁场结构, 成了日地物理学研究的重要课题之一.

极光形态多种多样, 合理的分类研究对了解极光发生机制及其与磁层动力学过程之间的关系非常重要. 虽然极光的研究已有上百年的历史, 人们对于不同极光形态背后的详细物理过程及形成机制的理解还很贫乏(Hultqvist, 2007), 极光分类研究一直在继续. 早在1964年, Akasofu(1964)就曾将夜侧极光基于过程分为赤道向扩展、点亮、西行浪涌和赤道向恢复等

中文引用格式: 杨秋菊, 胡泽骏. 2017. 一种基于形态特征的极光自动分类方法. 中国科学: 地球科学, 47: 252-260, doi: 10.1360/N072016-00060
英文引用格式: Yang Q J, Hu Z J. 2017. An automatic auroral classification method based on morphological characteristics (in Chinese). Scientia Sinica Terrae, 47: 252-260, doi: 10.1360/N072016-00060

4种类型,这一分类研究后来成为了亚暴研究的基础;1998年,Simmons(1998)将极光分为了日侧极光、夜侧极光、分立极光和弥散极光等14种类型;1999年,中国极地研究中心胡红桥等(1999)基于南极中山站的全天空图像,对午后-子夜扇区的极光进行研究,将极光分成了冕状、带状、极光浪涌和向日极光弧4种类型;2000年,Yang等(2000)同样利用南极中山站全天空观测数据,将日侧极光分为了冕状极光和弧状极光两大类;2002年,挪威科学家Sandholt等(2002)利用Ny-Ålesund地区的极光观测数据,将日侧极光分为了极向运动极光结构、多重极光弧和跨极盖极光弧等6种极光类型;2009年,Hu等(2009)利用北极黄河站全天空观测数据,将日侧极光分成了弧状、帷幔冕状、辐射冕状和极光亮斑4种类型,并将各种极光类型与日侧极光卵活动区进行了对应。

以上极光分类研究都是依靠人眼识别来完成,虽然人工分析比较适合研究只有定性描述(没有定量界定)的极光物理问题;但随着极光观测的持续进行,极光图像数据与日俱增。以中国观测台站为例,北极黄河站每年的极光观测期有4个多月,3台CCD成像仪分别对3个波段(427.8、557.7及630.0nm)的极光以10s分辨率同时进行采集,至今已经开展了13年的观测(2003~2015);而南极中山站有4台CCD成像仪分别对4个尺度(磁天顶180°、47°、19°和8°视野)的极光进行观测,每年数据量都在30T以上,从2010年至今也已开展了6年的观测。长期系统的极光观测数据为了解极光发生机制,研究磁层与电离层-热层的复杂相互作用提供了数据保障。但与此同时,海量的数据也给研究带来了难度。如果继续像以往研究一样,在几千万幅极光图像数据中通过人眼识别来进行极光分类研究,其工作量之大将是难以想象的。

事实上,近年来计算机图像处理和模式识别技术已被越来越多的研究人员用来对空间物理中的图像数据进行表征和分析(Jacobs等,2015),已逐渐成为极光分类研究的新手段。早在2004年,Syrjäsuo和Donovan(2004)就将计算机视觉方法引入到极光图像的分类工作中,他们将加拿大CANOPUS项目的全天空极光图像分成了弧形、斑块型、欧米伽型和南北结构型4大类。通过利用极光的区域和颜色信息,Biradar和Pratiksha(2012)设计了一个极光图像自动分类系统,可用于对海量极光图像进行分类。西安电子科技大学和中国极地研究

中心合作,在极光图像自动分类研究上也取得了一些成果: Fu等(2009)利用形态学成分分析方法,把极光图像分成了弧状和冕状两大类; Wang等(2010)基于局部二值模式(LBP)方法,将2004~2009年黄河站越冬观测图像自动分为了弧状、帷幔冕状、辐射冕状和热点状4大类;同样是基于这4种分类机制, Yang等(2012)针对极光活动随时间动态演变的特点,通过结合极光图像帧间时序信息,对极光图像进行自动分类,并在多年数据集上进行了验证;韩冰等人(韩冰等,2013;韩冰和仇文亮,2013)借助显著性编码方法对极光图像进行了分类研究;杨曦等(2013)提出了一种分层小波模型极光图像分类算法。

