

基于迁移学习的太空台风自动识别*

夏 凯¹ 邢赞扬² 张清和² 王艳玲¹
杨秋菊³ 陆 盛² 刘振平¹

1(山东大学机电与信息工程学院 威海 264209)

2(山东大学空间科学研究院 山东省光学天文与日地太空环境重点实验室 威海 264209)

3(陕西师范大学物理学与信息技术学院 西安 710062)

摘 要 太空台风是极盖区内一种新发现的大尺度亮斑状极光结构, 直观表征了地磁平静期的一种堪比磁暴的太阳风能量注入现象, 这更新了人们对太阳风-磁层-电离层耦合过程的认识, 如何从海量星载极光数据中准确高效识别出太空台风事件具有重要的科学意义。采用深度学习的方法, 通过六种网络模型的对比, 最终基于迁移学习和 EfficientNetB2 网络提出了一种太空台风自动识别方法。在 2005–2021 年美国国防气象卫星 (Defense Meteorological Satellite Program, DMSP) 上搭载的紫外光谱成像仪 (Special Sensor Ultraviolet Spectrographic Imager, SSUSI) 的观测数据中验证了该模型的有效性, 识别准确率达到 97.7%。研究结果表明, 该方法可用于从海量星载极光观测数据中自动识别太空台风事件。

关键词 太空台风, 极光, 迁移学习, EfficientNetB2

中图分类号 P352

Automatic Identification of Space Hurricane Based on Transfer Learning

XIA Kai¹ XING Zanyang² ZHANG Qinghe² WANG Yanling¹
YANG Qiuju³ LU Sheng² LIU Zhenping¹

1(School of Mechanical, Electrical and Information Engineering, Shandong University, Weihai 264209)

2(Shandong Key Laboratory of Optical Astronomy and Solar-Terrestrial Environment,
Institute of Space Sciences, Shandong University, Weihai 264209)

3(School of Physics and Information Technology, Shaanxi Normal University, Xi'an 710062)

* 国家自然科学基金项目资助 (42120104003, 41904169, 41874170)

2022-07-11 收到原稿, 2022-10-22 收到修定稿

E-mail: xiakai@mail.sdu.edu.cn. 通信作者 邢赞扬, E-mail: xingzanyang@sdu.edu.cn;

王艳玲, E-mail: wangyanling@sdu.edu.cn

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

Abstract Space hurricane is a newly discovered large-scale and bright spot-like auroral structure in the polar cap region, which visually characterizes a solar wind energy injection phenomenon comparable to a magnetic storm during the geomagnetic calm period, this updates the understanding of the solar wind-magnetosphere-ionosphere coupling process, it is of great scientific importance to accurately and efficiently identify space hurricane events from the huge amount of auroral data. Deep learning is used, six networks are compared, and an automatic space hurricane identification method based on Transfer learning and EfficientNetB2 is proposed, validate the effectiveness of the model in DMSP/SSUSI observations from 2005 to 2021 with an accuracy of 97.7%. The results show that the method can be used to automatically identify Space hurricane events from a large amount of satellite-based auroral observation data.

