

# 基于深度学习的极光序列自动分类方法

张浩\*\*, 陈昌红\*

南京邮电大学通信与信息工程学院, 江苏 南京 210003

**摘要** 提出一种基于深度学习的极光序列分类方法,有效结合卷积神经网络(CNN)特征丰富的空间域信息和长短时记忆(LSTM)网络捕捉序列信息的优势,并利用极光的属性对CNN添加反馈约束调节使特征更契合极光图像。在中国北极黄河站的全天空成像仪(ASD)极光图像数据库上进行有监督的极光序列分类研究和无监督的极光事件检测,实验结果表明本文方法能有效用于极光序列的表征,为海量极光序列的自动分类提供了可能性。

**关键词** 机器视觉; 极光序列分类; 卷积神经网络; 长短时记忆网络; 属性

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.111504

## Aurora Sequence Classification Based on Deep Learning

Zhang Hao\*\*, Chen Changhong\*

College of Communication and Information Technology, Nanjing University of Posts and  
Telecommunications, Nanjing, Jiangsu 210003, China

**Abstract** An aurora sequence classification method based on deep learning is proposed. It combines the rich spatial domain information and the sequence information corresponding to the advantages of convolutional neural network (CNN) features and long short-term memory (LSTM) network. In addition, aurora attributes employed as feedback constraints to the CNN make features more suitable for aurora images. Supervised aurora sequence classification and unsupervised aurora event detection are performed on the Chinese Yellow River Station All-Sky Imager (ASI) dataset. The experiment shows that our method can characterize aurora sequences effectively and can be able to implement automatic classification for massive aurora sequences.

**Key words** machine vision; aurora sequence classification; convolutional neural network; long short-term memory network; attribute

**OCIS codes** 150.1135; 100.2960; 350.4600

## 1 引言

极光现象是沿着磁力线运动的高能带电粒子沉降至地球极区磁层时,与高层的大气粒子相互作用产生的一种绚丽的发光现象。极光现象是现在人们唯一所知的一种可以通过肉眼直接看到的极区地球物理现象,是极区日地物理过程(特别是磁层-电离层相互作用)最集中的表现形式,是研究太阳风暴最好的途径。通过对极光的形态特征变化规律的观察和探索,可以得到巨量的关于磁层以及日地间电磁活动的信息。面对观测到的如此庞大的极光图像数据量,依靠人工进行极光分类简直是杯水车薪,所以

如何有效利用这些重要的数据已经成为极光研究人员急待解决的问题。

至今,对极光图像的研究主要集中于两个方面:1)忽略帧间的运动信息,单独地处理极光图像;2)结合时间信息,将极光图像视为连续的序列进行分析。对于前者,已经提出了大量的方法,如分块局部二值模式(LBP)<sup>[1]</sup>、韦伯局部描述符(WLD)<sup>[2]</sup>、显著性编码<sup>[3]</sup>、二维主成分分析网络(2D-PCA)<sup>[4]</sup>等。显然,因为极光是一个不断变化、动态发展的过程,所以结合帧间的运动信息更为合理。Yang等<sup>[5]</sup>考虑极光特征随时间变化特点,结合隐马尔科夫模型(HMM)对极光动态特征进行描述和分类。Xu

收稿日期: 2018-04-15; 修回日期: 2018-05-09; 录用日期: 2018-05-29

基金项目: 国家自然科学基金(61571353)

\* E-mail: chenchh@njupt.edu.cn; \*\* E-mail: ztqp666@outlook.com

等<sup>[6]</sup>紧密联系了上下文信息,基于隐条件随机场模型(HCRF)对极光序列完成了自动分类任务。同年,Han等<sup>[7]</sup>提出了基于环状局部方向模式的弧状极光序列分类,兼顾了局部特征和全局特征并联系了帧之间的关系,对弧状极光进行分类。同年,宋亚婷等<sup>[8]</sup>提出了基于张量动态纹理模型的极光视频分类,该方法引入张量分解,提高了模型效率,完成了对极光序列的分类任务。