分析现有研究方法,对极光图像进行自动分类的关键在于有效表征极光图像的形态信息,包括极光的亮度、形状和纹理等表象特征,其根本思想是模仿人的感官去判断,区分不同类型极光图像之间的差异。因此本文将利用从心理学韦伯定律发展而来的一种纹理描述算子WLD(Weber Local Descriptor, 韦伯局部描述符)(Chen等,2010),来表征极光图像的形态信息,然后将获得的极光WLD特征输入到 k -近邻分类器完成极光分类过程。

2 数据和方法

2.1 数据集简介

本文所用数据来自中国北极黄河站2003~2009年越冬观测的全天空成像仪(All Sky Imager, ASI)。该观测时段内,全天空成像仪获得每帧图像的曝光时间为7s,相邻两帧图像之间的时间间隔为10s,每帧图像大小为512×512像素。考虑到427.8nm波段极光激发强度非常微弱,极光图像背景噪声大;而630.0nm波段极光激发过程时间跨度范围大,表现出来的极光形态不够清晰,本文选用557.7nm波段的数据。黄河站地理坐标为(78.92°N, 11.93°E),修正磁纬为76.24°N,磁地方时(MLT)≈世界时(UT)+3.1h(Hu等,2009)。黄河站位于极隙区纬度,非常适合观测日侧极光,因此本文只考虑0600~1800MLT时段的极光数据。为了方便后续操作,我们对原始观测数据进行了以下预处理操作:减去暗电流(全天空图像亮度积累)、图像灰度拉伸(图像由16位灰度图像变为8位)、旋转(旋转后的极光图像磁正北方向朝上)、去边缘噪声和剪裁(去掉形变率大的

圆周边缘, 剪裁后的极光图像大小为 440×440), 详见Wang等(2010).

按照极光形态信息, 参考Hu等(2009)对极光的分类方法, 本文将极光图像分为弧状、帷幔冕状、辐射冕状和热点状4大类, 如图1所示. 其中弧状极光是东西向延伸的、南北窄的条带状极光, 包括单弧和多弧(多条极光弧平行出现); 帷幔冕状极光强度比较弱, 具有清晰射线结构, 常常在东西方向同时出现多条平行射线带; 辐射冕状极光表现为向四周放射性发散的射线结构; 热点状极光形态复杂, 常包含小尺度的极光亮斑结构.

2.2 基于WLD特征的ASI极光图像表征

韦伯局部描述符(WLD)是由Chen等(2010)提出的一个图像局部纹理描述符, 它由差动激励(differential excitation)和方向角(orientation)两个参数组成. WLD的灵感来源于著名的韦伯心理学法则, 其主要内容是说一个刺激(如声音、光照等)的显著变化和该刺激本身之间有一个恒定的比值. 比如, 在一个嘈杂的环境, 一个人必须大声说话别人才能听见, 而在一个安静的房间里, 小声说话其他人就都能知道. 受这个定律的启发, 一幅图像中每个像素点的WLD特征可以由两方面统计得到: 一个是每个像素点本身的像素值, 另一个是该像素点周边区域(如像素点周围的 3×3 区域)的像素值. 该像素点本身的像素值表原始激励, 周边区域像素值表激励的变化, 差动激励可表示二者之间的数值关系. 为了进一步表示该像素点和周边区域像素值之间的关系, 需进一步计算该像素点的上下、左右梯度. 因此, WLD特征需要计算图像中所有像素点的差动激励和方向角. 然后对计算结果量子化, 统计差

动激励和方向角的直方图得到特征向量. 图2给出了极光图像WLD特征提取的全过程.

(1) 差动激励. 差动激励 ε 反映的是当前像素值和其周边区域像素值的差异, 它能模仿人眼视觉找出一幅图像中变化比较明显的区域. 设当前像素点为 x_c , 其差动激励表示为 $\varepsilon(x_c)$. 首先计算 x_c 和周边相邻区域像素点的不同, 如式(1)所示:

$$v_s^{00} = \sum_{i=0}^{p-1} (\Delta x_i) = \sum_{i=0}^{p-1} (x_i - x_c), \quad (1)$$