Key words Space hurricane, Aurora, Transfer learning, EfficientNetB2

0 引言

极光是来自太阳风和地球磁层的高能粒子沿地球磁场线沉降到南北两极地区,与电离层高度大气中的原子或分子碰撞并激发出光子的发光现象^[1],能够直接反映太阳风-磁层能量耦合过程和效率。在地磁活跃期,太阳风容易入侵地球磁层,并能在极光椭圆区引起较强的极光活动。在地磁平静条件和行星际磁场北向条件下,整个极光椭圆区内的极光常常比较弱,但有时极盖区内却出现明亮的极光亮斑或者极光弧^[2-5],表明此时在极盖区内的局地区域存在着高效的太阳风-磁层能量耦合过程。在过去几十年里,极光及其磁层动力学过程得到了太空物理和极光物理界的广泛关注和研究,但是绝大多数聚焦于地磁活跃期极光椭圆区的极光现象,而对地磁平静期的极盖区极光现象却缺乏清晰的理解和系统的研究。2021年Zhang等^[5]利用DMSP卫星上搭载的SSUSI星载极光观测以及粒子探测,首次发现在极端地磁平静期,地球极区电离层与磁层存在一种类似台风或飓风的现象,光学表现为在极盖区内的极光亮斑,称为太空台风(Space hurricane),结合高精度的磁流体力学模拟,推测高纬度磁层顶的稳定尾瓣重联为太阳风入侵地球磁层开辟了一条快速的能量传输通道,显著提升了极盖区内局地的太阳风-磁层能量耦合效率,使得太阳风-磁层能量粒子沉降到电离层,进而引起该现象。目前,对太空台风的判别大多依赖于人工筛选,但该方法会耗费大量的人力物力资源。因此,本文将深度学习的方法引入太空台风自动识别中,从而实现太空台风的高效判别。

太空台风作为一种新发现的极光现象,在计算机领域尚未开展研究。但在2004年,Syrjasuo等^[6]已经将机器学习和模式识别技术应用于静态极光图像分类。自此以后,大量极光图像自动识别方法不断出现。基于地基极光观测,Li等^[7]提取图像二值特征(LBP),并使用分布式加权K近邻分类器(WC-SKNN)来判别极光的形态,该方法显著提高了极光特征的判别能力。基于星载极光观测,Kim等^[8]提出了基于内容的极光图像检索系统,并利用Polar Orbit Meteorological Satellite(POLAR)卫星上的紫外极光成像仪数据,采用分层表征法对标准极光和三种特定类型极光图像进行了初步研究。随着研究的不断深入,传统机器学习算法在极光图像识别方面的效果不佳,深度学习的出现,解决了很多传统机器学习算法存在的问题。深度学习作为机器学习的一个分支,不再需要手动提取图像的特征,而是可以直接从训练样本中自动学习输入图像的特征,在图像识别和分类任务中达到了领先水平^[9]。Tong等^[10]利用密集连接卷积神经网络(DenseNet)对喉区极光特征自动学习,完成了喉区极光的机器识别,识别准确率达96%。Clausen等^[11]使用预先训练好的深度神经网络,自动从极光图像中提取1001维的特征向量,在只区分有极光和无极光二元分类中,准确率达到96%。Kvammen等^[12]利用位于瑞典基律纳附近的全天空相机获取的极光图像,对比了VGG和ResNet等多种深度学习模型,ResNet-50模型在准确率、召回率和三级指标 F_1 分数等所有指标中都获得了最高分,平均分类精度达到92%。

深度学习模型往往需要大量的数据进行训练,但本文实验中使用的太空台风图像数据较少,直接训练效果往往达不到最优效果。Donahue 等^[13]提出一种迁移学习的方法,即从大规模数据集学习到的模型迁移到其他数据集上进行预测,可以用来解决某些数据集中数据少的问题。Li 等^[14]利用北极黄河站全天空成像仪拍摄的极光图像进行实验,将在 ImageNet 数据集预训练的原始 VGG16 网络模型迁移到的改进的 VGG 网络中,两种极光数据库测试准确率分别达到了 96.54% 和 98.99%。Sado 等^[15]使用支持向量机 (SVM) 算法重新训练最后一个神经网络层,在区分极光类和非极光类的实验中,准确率高达 91%。

为高效、准确地识别出太空台风,本文对比了 6 种网络模型,选取效果最佳的网络模型应用于 2005—2021 年太空台风的自动识别中。由于太空台风图像较少,采用了迁移学习的方法以提高模型的准确率。