深度学习在学习各种海量数据方面有很大优势,可以完全自动地学习到抽象的特征表达,这种特征是更加深层、更加抽象的。深度学习考虑了人对数据可能还没有认知的层面,很多时候可以代替人工设计的特征。卷积神经网络(CNN)<sup>[9]</sup>和长短时记忆(LSTM)网络<sup>[10]</sup>都是成功的网络模型,已经成功应用于行人再识别<sup>[11]</sup>、视频识别<sup>[12-13]</sup>、行人检测<sup>[14]</sup>、跟踪系统<sup>[15]</sup>、红外图像及视频深度估计<sup>[16-17]</sup>等很多场景中。将两者相结合可以发挥更好的效果,途径有两种:1)串行连接方式,将LSTM网络连接在CNN之后,利用LSTM网络分析得到的CNN特征中的时序信息;2)并行连接方式,将LSTM网络和CNN并行结合,分别得到分类预测得分,然后采用融合的方式将得分融合得到网络最终结果并进行分类,融合手段有加法融合<sup>[18]</sup>、最大值融合等。

结合极光数据本身的特点,本文利用CNN与LSTM网络串行结合方式提出一种基于深度学习的极光序列自动分类方法,主要创新如下。1)目前

大多数极光分类算法是基于帧的,很少考虑帧间的动态关系。本文利用LSTM网络在描述变长序列方面的优势,提出一种基于LSTM网络的极光序列建模算法,实现极光序列的分类和极光事件的检测。2)提出一种属性约束CNN提取极光特征。基于对极光图像本身的理解,引入了光斑结构这一属性,在网络中加入新的全连接层,将隐层特征映射至标签空间,利用属性信息通过网络反向传播来调节CNN特征,使得特征既含有局部光斑结构信息,也含有极光图片全局信息。

## 2 基本方法

### 2.1 框 架

结合CNN和LSTM网络两者的优点,实现极光序列的自动分类。网络框架如图1所示,首先将Image-Net数据库<sup>[19]</sup>上预训练过的CNN模型在极光图像数据上进行微调,利用微调过的CNN模型按顺序提取序列中图像的CNN特征,且在此过程中基于极光属性对CNN特征增加了约束反馈调节(后文中将详细描述)。假设整个网络输入是一个极光图像序列 $Q = \{I_1, I_2, I_3, \dots, I_t\} (t=1, \dots, T)$ ,其中 $T$ 为序列帧长,此时分别得到帧级别的特征 $x_t$ 。为了得到一个序列级别的特征向量来分别表达每一个序列的变化信息,利用LSTM网络进行时序分析,最终通过softmax层得到各类极光预测概率并取最大值为预测极光类型。




图1 网络框架

Fig. 1 Framework of our method

### 2.2 极光光斑属性

极光被分类为弧状极光、帷幔冕状极光、辐射冕状极光、热点状极光四类<sup>[20]</sup>,这种分类机制也被多次验证并被广泛使用。极光图像分别分布在427.8 nm波段、557.7 nm波段和630.0 nm波段,本文研究的是激发程度适中且成像相对较为清晰的

557.7 nm波段的极光图像。极光形态虽然变化多端,但是四种极光各有特点。1)弧状极光:弧状极光因其出现时间的不同,可分为午前弧状极光和午后弧状极光。此类极光从结构上来说,东西方向较长,南北方向较窄,偶尔会出现螺旋或褶皱。2)帷幔冕状极光:帷幔冕状极光在3个波段激发都很弱,结构

上呈多条东西方向的射线,看起来比较像烟雾。

3)辐射冕状极光:辐射冕状极光在 630.0 nm 波段激发强烈,但在另外两个波段激发较弱。其形态从东南西北四个方向上放出,射线状的线条尤为明显。

4)热点状极光:热点状的结构形态最为复杂,整体呈放射状,且含有明显的不规则亮斑结构。

热点状极光形态尤为复杂,整体呈放射状,且含有明显的不规则亮斑结构,难以分辨。分类的结果一般是热点状极光的分类准确率较低,易将其错分为同样具有射线结构的辐射冕状极光。比较这两种极光可知,辐射冕状极光的光激发效果在 557.7 nm