式中, $x_i (i=0, 1, \dots, p-1)$ 表示当前像素 x_c 的 p 个相邻像素值, 若采用 3×3 的区域, 则 $p=8$. 现在进一步计算 x_c 和 x_i 之间的比值:

$$G_{\text{ratio}}(x_c) = \frac{v_s^{00}}{v_s^{01}}, \quad (2)$$

式中, v_s^{01} 表示 x_c 的像素值, 设 $G_{\text{ratio}}(\cdot)$ 的反正切函数为

$$G_{\text{arctan}}[G_{\text{ratio}}(x_c)] = \arctan[G_{\text{ratio}}(x_c)]. \quad (3)$$

结合式(1)~(3), 可知差动激励 $\varepsilon(x_c)$ 的计算方法为

$$\begin{aligned} \varepsilon(x_c) &= G_{\text{arctan}}[G_{\text{ratio}}(x_c)] = \arctan\left[\frac{v_s^{00}}{v_s^{01}}\right] \\ &= \arctan\left[\sum_{i=0}^{p-1} \frac{x_i - x_c}{x_c}\right]. \end{aligned} \quad (4)$$

由式(4)可知, 若当前点的像素值大于其周围点的像素均值, 即 $\varepsilon(x_c) < 0$, 则表明当前点在该区域亮度较高; 反之, 若 $\varepsilon(x_c) > 0$, 说明周围邻近点的像素值比中心点像素值大(直观上, 中心像素较黑).

(2) 梯度方向角. WLD的梯度方向实质上是图像每个像素点相对于其周围邻近点的梯度方向:

图1 不同类型ASI极光图像举例

$$\theta(x_c) = \arctan\left(\frac{v_s^{11}}{v_s^{10}}\right), \quad (5)$$

式中, v_s^{10} 和 v_s^{11} 分别由中心像素点的上下、左右像素计算得出:

$$v_s^{10} = x_5 - x_1, \quad v_s^{11} = x_7 - x_3. \quad (6)$$

由于方向角反映的是梯度信息, 每个点的梯度取值范围应为 $[0, 2\pi)$, 而由式(5)计算得到的 $\theta(x_c)$ 的取值范围为 $\left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$, 因为必须将其进行扩展至 $[0, 2\pi)$. 设映射 $f: \theta \rightarrow \theta'$, 且 $\theta' = \arctan2(v_s^{11}, v_s^{10}) + \pi$, 其中

$$\arctan2(v_s^{11}, v_s^{10}) = \begin{cases} \theta, & v_s^{11} > 0 \ \& \ v_s^{10} > 0 \\ \pi + \theta, & v_s^{11} > 0 \ \& \ v_s^{10} < 0 \\ \pi - \theta, & v_s^{11} < 0 \ \& \ v_s^{10} < 0 \\ \theta, & v_s^{11} < 0 \ \& \ v_s^{10} > 0 \end{cases}. \quad (7)$$

这样, $\theta \in \left[-\frac{\pi}{2}, \frac{\pi}{2}\right]$, $\theta' \in [0, 2\pi]$. 最后对 θ' 进行量子化:

$$\Phi_t = f_q(\theta') = \frac{2t}{T}\pi, \quad (8)$$

其中:

$$t = \text{mod}\left(\left\lfloor \frac{\theta'}{2\pi/T} + \frac{1}{2} \right\rfloor, T\right). \quad (9)$$

例如, $T=8$, 那么这 T 个主方向为 $\Phi_t = t\pi/4$, $t=0, 1, \dots, T-1$. 换句话说, 那些位于区间 $[\Phi_t - \pi/T, \Phi_t + \pi/T]$ 内的值被量化为 Φ_t .

(3) WLD直方图. 如图2所示, 先使用式(4)计算每个像素的差动激励 $\varepsilon(x_c)$, 同时用式(8)计算每个像素的方向角 Φ_t 并量化, 从而得到差动激励图像和梯度方向图像, 根据这两幅图像计算二维直方图 $\{WLD(\varepsilon_j, \Phi_t)\} (j=0, 1, \dots, M-1; t=0, 1, \dots, T-1)$, 其大小为 $T \times M$, M 是 ε 的区间数, 本文取 $T=8$, $M=6$. 在二维直方图中, 每一列对应的是一个方向角 Φ_t , 每一行对应的是一个差动激励 ε_j . 为了使描述符更具有表征性, $\{WLD(\varepsilon_j, \Phi_t)\}$ 被进一步转换成一维直方图. 如图2所示, 二维直方图的每一行组成一个一维直方图, 按一定顺序把所有 M 个子直方图连接起来, 就形成了最终的一维直方图.