1 方法

太空台风自动识别算法构架如图 1 所示。首先在 Image21k 数据集上对六种网络模型进行预训练,得到预训练后的模型权重,进而基于人工挑选的 2011 和 2012 年太空台风数据集进行迁移学习,得到 6 种模型,最后选择最优模型应用于 2005—2021 年 (除 2011 年和 2012 年) DMSP/SSUSI 图像中,完成太空台风自动识别。本文采用的 Image21k 数据集拥有超百万张图像,已广泛应用于各类比赛项目中,是目前世界上图像识别领域较为常用数据库。

1.1 模型选取

采用 4 类 6 种网络模型,分别为 VGG16, ResNet34,

EfficientNetB0, EfficientNetB2, EfficientNetV2-S 以及 EfficientNetV2-M, 这些网络模型在图像识别、图像分类领域均取得了较好效果。

VGG 网络^[16]是牛津大学著名研究组 VGG 于 2014 年提出,获得了 2014 年 ImageNet 竞赛定位任务第一名以及分类任务第二名。VGG16 网络通过堆叠多个 3×3 的卷积层来替代大尺度卷积层,证明了使用小尺度卷积核和增加网络深度可以有效地提升模型的效果。

ResNet 网络^[17]是微软实验室于 2015 年提出,获得了 2015 年 ImageNet 竞赛中分类任务、目标检测的第一名;获得了 COCO 数据集中目标检测和图像分割的第一名。ResNet34 网络同样使用了多个 3×3 的卷积层堆叠,但堆叠过深会带来模型梯度消失和网络退化。通过数据的预处理以及网络中使用 BN 层来解决梯度消失问题;提出了残差结构模块,减轻了深层网络中的退化问题。

EfficientNet 网络^[18]是谷歌 Brain 团队于 2019 年提出,通过一组固定的缩放系数统一缩放网络深度、网络宽度和分辨率这三个维度,在这三个维度上提升了网络性能。EfficientNetB0 是通过神经网络结构搜索技术搜索得到, EfficientNetB2 是 EfficientNetB0 的倍数,模型宽度和深度分别为 EfficientNetB0 的 1.1 和 1.2 倍。

EfficientNetV2 网络^[19]由谷歌 Brain 团队于 2021 年提出,作为 EfficientNet 的改进版,将浅层网络中 MBConv 替换成 Fused-MBConv, 明显提升了训练速度,并提出改进的渐进学习方法,该方法会根据训练图像的尺寸动态调节正则方法,同时采用新的搜索技术得到 EfficientNetV2 结构。EfficientNetV2-S 与




图 1 太空台风自动识别算法构架

Fig. 1 Architecture diagram of space hurricane automatic identification

EfficientNetV2-M 的结构相似,只是相较于基准网络其倍率因子不同。Zeng 等^[20]利用 EfficientNetV2 在 CVPR2021 阿里挑战赛大规模的数据识别中获得第一名。

1.2 迁移学习

迁移学习是利用现有的知识对相近研究领域进行求解的一种机器学习方法,简单来说就是将任务一的模型再次应用到任务二中。与传统机器学习的方法相比,深度学习模型需要大量的数据来寻找数据间的内在联系,因此深度学习模型具有严重的数据依赖性。在样本数据集数量较少的情况下,采用深度学习的方法在训练过程中很容易出现过拟合的现象,训练出来的模型效果较差,迁移学习技术的出现缩短了构建模型和训练样本花费的时间,同时迁移学习所需要的样本数据量更小,模型的泛化性更好,能够在一定程度上缓解深度学习的过拟合问题^[21]。本文采用了迁移学习的方法。迁移学习中的数据分为源数据和目标数据,本文中源数据为 Image21k 数据集,目标数据为太空台风数据集。源数据集预训练产生源模型,目标模型复制了源模型上部分模型设计及参数。图 2 给出了本文中的迁移学习策略,先用 Image21k 数据集在源模型上进行预训练,之后用太空台风数据集在 1.1 节中提到的 6 种网络模型上进行迁移学习,在迁移学习训练过程中,除输出层外,其他所有层均被冻结。