波段上较弱,不含有明亮的光斑结构或光斑不明显,但是热点状极光在 557.7 nm 波段上激发很强,基本都含有明显且明亮的光斑结构。另外两种极光类型中,弧状极光的形态结构易于区分,从以往的研究中也可看出其分类准确率是最高的,因为弧状极光在 557.7 nm 波段的激发效果较强,含有较明显且明亮的光斑结构;帷幔冕状极光在三个波段上的激发效果都比较弱,所以基本没有光斑结构。图 2 中给出一些范例,可以看到弧状极光和热点状极光的明显光斑结构,而辐射冕状极光和帷幔冕状极光没有明显光斑结构。




图 2 557.7 nm 波段的四类极光图像示例

Fig. 2 Four categories of sample images at 557.7 nm

### 2.3 属性约束 CNN

CNN 基于当前比较流行的 VGG-16 模型,这是由 Simonyan 等<sup>[21]</sup>提出的一个性能优越的深度卷积神经网络模型。VGG-16 网络模型中共包括 13 个卷积层和 3 个全连接层,其中全连接层在整个卷积神经网络中起到分类器的作用。在卷积神经网络中,可以认为卷积层、池化层的操作是想将原始的图片数据映射至隐层特征空间,而最后的全连接层是将前面的网络层中学习到的隐层特征变化映射至样本标签空间。

针对前文描述的光斑属性,提出一种属性约束 CNN 提取极光特征。对于极光图片,光斑属性是一种可以帮助分类的先验知识,且光斑结构这一属性的识别关注的是极光图像的局部特征,而极光类型的识别关注的则是全局特征。所以希望经改进后的 CNN 提取的 CNN 特征,在能够判断极光类型的同

时拥有更丰富的结构信息——分辨光斑结构的信息。

图 3 所示为属性约束 CNN 结构,其中粉色部分是原 VGG 模型,黄色部分是改进的内容。在 VGG 网络中前两层全连接层后加入批归一化层(BN)<sup>[22]</sup>,分别为 BN1 层和 BN2 层,目的是加速收敛,方便训练,改善正则化策略。然后在 BN2 层之后加入新的全连接层,分别为 FC8\_1 和 FC8\_2。

新加入的全连接层职能不同,FC8\_1 经过 softmax 层输出一个四维向量,代表四类极光的预测概率;FC8\_2 经过 softmax 层输出一个二维向量,代表有无光斑结构的概率。作出这项改进的初衷是:前文提及全连接层起到将学到的分布式特征表示映射到样本标记空间的作用,约束了隐层特征的非线性变化方向。如图 3 所示,可以看到前层网络的输出分别由 FC8\_1 层和 FC8\_2 层通过非线性映




图3 属性约束 CNN

Fig. 3 CNN with attribute constraints

射至极光类型的标签空间和有无光斑的标签空间,即这两层全连接层针对不同的任务改变了隐层特征的非线性变化方向,换句话说,可以认为是给隐层特征的变化施加了约束,而这个约束促使隐层特征向相应任务的标签空间变换,最终改变整个网络的损失。

网络的损失函数定义为当前网络参数下预测值与真实值的差距。若分类类别为  $M$  个,则网络最后一层全连接层输出给 softmax 层  $M$  维向量,此类预测结果的网络损失为

$$L = -\frac{1}{n} \sum_{m=1}^M \log [p(m)] q(m), \quad (1)$$

式中:  $n$  为 mini-batch 样本数量;  $p(m)$  为各个类别的预测概率;  $q(m)$  为各个类别的真实概率。定义经过 FC8\_1 层后得到的判别极光类型的网络损失为  $L_{\text{aurora}}$ , 经过 FC8\_2 层后得到的判别有无光斑结构的网络损失为  $L_{\text{facula}}$ 。因为分辨极光类型是主要任务,判别有无光斑结构起辅助作用,通过反向传播来调节前层网络参数,从而调整提取的 CNN 特征信息,所以添加一个权重参数  $\omega$  来平衡两者的关系。