2.3 典型ASI极光图像的WLD特征

根据2.2节描述的方法, 图3给出了图2所示的4幅

典型ASI极光图像的WLD特征. 从图中可以看出, 两类冕状极光的形态特征非常相似, 得到的WLD特征分布也比较接近, 而图2所示的弧状极光和热点状极光都有明显的亮斑结构, 可以看出WLD特征分布也有些类似.

3 ASI极光图像自动分类

为了对极光图像进行分类, 两个最为关键的步骤是: 极光形态表征和分类器设计. 本文采用WLD描述符来对极光图像进行表征并建立了一个分类器系统. 形态表征时, 对任意给定的一幅极光图像, 本文都如图2所示提取WLD直方图, 取 $M=6$, $T=8$, $S=10$, 所以特征长度为 $6 \times 8 \times 10 = 480$, 即每一幅图像都用一个长度为480的向量表征.

本文采用广泛使用的 k -近邻(k -nearest neighbor)分类器来对极光图像进行分类, 并分别取 $k=1$ 和 $k=3$. 即对给定的一幅图像 I , 我们根据与它距离最近的1幅(3幅)图像的类型来估计它的类型, 采用“少数服从多数”的准则, 即与它距离最近的1幅(3幅)图像中大多数是哪种极光类型, 那么该幅图像的类型也一样. 当取 $k=3$ 时, 如果不存在多数类, 则该幅图像被拒识. 为了计算极光 I_1 和 I_2 两幅图像之间的距离, 本文首先计算它们的WLD直方图 H_1 和 H_2 , 然后计算 H_1 和 H_2 的卡方(χ^2)距离:

$$d(I_1, I_2) = \chi^2(H_1, H_2) = \sum_r (H_{1r} - H_{2r})^2 / (H_{1r} + H_{2r}), \quad (10)$$

式中, r 表示特征向量的索引值, $r=1 \sim 480$. 选用卡方距离是因为WLD表征的是直方图向量.

本部分对黄河站2003-12~2004-01期间8001幅图像进行分类实验, 根据Hu等(2009)、Wang等(2010)和Yang等(2012)等文中对极光的分类研究, 本文将此数据库中的极光图像进行了类别标记, 其中弧状极光3934幅, 帷幔冕状1786幅, 辐射冕状1497幅, 热点状极光784幅. 本文采用5重交叉验证实验, 即将数据随机分成5份, 1份用于测试, 4份用于训练分类器. 为减少随机性, 实验重复了200次, 每一轮的数据划分都不一样, 计算平均分类正确率作为评估准则:

$$\text{分类正确率} = \# \text{正确分类} / \# \text{所有图像}. \quad (11)$$

实验结果如图4所示. 图中给出了NN分类器、3NN分类器的平均分类正确率, 并分别计算了NN分类器下弧状极光、帷幔冕状、辐射冕状、热点状极光

图2 ASI极光图像WLD特征提取

图3 图1所示ASI极光图像对应的WLD特征弧

(a) 弧状; (b) 帷幔冕状; (c) 辐射冕状; (d) 热点状

图4 有监督分类结果

各自的分类正确率. Wang等(2010)发现局部二值模式 (Local Binary Pattern, LBP)对ASI极光图像具有良好的

表征能力,因此本文中将WLD特征与LBP特征进行了对比,由图2可以看出, WLD特征比LBP特征具有更好的表征能力,用WLD表征极光时获得了更高的分类准确率. 对比弧状、帷幔冕状、辐射冕状和热点状4类极光的形态结构,弧状极光最简单,热点状最复杂,我们的实验结果也显示,无论是利用WLD表征还是LBP表征,弧状极光的单类分类正确率均最高,热点状最低;而辐射冕状极光里因常会含有一些非常小的亮斑结构,不利于识别,故分类正确率低于帷幔冕状极光.

此外,利用3NN分类器进行极光分类时,可能会出现没有“多数类”存在的情况,即与待分类图像距离最近的3幅图像分属3个不同的极光类型,此时,该图像被“拒识”. 经统计,采用WLD特征时拒识率为0.0097,采用LBP特征时拒识率为0.0123,再一次表明WLD特征具有非常优秀的表征能力,优于LBP特征.