1.3 评价指标

为了解模型的优劣,本文采用混淆矩阵来评估模型的有效性。混淆矩阵是用来总结一个分类器结果的矩阵,对于二元分类,混淆矩阵如表 1 所示。其中 n_1, n_2, n_3, n_4 分别代表真阳性、假阳性、假阴性、真阴性,4 数之和为样本总数量。

混淆矩阵仅统计个数,很难衡量模型的优劣。因此,在混淆矩阵的结果上又增加了以下 4 个二级指标,分别是准确率 a 、精确率 p 、召回率 r 以及特异度 s 。通过上述的 4 个二级指标,可以将混淆矩阵中数量结果转化为 0~1 之间的比率,便于进行标准化的衡量,计算公式如下:

$$a = \frac{n_1 + n_4}{n_1 + n_2 + n_3 + n_4}, \quad (1)$$

$$p = \frac{n_1}{n_1 + n_2}, \quad (2)$$

$$r = \frac{n_1}{n_1 + n_3}, \quad (3)$$

$$s = \frac{n_4}{n_2 + n_4}. \quad (4)$$

在这 4 个指标的基础上再进行拓展,会产生另外一个三级指标 F_1 分数,计算公式如下:

$$F_1 = \frac{2 \times p \times r}{p + r}. \quad (5)$$

F_1 分数指标综合了精确率与召回率的结果,其取值范围为 0~1,其中 1 代表模型的输出结果最好,0 代表模型的输出结果最差。

2 实验结果分析

2.1 实验环境与参数

实验采用 Python 编程语言,主要基于 PyTorch 框架搭建模型和完成训练。CPU 处理器为 Intel(R) Core(TM) i7-10700 CPU @ 2.90 GHz, GPU 处理器为 NVIDIA GeForce GTX 1660 Super,内存 (RAM) 为 16 GB,操作系统为 64 bit Windows10 专业版。

2.2 实验数据

本文研究所使用的实验数据为 2005—2021 年




图 2 迁移学习策略

Fig. 2 Transfer learning strategy

F16~F19 四颗卫星 DMSP/SSUSI 图像^{*}。2005—2021 年 DMSP/SSUSI 图像大约 30 万张,由人工完全挑选是十分耗时耗力的。因此,本文由人工挑选出 2011—2012 年太空台风事件,共计 235 张太空台风图像。对于非太空台风图像,由人为指定平静时期、15 MLT-PCA、跨极盖区极光弧等图像共 235 张,以上 470 张图像按照 8:2 的比例随机划分成为训练集与验证集。测试集从 2005—2021 年(除 2011 和 2021 年)各挑选出 8~12 张太空台风图像与非太空台风图像,共计 300 张。本文挑选的部分太空台风事例如图 3 所示,即在极盖区内的亮斑状极光结构。

表 1 混淆矩阵
Table 1 Confusion matrix

Confusion matrix		True labels	
		1	0
Predicted labels	1	n_1	n_2
	0	n_3	n_4

2.3 数据预处理

DMSP 卫星拍摄的 SSUSI 极光数据并不是图像格式,而是一组数值阵列,因此在将极光图像输入到卷积神经网络之前,根据其原始数据进行了预处理,如图 4 所示。由于原始数据中存在很多噪点,如图 4(a)所示,这对后续训练模型有很大影响,因此采用中值滤波的方法对原始数据进行去噪处理。中值滤波会选取数字图像或数字序列中像素点及其周围临近像素点的像素值,将这些像素值排序,然后将位于中间位置的像素值作为当前像素点的像素值,从而消除孤立的噪点。去噪后图像如图 4(b)所示,可以明显看出经预处理后图像噪点明显减少。其次,太空台风是发生在极盖区内的一种极光现象,可粗略将 75°以上的区域定为极盖区。为了减小其他区域对模型训练的影响,本文大致截取 75°以上的区域,如图 4(c)所示。最后,由于太空台风事件较少,除了采用迁移学习的方法,也对图像进行图像增强等转换操作,如图 4(d)(e)所示。通过人为地随机范围裁剪、缩放和旋转等