最终定义整个网络的总损失为

$$L_{\text{net}} = \omega L_{\text{aurora}} + L_{\text{facula}} \quad (2)$$

后文实验部分中将研究  $\omega$  参数大小对整个网络以及对极光类型判断的影响,并找到适合的  $\omega$  参数来提升网络性能,证明文中对网络改进的有效性。

优化网络使得整个网络的参数收敛至最佳的过程就是当训练样本以一个 mini-batch 大小在迭代更新时,最小化网络的损失函数的过程。从(2)式可以看出,光斑结构的判别和极光类型的判别相互影响,并最终决定了整个网络损失,在不断最小化网络损失的同时,光斑属性的约束,如图3中绿色虚线所示,通过反向传播的方式改变前层网络参数,从而起到了调节 CNN 特征的作用。此时,从 CNN 中提取到的 CNN 特征就是通过光斑属性信息调节后的特征,达到了前文所提到的目的——希望提取的 CNN 特征更加丰富,既包含极光图片全局信息,也含有局部光斑结构信息,改善分类效果。

图4将网络中学到的特征进行了可视化显示,证明了加入光斑属性的约束确实增强了网络对特征的描述能力。




图4 网络中学习的光斑属性特征图。(a)弧状极光;(b)热点状极光;(c)弧状特征图;(d)热点状特征图  
Fig. 4 Feature maps of facula attributes learned from our network. (a) Arc image; (b) hot-spot image; (c) arc feature map; (d) hot-spot feature map

## 2.4 极光序列建模

LSTM 网络<sup>[10]</sup>是一种新型递归神经网络,在传统循环神经网络基础上加入了门结构,解决了长期依赖问题,更擅长捕捉时序中的信息。一般的 LSTM 网络架构由记忆单元和门结构组成,而门结构包括输入门、遗忘门和输出门三种类型。当一个新的输入进入网络时,如果输入门  $i_t$  被激活函数激活,则新的输入中提取的信息会被储存至记忆单元  $c_t$ 。如果遗忘门  $f_t$  处于被激活状态,则上一个时刻记忆单元  $c_{t-1}$  会被忘记。输出门  $o_t$  控制的是 LSTM 网络单元的输出  $h_t$ 。网络中的信息传递方程为

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci} \circ c_{t-1} + b_i), \quad (3)$$

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf} \circ c_{t-1} + b_f), \quad (4)$$

$$c_t = f_t \circ c_{t-1} + i_t \circ \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c), \quad (5)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co} \circ c_t + b_o), \quad (6)$$

$$h_t = o_t \circ \tanh(c_t), \quad (7)$$

式中:  $\circ$  运算符为哈达玛乘积;  $\sigma$  为 sigmoid 激活函数;  $W$  为权重;  $b$  为偏置。

CNN 模型将序列中每一帧极光图像的特征向量堆叠为一个特征矩阵  $\mathbf{X}_Q = [x_1, x_2, x_3, \dots, x_t]$ , 将其作为 LSTM 网络的输入。遵循 LSTM 网络的信息流动规则得到各个 LSTM 网络单元的输出  $h_t$ , 然后由全连接层进行非线性映射至标签空间得到极光图像序列的序列级别的特征  $\mathbf{S}_Q = [s_1, s_2, s_3, s_4]$ 。通过 softmax 层将得到的  $\mathbf{S}_Q$  转化为四种类别极光的预测概率:

$$p_k = \sigma(s_k) = \frac{\exp(s_k)}{\sum_{d=1}^K \exp(s_d)}, k = 1, \dots, K, \quad (8)$$

