

LI Shuxin, ZHAO Xuebin, CHEN Jun, LI Weifu, CHEN Hong, CHEN Yanhong, CUI Yanmei, YUAN Tianjiao. Recognition Method for Mount Wilson Magnetic Type of Sunspots Based on Deep Learning (in Chinese). *Chinese Journal of Space Science*, 2022, **42**(3): 333–339. DOI:10.11728/cjss2022.03.210107004

基于深度学习的太阳黑子 Wilson 山 磁类型识别方法*

李书馨^{1,2,3} 赵学斌⁴ 陈 君⁴ 李伟夫⁴
陈 洪⁴ 陈艳红^{1,3} 崔延美^{1,3} 袁天娇^{1,3}

1(中国科学院国家空间科学中心 北京 100190)

2(中国科学院大学 北京 100049)

3(中国科学院空间环境态势感知技术重点实验室 北京 100190)

4(华中农业大学理学院 武汉 430070)

摘 要 太阳黑子是太阳光球层中带有较强磁场的区域，通常是太阳爆发活动的源区。Wilson 山磁分类是当前最为主流的太阳黑子分类方法之一，对研究太阳爆发有重要意义。利用 2010—2017 年间 SDO/HMI 成像仪观测到的 720s_SHARP 磁图和白光图数据，研究使用深度学习对太阳黑子群 Wilson 山磁分类的方法。实验结果表明，Xception 网络在识别太阳黑子 Wilson 山磁类型上能取得最优的效果，其中对 α 类型黑子的 F_1 得分为 96.50%， β 类为 93.20%，其他类型的黑子为 84.65%。

关键词 太阳黑子，Xception 网络，深度学习，Wilson 山磁分类
中图分类号 P352

Recognition Method for Mount Wilson Magnetic Type of Sunspots Based on Deep Learning

LI Shuxin^{1,2,3} ZHAO Xuebin⁴ CHEN Jun⁴ LI Weifu⁴ CHEN Hong⁴
CHEN Yanhong^{1,3} CUI Yanmei^{1,3} YUAN Tianjiao^{1,3}

1(National Space Science Center, Chinese Academy of Sciences, Beijing 100190)

2(University of Chinese Academy of Sciences, Beijing 100049)

3(Key Laboratory of Science and Technology on Environment Space Situation Awareness,
Chinese Academy of Sciences, Beijing 100190)

4(College of Science, Huazhong Agricultural University, Wuhan 430070)

* 中国科学院战略性先导科技专项资助 (XDA17010302)

2021-01-07 收到原稿，2021-09-03 收到修定稿

E-mail: liweifu@mail.hzau.edu.cn

Abstract Sunspots are the regions with stronger magnetic field in the solar photosphere and most of solar eruptions occur in complex sunspot groups. Mount Wilson magnetic classification is one of the most popular sunspots classification methods, which is of great significance to the study of solar eruptions. In recent years, with the rapid development of China's space industry, space physics research has entered the era of big data. Deep learning methods for processing space science data are springing up. In this study, based on the SDO/HMI SHARP continuum and magnetogram data during 2010–2017, we propose to apply deep learning for the image recognition of Mount Wilson magnetic type of sunspots. The results show that Xception has a productive performance in the identification of the sunspots magnetic types in solar active regions. The F_1 score of sunspots group of α exceeds 96%, that of β is more than 93%, and that of other types is more than 84%.