图 3 太空台风事例
Fig. 3 Examples of space hurricane

^{*}https://ssusi.jhuapl.edu/gal_Aur

操作, 增大训练集中的数据多样性和全面性, 进而提高模型的泛化能力。图 4(d)(e)给出了图像转换的示例。

2.4 分类性能比较

图 5 给出了 6 种网络模型训练过程中训练集损失率及验证集准确率的变化情况。从图 5(a)中可以看出, ResNet34, EfficientNetB0, EfficientNetB2 网络模型收敛速度较快。大约在 20 次训练后, 损失率收敛至 0.2 附近; 大约在 40 次训练后, VGG 网络模型收敛至 0.3 左右。EfficientNetV2 网络模型收敛最慢,

且在训练初期有损失率增加的现象, 大约在 80 次训练后收敛至 0.4。从图 5(b)中可以看出, 迁移学习的方法不用从头开始训练模型, 可以有效的提高模型的准确率, 且 EfficientNetB2 准确率明显高于其他模型。图 6 给出了 6 种网络模型在太空台风测试集上的混淆矩阵, SH 代表太空台风事件, Others 代表其他事件。从混淆矩阵结果可以看出, 6 种网络模型均能较好地识别出太空台风事件, 仅个别事件分类错误。其中 EfficientNet 的两种模型效果最佳。表 2 给出了由混淆矩阵计算的各评价指标。从表 2 中可以看出,




图 4 数据预处理

Fig. 4 Data pre-processing




图 5 6 种模型训练集损失率 (a) 与验证集准确率 (b) 的变化情况

Fig. 5 Variation of loss rate in the training set (a) and accuracy rate in the validation set (b) of six models




图 6 6 种模型测试集的混淆矩阵

Fig. 6 Confusion matrices of six models in the test set

表 2 6 种模型测试集的评价指标

Table 2 Evaluation metrics of six models in the test set

Model name	a	p	r	s	F_1
VGG	0.9700	0.9930	0.9467	0.9933	0.9693
ResNet	0.9667	0.9795	0.9533	0.9800	0.9662
EfficientNetB0	0.9767	0.9799	0.9733	0.9800	0.9766
EfficientNetB2	0.9767	0.9735	0.9800	0.9733	0.9767
EfficientNetV2-S	0.9200	0.9200	0.9200	0.9200	0.9200
EfficientNetV2-M	0.9400	0.9459	0.9333	0.9467	0.9396

各模型识别效果均良好,准确率均在 90% 以上。综合上述结果, EfficientNetB2 网络模型效果最好。因此, 本文应用 EfficientNetB2 来识别其他年份事件。

2.5 EfficientNetB2 网络结构

EfficientNet 各网络结构是以 EfficientNetB0 为基准网络, 然后使用不同的混合因子得到的。Effi-

cientNetB0 的结构如表 3 所示,以 EfficientNetB2 为例,其结构是 EfficientNetB0 的倍数,模型宽度和深度分别为 EfficientNetB0 的 1.1 和 1.2 倍,输入图像的分辨率为 260×260 。由表 3 可以看出, EfficientNet 模型主要的结构在于 MBConv 结构的堆叠, MBConv 结构如图 7 所示,主要由一个用于升维的 1×1 的普通卷积、一个 $k \times k$ 的 Depthwise Conv 卷积和一个用于降维的 1×1 的普通卷积构成。其中, DW 卷积可以有效的减少参数,降低计算量。