式中:  $K = 4$ 。最终得到预测各类极光的概率  $\{p_1, p_2, p_3, p_4\}$ , 其中概率最大的极光类型为模型预测的极光类型。

## 3 实验与结果分析

### 3.1 数据集简介

基于中国北极黄河站的极光图像观测数据,从 2003 年 12 月到 2009 年 1 月期间挑选 249 天的数据构建数据库。数据库有两个部分,分别用于有监督的极光序列分类研究和无监督的极光事件检测研究。第一部分数据经过人工标记并分段为多个短序列,每个短序列尽可能包含一种极光类型,共 609 个极光序列,其中有 284 个弧状极光序列,119 个帷幔

冕状极光序列,138 个辐射冕状极光序列和 68 个热点状极光序列;第二部分也是人工挑选的 40 天较好的数据,但没有进行人工标注。

### 3.2 极光序列分类实验

实验中模型是基于 Google 最新开源的 TensorFlow 软件平台搭建的。CNN 模型部分是基于 VGG-16 网络,因为该模型的第一层输入要求图片大小为  $224 \times 224$ ,所以需要将数据库图片大小从原始的  $440 \times 440$  调整至  $224 \times 224$ 。同时为了加速训练和收敛,利用在 Image-Net 数据库上经过了预训练的模型参数来初始化本文网络的参数。其中,第一层卷积层的参数不选择覆盖,因为原预训练模型输入为三通道彩色图像,而本文极光图像数据库的图像为单通道。同时卷积层后的所有全连接层(FC6, FC7, FC8\_1, FC8\_2)参数也不选择覆盖,因为这正是微调所要改变的。训练中的其他参数: mini-batch 大小设为 32, epoch 大小设置为 50, 基础学习率设置为 0.001(因为加了 BN 层,所以在迭代过程中反复调整学习率的大小),网络优化器采用 Adam 优化算法<sup>[23]</sup>。

对于 LSTM 网络模型部分,串行结构中训练参数如下:基础学习率设置为 0.001,迭代步数设置为 500 次, mini-batch 大小为 10,网络优化器同为 Adam 优化算法。考虑到数据量不多, LSTM 网络只含一层隐层结构,其隐层共 64 个单元结构。并行结构中训练参数如下:基础学习率、epoch 大小和 mini-batch 大小与 CNN 一致,网络优化器也为 Adam 优化算法,但是网络结构采用双层 LSTM 网络结构,且每个隐层为 256 个单元结构。

在上述网络训练参数下,设置训练、测试、验证三个集的比例大小为 6:2:2。讨论  $\omega$  参数大小。如图 5 所示,可以看出当  $\omega = 4$  时, CNN 模块对四类极光的判别能力最优。




图 5 不同  $\omega$  参数下极光图片分类准确率  
Fig. 5 Classification accuracy of aurora images with different  $\omega$

将本文方法中 CNN 模块的图片分类效果与原始 CNN、并行 CNN-LSTM 网络(采用加法融合方式)进行对比,实验结果如表 1 所示。从表 1 可以看出,本文方法与并行 CNN-LSTM 网络相比,仅热点状极光识别能力相对较低,这证明了 LSTM 网络在并行结构中的有效性和融合模型的性能优越性。相对于原始 CNN,本文方法对热点状极光的识别能力提升,对辐射冕状极光的识别能力降低,这说明加入

表 1 极光图像分类准确率比较

Table 1 Comparison of classification accuracy on aurora images

Method	All	Arc	Drapery	Radial	Hot-spot
Original CNN	0.95	0.98	0.89	0.97	0.90
CNN-LSTM on parallel connection	0.96	0.98	0.91	0.91	0.98
Our method ( $\bar{\omega}=4$ )	0.95	0.98	0.89	0.90	0.95