4 2004~2009年黄河站越冬观测ASI极光图像类型分布规律

上述有监督实验所用数据集dataset1只用到了2003~2004年1个越冬数据,而且对数据进行了人工标记.如果要对多年观测数据进行人工标记,其工作量是非常大的.此外,dataset1所有数据均来自同一年的越冬观测,数据之间相关性大.为了进一步验证本文方法的有效性,本部分利用已标记的2003~2004年越冬观测(dataset1)来对2004~2009年越冬观测(未标记)进行分类.测试数据共涉及5个冬季,229天,399628幅

图像,记为dataset2.这是典型的半监督学习的思想,因为对数据进行标记的代价比较高,只有少量带有标记的数据,而大量未标记的数据却很容易得到.在有监督的分类算法中加入无标记样本来实现半监督分类,增强分类效果.self-training(自训练算法)是一种常见的半监督学习算法,本文利用 k -近邻算法($k=3$)来实现.对dataset2中的每一幅图像,寻找其与dataset1中距离最小的 k 幅图像,根据这 k 幅图像的极光类型,采用少数服从多数的策略,进行分类.

图5按照10min一个bin对图像从时间上进行分段划分,分别给出了极光图像数目分布规律(最上面一

图5 极光类型分布规律以及基于WLD特征和基于LBP特征两种分类结果对比

最上面一个子图表各个时刻极光图像的数目,中间4个子图分别表弧状、帷幔冕状、辐射冕状和热点状4类极光类型的分布规律,最底下一个子图表不确定类型的分布情况

个子图)、4种极光类型(中间4个子图)及被“拒识”的不确定类型极光(最底下一个子图)随时间的发生分布率. 为了比较各极光类型所处的极光活动区, 图5顶端用粗虚线加以标识给出了由极光多光谱强度获得的日侧极光的4个活动区域(Hu等, 2009), 并用细虚线标出了正午极隙区的两个状态.

从图5可以看出, 本文按照形态特征定义的4种极光类型分布在极光卵的不同区域, 从分布规律来看, 4种极光类型的分布趋势非常符合日侧极光多波段能量分布结果(Hu等, 2009). (1) 正午附近由于日辉干扰, 极光图像比较少, 午前午后极光图像比较多; (2) 弧状极光发生率最高, 呈午前-午后双峰分布, 且午后极光的发生率高于午前极光; (3) 两类冕状极光形态比较类似, 发生时间也比较接近, 主要出现在1300MLT以前, 只是峰值出现的位置不同, 帷幔冕状极光在整个极光卵M区域发生率都很高, 而辐射冕状极光主要集中在1100~1230MLT时间段; (4) 热点状极光发生率比上述三类极光低很多, 主要出现在极光卵H区域; (5) 本实验的未知类型极光比前一部分有监督实验中的发生率高, 主要原因是dataset2的数据组成和dataset1不同, dataset2未经人工挑选, 有些图像不够典型. 本实验的未知类型图像包括处于过渡状态形态不够典型的极光、被云遮挡的极光等.

对比本文基于WLD特征的分类方法和Wang等(2010)基于LBP特征的方法, 由图5我们可以发现, 两种方法得到的极光类型分布规律非常类似, 主要差别在基于WLD特征的分类方法获得了更多的弧状极光, 而基于LBP特征的分类方法获得了更多的帷幔冕状极光. 这是因为弧状极光常常由帷幔冕状极光过渡而来, 最后又演变成帷幔冕状极光. 处于过渡状态的极光, 形态比较复杂, 多呈现模棱两可的形态特征, 用不同的表征方法得到的极光类型会有所差异.

5 讨论和结论

面对日积月累产生的大量极光数据, 本文提出了一种基于WLD特征的极光图像表征方法, 用来描述极光图像的形状、纹理和亮度等形态特征, 在此基础上利用 k -近邻分类器对极光图像进行自动分类, 并在多年数据集上进行了实验验证. 但是, 由于极光形态特征非常复杂, 人们对其形成机制的理解还很匮乏, 至今尚无明确的极光分类机制. 本文实验均基于一定的数

据标记基础之上, 由于人工标记数据时采用的分类机制来自Hu等(2009), 因此自动分类的结果也与Hu等人的结论进行比较. 通过有监督分类实验的定量比较和半监督识别实验的定性分析, 得出的结果与人工标记和已有结论非常接近, 证明了本文表征方法的有效性.