2.6 极光图像特征的可视化

神经网络是一个黑盒子,可解释性差,但通过可视化特征图可以较为直观地了解从神经网络到底学到了什么东西。在每个卷积层,数据都是以三维形式存在的,可以把其看成许多个二维图片叠在一起,其中每一个称为一个特征图。卷积神经网络有两种特征图可视化方法,一种是正向传播方法,另一种是反向传播方法。本文所用的是正向传播方法来可视化卷积神经网络中间层的特征矩阵,该方法直接将每层的特征图显示出来,但随着经过卷积层与池化层,特征图的维度逐渐降低。图 8 给出了一个卷积层计算得到的 32 个特征图,每个特征图的切片中可以通过明暗程度来理解卷积层所关注的信息,其中越亮的区域越拥有更具价值的特征。从图 8 可以看出,在部分特征图中,模型已捕捉到太空台风特征。




图 7 MBConv 结构
Fig. 7 MBConv structure

2.7 误判事件

尽管选用识别模型 EfficientNetB2 的准确率高达 97.7%,但由于极盖区极光形态各异且本文太空台风事件样本量较少,有时将 15 MLT-PCA 和跨极盖区极光弧事件误判为太空台风事件,如图 9 所示。这些事件经过人工判读后将其剔除,确保所挑选的事件均为太空台风事件。

3 结论

太空台风是极盖区内的一种亮斑状极光结构,如何从海量星载极光数据中自动识别出太空台风,对深入研究太空台风发生规律具有重要意义。

本文提出了一种基于迁移学习的太空台风自动识别方法,通过对人工挑选出 2011 和 2012 年 DMSP/SSUSI 图像中的太空台风事件数据集进行迁移学习,结合 2005—2021 年(除 2011 和 2012 年)DMSP/SSUSI 图像中太空台风事件测试集,对比了六个深度学习模型的测试结果,发现 EfficientNetB2 模型效果最好,识别准确率达 97.7%,最终利用此模型完成了 2005—2021 年太空台风事件的识别,并对识别结果进行人工确认。由于极盖区内情况复杂,极光形态各异,太空台风自动识别过程中存在误判事件。

通过对这些事件进行人工剔除,可以保证将来统计分析太空台风发生规律等的准确性。此外,结合十余年太空台风事件的统计规律,联合太空物理参数,例如行星际磁场和地磁条件等,将可能建立一种融合太空物理参数的深度学习模型,减少误判事件的出现。

表 3 EfficientNetB0 的体系结构
Table 3 Architecture of EfficientNetB0

Stage	Operator	Resolution	Channels	Layers
1	Conv3×3	224×224	32	1
2	MBConv1, k3×3	112×112	16	1
3	MBConv6, k3×3	112×112	24	2
4	MBConv6, k5×5	56×56	40	2
5	MBConv6, k3×3	28×28	80	3
6	MBConv6, k5×5	14×14	112	3
7	MBConv6, k5×5	14×14	192	4
8	MBConv6, k3×3	7×7	320	1
9	Conv1×1&Pooling&FC	7×7	1280	1




图 8 太空台风识别卷积层的 32 个特征图

Fig. 8 32 feature maps of space hurricane recognition convolution layer




图 9 太空台风误判事件

Fig. 9 Misjudgements of space hurricane

致谢 山东省光学天文与日地太空环境重点实验室对本研究给予了支持和帮助。研究数据由 SSUSI 工作组 (https://ssusi.jhuapl.edu/gal_Aur) 提供。

参考文献

- [1] FELDSHTEYN Y I. Some problems concerning the morphology of auroras and magnetic disturbances at high latitudes[J]. *Geomagnetism Aeronomy*, 1963, **3**: 183-192
- [2] FREY H U, IMMEL T J, LU G, *et al.* Properties of localized, high latitude, dayside aurora[J]. *Journal of Geophysical Research: Space Physics*, 2003, **108**(A4): 8008
- [3] XING Z Y, ZHANG Q H, HAN D S, *et al.* Conjugate observations of the evolution of polar cap arcs in both hemispheres[J]. *Journal of Geophysical Research: Space Physics*, 2018, **123**(3): 1794-1805
- [4] HAN D S, FENG H T, ZHANG H, *et al.* A new type of polar cap arc observed in the ~ 1500 MLT Sector: 1.