将本文方法和 CNN-LSTM 网络、uLBP(均匀局部二值模式)-HMM 方法<sup>[5]</sup>以及 uLBP-HCRF 方法<sup>[6]</sup>在极光数据库上进行对比,图 6 所示为各种方法对极光序列的分类准确率。没有和前文所述环状局部方向模式方法<sup>[7]</sup>、张量动态纹理模型<sup>[8]</sup>方法进行对比,原因如下:1)环状局部方向模式方法仅针对弧状极光有效;2)这两种方法得到的实验数据与本文中使用的数据库略有差异。




图 6 极光序列的分类准确率对比

Fig. 6 Comparison of classification accuracy on aurora sequences

从图 6 可以看出,本文方法分类准确率最高。和 CNN-LSTM 网络相比,本文方法在相同的网络初始化参数和训练参数下进行训练和测试,从图中可以发现,在 CNN 特征中加入光斑属性信息约束后,在含有全局信息的同时还含有光斑局部信息,这对后续 LSTM 网络对帧间变化的时序信息捕捉有很大的帮助。其中识别精度相对较低的热点状极光序列和辐射冕状极光序列在本文方法中情况有了明显的改善,识别准确率分别从 89% 提升至 96%,从 85% 提升至 98%。这证明了引入对极光数据本身特点——光斑属性约束的考虑是有效的。

光斑属性来调节提取的 CNN 特征对原分类效果产生了影响。

从单帧图片整体的识别准确率来看,三种方法相差不大。本研究最终目的是实现极光序列的自动分类,因此利用已经训练好的 CNN 模型来提取单帧的极光图像特征并输入 LSTM 网络分析其时序规律。将已挑选的 609 个序列按训练、测试比为 6:4 的比例划分。

另外两种用于比较的方法都是基于模型的方法,且用到了之前在极光图像上效果较好的 uLBP 特征。对帧级别的特征而言,CNN 提取的特征在针对静态图像分类任务中的效果优于 uLBP 特征。使用模型进行时序性分析时,HMM 模型假设观测变量之间是相互独立的,极光序列是一个动态变化的过程,前后帧之间存在一定的相似性,LSTM 网络则没有这种假设;HCRF 模型合理利用了上下文信息来学习模型,但是与 LSTM 网络模型相比,它不能考虑远距离的上下文信息,考虑更多的是局部线性加权,因此,一旦序列帧数变多时,有效性明显不及 LSTM 网络模型。本文方法与其他方法相比,其极光序列分类效果更好。

### 3.3 极光事件检测实验

极光事件检测实验使用的数据是经过人工挑选的相对清晰的 40 天的极光,便于对每天的极光分布规律进行研究。对一天的长序列进行自动分段。分段过程中,尽可能保证一天的极光序列分成多个性质相同的短序列,即尽可能保证每个短序列中尽量只有一种类型的极光序列,分别对每个序列进行分类并分析其分布规律。采用基于运动场的局部向量差分算法<sup>[24]</sup>进行分段。将分段后的序列输入训练好的网络中进行分类,得到该序列的极光类型。

为了显示每种极光在时间上的分布,在 03:00 UT—15:00 UT 的 12 h 内,每隔 200 s 划分一个区间,一共划分为 216 个区间。每两帧拍摄时间间隔 10 s,即每隔 20 帧图像划分一个区间。待网络模型测得每个短序列的极光序列类别标签后,另外序列中的每帧图像类别都为此预测类别,以此得到 40 天待检测极光图像数据中所有图像类别标

签。在每一个区间内,统计每种类型的极光图像占比并绘制图像。

图7所示为本文方法检测出的四类极光在时间上的分布规律,与日侧极光多波段能量的分布情况描述<sup>[20]</sup>基本一致。1)W和D区分别为午前和午后区域,弧状极光分布呈明显的双峰型,两个峰值大概分布在午前和午后区域,而且午前的极光比午后少。图中的弧状极光基本符合这一规律。2)亮度较弱的