Hu等(2009)在给出极光分类机制时, 综合了427.8、557.7及630.0nm共3个波段的数据; 本文在进行数据标记时, 也参考了3个波段的数据, 所以, 如果自动分类时能同时利用3个波段的数据, 理论上肯定能提高分类精度. 不过, 加入更多波段的数据, 就有更多的信息需要计算处理, 如何融合3个波段的信息进行分类决策, 是我们下一步要研究的内容.

参考文献

- 韩冰, 杨辰, 高新波. 2013. 融合显著信息的LDA极光图像分类. 软件学报, 24: 2758–2766
- 韩冰, 仇文亮. 2013. 一种特征显著性编码的极光图像分类方法. 西安电子科技大学学报(自然科学版), 40: 180–186
- 胡红桥, 刘瑞源, 王敬芳, 杨惠根, Makita K, 王幸, Sato N. 1999. 南极中山站极光形态的统计特征. 极地研究, 11: 8–18
- 刘瑞源, 杨惠根. 2011. 中国极区高空大气物理学观测研究进展. 极地研究, 23: 241–258
- 杨曦, 李洁, 韩冰, 高新波. 2013. 一种分层小波模型下的极光图像分类算法. 西安电子科技大学学报(自然科学版), 40: 18–24
- Akasofu S I. 1964. The development of the auroral substorm. *Planet Space Sci*, 12: 273–282
- Biradar C, Pratiksha S B. 2012. An innovative approach for aurora recognition. *Int J Eng Res Technol*, 1: 1–4
- Chen J, Shan S G, He C, Zhao G Y, Pietikäinen M, Chen X L, Gao W. 2010. WLD: A robust local image descriptor. *IEEE Trans Pattern Anal Mach Intell*, 32: 1705–1720
- Fu R, Li J, Gao X B, Jian Y J. 2009. Automatic aurora images classification algorithm based on separated texture. *IEEE Int'l Conf on Robotics and Biomimetics (ROBIO)*, 1331–1335
- Hu Z J, Yang H, Huang D, Araki T, Sato N, Taguchi M, Seran E, Hu H, Liu R, Zhang B, Han D, Chen Z, Zhang Q, Liang J, Liu S. 2009. Synoptic distribution of dayside aurora: Multiple-wavelength all-sky observation at Yellow River Station in Ny-Ålesund, Svalbard. *J Atmos Sol-Terrestrial Phys*, 71: 794–804
- Hultqvist B. 2007. Processes in the solar-terrestrial environment, the aurora. In: Kamide Y, Chian A, eds. *Handbook of the Solar-Terrestrial Environment*. Berlin: Springer Press. 334–352
- Jacobs M, Chang L C, Pulkkinen A, Romano M. 2015. Automatic analysis of double coronal mass ejections from coronagraph images. *Space*

- [Weather](#), 13: 761–777
- Sandholt P E, Carlson H C, Egeland A. 2002. Dayside and Polar Cap Aurora. Amsterdam: Kluwer Academic Publish
- Simmons D. 1998. A classification of auroral types. *J Brit Astron Assoc*, 108: 247–257
- Syrjäsuo M T, Donovan E F. 2004. Diurnal auroral occurrence statistics obtained via machine vision. *Ann Geophys*, 22: 1103–1113
- Wang Q, Liang J M, Hu Z J, Hu H H, Zhao H, Hu H Q, Gao X B, Yang H G. 2010. Spatial texture based automatic classification of dayside aurora in all-sky images. *J Atmos Sol-Terrestrial Phys*, 72: 498–508
- Yang H G, Sato N, Makita K, Kikuchi M, Kadokura A, Ayukawa M, Hu H Q, Liu R Y, Häggström I. 2000. Synoptic observations of auroras along the postnoon oval: A survey with all-sky TV observations at Zhongshan, Antarctica. *J Atmos Sol-Terrestrial Phys*, 62: 787–797
- Yang Q J, Liang J M, Hu Z J, Zhao H. 2012. Auroral sequence representation and classification using hidden markov models. *IEEE Trans Geosci Remote Sens*, 50: 5049–5060