- Northern hemisphere observations[J]. *Geophysical Research Letters*, 2020, **47**(20): e2020GL090261
- [5] ZHANG Q H, ZHANG Y L, WANG C, *et al.* A space hurricane over the Earth's polar ionosphere[J]. *Nature Communications*, 2021, **12**(1): 1207
- [6] SYRJÄSUO M T, DONOVAN E F. Diurnal auroral occurrence statistics obtained via machine vision[J]. *Annales Geophysicae*, 2004, **22**(4): 1103-1113
- [7] LI Y C, JIANG N K. An aurora image classification method based on compressive sensing and distributed WKNN[C]//2018 IEEE 42 nd Annual Computer Software and Applications Conference (COMPSAC). Tokyo: IEEE, 2018: 347-354
- [8] KIM S K, RANGANATH H S. Content-based retrieval of aurora images based on the Hierarchical Representation[C]//12 th International Conference on Advanced Concepts for Intelligent Vision Systems. Sydney: Springer, 2010: 249-260
- [9] GONZALEZ R C. Deep convolutional neural networks (Lecture Notes)[J]. *IEEE Signal Processing Magazine*, 2018, **35**(6): 79-87
- [10] TONG Xin, ZOU Ziming, BAI Xi, *et al.* Machine identification of throat aurora[J]. *Chinese Journal of Space Science*, 2021, **41**(4): 654-666 (佟欣, 邹自明, 白曦, 等. 喉区极光的机器识别[J]. *空间科学学报*, 2021, **41**(4): 654-666)
- [11] CLAUSEN L B N, NICKISCH H. Automatic classification of auroral images from the Oslo Auroral THEMIS (OATH) data set using machine learning[J]. *Journal of Geophysical Research: Space Physics*, 2018, **123**(7): 5640-5647
- [12] KVAMMEN A, WICKSTRÖM K, MCKAY D, *et al.* Auroral image classification with deep neural networks[J]. *Journal of Geophysical Research: Space Physics*, 2020, **125**(10): e2020JA027808
- [13] DONAHUE J, JIA Y Q, VINYALS O, *et al.* DeCAF: a deep convolutional activation feature for generic visual recognition[C]//Proceedings of the 31 st International Conference on Machine Learning. Beijing: ACM, 2014: I-647-I-655
- [14] LI Y Z, CHEN C H, XIE X F. Research on aurora image classification algorithm based on improved convolutional neural network[J]. *Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition)*, 2019, **39**(6): 86-93 (李彦枝, 陈昌红, 谢晓芳. 基于改进卷积神经网络的极光图像分类算法研究[J]. *南京邮电大学学报(自然科学版)*, 2019, **39**(6): 86-93)
- [15] SADO P, CLAUSEN L B N, MILOCH W J, *et al.* Transfer learning aurora image classification and magnetic disturbance evaluation[J]. *Journal of Geophysical Research: Space Physics*, 2022, **127**(1): e2021JA029683
- [16] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. *Computer Science*, 2014. DOI: 10.48550/arXiv.1409.1556
- [17] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778
- [18] TAN M X, LE Q. EfficientNet: Rethinking model scaling for convolutional neural networks[C]//Proceedings of the 36 th International Conference on Machine Learning. Long Beach: PMLR, 2019: 6105-6114
- [19] TAN M X, LE Q. EfficientNetV2: smaller models and faster training[C]//Proceedings of the 38th International Conference on Machine Learning. ElectrNetwork: PMLR, 2021: 10096-10106
- [20] LI H, PAN J K, ZENG H D, *et al.* Identification of specific substances in the FAIMS spectra of complex mixtures using deep learning[J]. *Sensors*, 2021, **21**(18): 6160
- [21] PAN S J, YANG Q. A survey on transfer learning[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2010, **22**(10): 1345-1359