帷幔冕状极光和辐射冕状极光在形态上差别较小,两者的发生位置也比较接近,主要出现在10:00 UT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(M区域即06:30 UT—10:00 UT),而辐射冕状极光的峰值分布约在08:00 UT—09:30 UT。3)热点状极光的发生概率相对较低,主要分布在极光卵H区域,在10:30 UT出现明显的峰值。




图7 四类极光分布规律

Fig. 7 Distribution of four kinds of aurora

与杨秋菊等<sup>[2]</sup>得到的极光分布规律结果最大的区别是本文方法检测到的帷幔冕状极光的占比更高,弧状极光占比更低。产生这一情况的原因有二:一是因为杨秋菊等是基于帧的统计规律,所以测试数据是2004—2009年中所有观测天数的图片,共399628幅,不排除有时天气恶劣或者拍摄不清晰导致很多弧状极光数据检测错误,而本文方法是通过人工筛选一天之中帧数全且图像相对较清晰的数据来进行测试;二是弧状极光经常是由帷幔状极光过渡而来的,最后又演变成帷幔冕状极光,处于过渡状态的极光形态特别复杂,多呈模棱两可的形态特征,用不同的方法检测时会得到不同的结果。

## 4 结 论

将深度学习算法引入极光分类中,提出了一种基于属性约束CNN和LSTM网络相结合的极光序列自动分类方法。在传统CNN的基础上加入属性约束来辅助调节CNN特征,之后引入LSTM网络提取序列特征,在极光序列分类任务中取得了较好的效果。该网络提取的帧级特征在含有全局信息的同时还含有光斑局部信息,结合LSTM网络保证了序列特征蕴含整个序列的时间信息。极光序列分类和极光事件检测实验结果显示了本文方法的有效性。

研究极光图像仍需要紧密结合该激发现象的物理性质来进行分析。本文方法结合了极光图像中存在光斑结构这一特性来改进原网络,但是极光本身应还有更多物理性质值得我们去挖掘并分析该物理现象的发生规律和机制。下一步工作需要挖掘并结合更多极光本身的性质来分析数据,研究极光发生规律。

## 参 考 文 献

- [1] Wang Q, Liang J, Hu Z J, *et al.* Spatial texture based automatic classification of dayside aurora in all-sky images [J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2010, 72(5): 498-508.
- [2] Yang Q J, Hu Z J. An automatic auroral classification method based on morphological characteristics [J]. *Scientia Sinica (Terrae)*, 2017, 47(2): 252-260.  
杨秋菊, 胡泽骏. 一种基于形态特征的极光自动分类方法 [J]. *中国科学: 地球科学*, 2017, 47(2): 252-260.
- [3] Han B, Qiu W L. Aurora images classification via features salient coding [J]. *Journal of Xidian University*, 2013, 40(6): 180-186.  
韩冰, 仇文亮. 一种特征显著性编码的极光图像分类方法 [J]. *西安电子科技大学学报*, 2013, 40(6): 180-186.

- [4] Han B, Jia Z H, Gao X B. Improved PCANet for aurora images classification [J]. Journal of Xidian University, 2017, 44(1): 83-88.  
韩冰, 贾中华, 高新波. 改进的主成分分析网络极光图像分类方法[J]. 西安电子科技大学学报, 2017, 44(1): 83-88.
- [5] Yang Q J, Liang J M, Hu Z J, *et al.* Auroral sequence representation and classification using hidden Markov models [J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50 (12): 5049-5060.
- [6] Xu B, Chen C, Gan Z, *et al.* Aurora sequences classification and aurora events detection based on hidden conditional random fields [C] // Chinese Conference on Pattern Recognition, Springer Singapore, 2016: 404-415.
- [7] Han B, Song Y, Gao X, *et al.* Dynamic aurora sequence recognition using Volume Local Directional Pattern with local and global features [J]. Neurocomputing, 2016, 184: 168-175.
- [8] Song Y T, Han B, Gao X B. Tensor based dynamic textures model for aurora sequences classification [J]. Journal of Nanjing University (Natural Science), 2016, 52(1): 184-193.  
宋亚婷, 韩冰, 高新波. 基于张量动态纹理模型的极光视频分类[J]. 南京大学学报(自然科学版), 2016, 52(1): 184-193.
- [9] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C] // Advances in Neural Information Processing Systems, 2012: 1097-1105.
- [10] Hochreiter S, Schmidhuber J. Long short-term memory [J]. Neural Computation, 1997, 9 (8): 1735-1780.
- [11] Matsukawa T, Suzuki E. Person re-identification using CNN features learned from combination of attributes [C] // International Conference on Pattern Recognition, IEEE, 2017: 2428-2433.
- [12] Simonyan K, Zisserman A. Two-stream convolutional networks for action recognition in videos [C] // International Conference on Neural Information Processing Systems, MIT Press, 2014: 568-576.
- [13] Donahue J, Hendricks L A, Guadarrama S, *et al.* Long-term recurrent convolutional networks for visual recognition and description [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2015: 2625-2634.
- [14] Ye G L, Sun S Y, Gao K J, *et al.* Nighttime pedestrian detection based on faster region convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(8): 081003.  
叶国林, 孙韶媛, 高凯珺, 等. 基于加速区域卷积神经网络的夜间行人检测研究[J]. 激光与光电子学进展, 2017, 54(8): 081003.
- [15] Zou Y B, Zhou W L, Chen X Z. Research of laser vision seam detection and tracking system based on depth hierarchical feature [J]. Chinese Journal of Lasers, 2017, 44(4): 0402009.  
邹焱飏, 周卫林, 陈向志. 基于深度分层特征的激光视觉焊缝检测与跟踪系统研究[J]. 中国激光, 2017, 44(4): 0402009.
- [16] Xu L, Zhao H T, Sun S Y. Monocular infrared image depth estimation based on deep convolutional neural networks [J]. Acta Optica Sinica, 2016, 36 (7): 0715002.  
许路, 赵海涛, 孙韶媛. 基于深层卷积神经网络的单目红外图像深度估计[J]. 光学学报, 2016, 36(7): 0715002.
- [17] Wu S C, Zhao H T, Sun S Y. Depth estimation from monocular infrared video based on bi-recursive convolutional neural network [J]. Acta Optica Sinica, 2017, 37(12): 1215003.  
吴寿川, 赵海涛, 孙韶媛. 基于双向递归卷积神经网络的单目红外视频深度估计[J]. 光学学报, 2017, 37(12): 1215003.
- [18] Xu Y, Lu Y. Adaptive weighted fusion: A novel fusion approach for image classification [J]. Neurocomputing, 2015, 168: 566-574.
- [19] Deng J, Dong W, Socher R, *et al.* ImageNet: a large-scale hierarchical image database [C] // IEEE Conference on Computer Vision and Pattern Recognition, 2009: 248-255.
- [20] Hu Z J, Yang H, Huang D, *et al.* Synoptic distribution of dayside aurora: multiple-wavelength all-sky observation at Yellow River Station in Ny-Ålesund, Svalbard [J]. Journal of Atmospheric and Solar-Terrestrial Physics, 2009, 71(8): 794-804.
- [21] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition [C] // International Conference on Learning Representations, 2015: 1-14.
- [22] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift [C] // International Conference on Machine Learning, 2015: 448-456.

- [23] Kingma D P, Ba J. Adam: a method for stochastic optimization[C] // 3rd International Conference for Learning Representations, 2015.
- [24] Wang Q, Hu H Q, Hu Z J, *et al.* A method for detecting the change of auroral activities based on the all-sky image sequence [J]. Chinese Journal of Geophysics, 2015, 58(9): 3038-3047.
- 王倩, 胡红桥, 胡泽骏, 等. 基于全天空图像的极光活动变化检测方法研究[J]. 地球物理学报, 2015, 58(9): 3038-3047.