Key words Sunspots, Xception network, Deep learning, Mount Wilson magnetic classification

0 引言

太阳黑子是太阳光球层由炽热气体形成的带有较强磁场的区域,表现为在太阳表面温度更低,呈现黑色的区域,一般以黑子群的形式出现。一个发展成熟的黑子主要由中心较暗的黑色本影和边缘较浅的半影两部分组成。单个太阳黑子的寿命为几小时到几个星期,黑子群的寿命一般可达几个月,黑子群的演化具有时间上的缓变性,即同一个黑子群的磁类型在一定时间内不会发生改变。太阳黑子既是活动区的核心,也是活动区最明显的标志,一般将黑子经常出现的区域界定为太阳活动区。一般而言,黑子群出现的区域往往很大可能会出现耀斑、日冕物质抛射等太阳爆发性活动,这些活动严重时对地球通信、航天系统的正常运行等产生影响。总体而言,太阳黑子不仅代表一定时期内太阳活动的总体水平,还为揭示其他太阳活动提供了线索。

根据形态分布和磁场极性等特征对太阳黑子群进行分类,是太阳爆发预报研究的重要手段,目前对于太阳黑子群的分类,较为主流的有 Wilson 山磁分类, Zurich 分类和 McIntosh 分类^[1]。

目前对于黑子群的分类方法主要依托人工识别,还没有国际公认的自动识别方法。近年来,机器学习特别是深度学习在图像识别领域取得了巨大的成功,并且空间物理的监测数据大量增加,使得发展太阳黑子磁类型自动识别方法成为可能。机器学习可以利用海量数据,发现数据间的内隐关系,得到预期的结果。深度学习是机器学习的分支之一,可以看作是神经网络的进阶版。其中卷积神经网络(Convolutional

Neural Networks, CNN)是图像识别方向最为流行的深度学习方法之一,通过此方法可以对图像低层和高层的特征进行提取,识别出具有类似特征的新图片。Padinhatteeri 等^[2]提出了一种“太阳活动区监视系统—磁 δ 探测器”(SMART-DF)方法,该方法可以对 δ 黑子实现自动识别,并将其标记到可能的耀斑区域;Fu 等^[3]基于 R-FCN 的方法, Li 等^[4]基于 R-FCN 的方法和基于卷积神经网络对 McIntosh 黑子实现了自动识别与分类。Fang 等^[5]构建了三层 CNN 网络实现了对 Wilson 山磁类黑子的自动识别,但是该研究工作并未考虑黑子群演化的缓变性,在选取测试集时,通过随机采样的方法选择,即在测试集中,会出现很多与训练集极为相似的样本,使得模型的误准率较高。为了更好提升太阳黑子 Wilson 山磁分类自动识别的准确性,本文尝试了多种深度学习方法并进行评估,得到更优的 Wilson 山磁分类自动识别深度网络。

1 Wilson 山磁类型

Wilson 山磁分类法是由美国加利福尼亚州 Wilson 天文台于 1919 年提出的根据黑子磁场的不同极性进行分类的一种方法^[6]。此分类方法以双极群黑子为基本类型(β 型),从而衍生出不同类别的黑子群,典型的代表为三种类型,分别为单极群(α 型)、双极型(β 型)和多极型(γ 型)。多极型后来又衍生了多种类型,分别为 β - γ , δ , β - δ , β - γ - δ , γ - δ , 每种极型的释义见表 1。

Fang 等^[5]基于美国海洋局空间天气预报中心

(NOAA/SWPC)每天发布的太阳活动区概况文件,统计了从 2010 年 5 月至 2017 年 5 月的 1592 个活动区的黑子类型,共梳理出 11306 个文件, α 类型、 β 类型和其他类型黑子出现概率分别为 31.6%, 54.2%, 10.1%。此外, Sammis 等^[7]指出,磁类型更复杂的活动区黑子有更大的可能会爆发太阳活动。在本文中,对所识别的黑子类型 Wilson 山磁分类做了简化,简单分为三类,分别记为单极型(α 型)、双极型(β 型)和其他极型(β - x 型),如图 1 所示。

2 数据来源及预处理

本文所使用的数据来自太阳动力学观测台 (Solar Dynamics Observatory, SDO) 卫星的日震及磁场成像仪 (Helioseismic and Magnetic Imager, HMI) 观测到的 SHARP (SpaceWeather HMI Active Region Patches) 磁图和白光图数据集。SHARP 数据的时间精度为 12 min, 每条数据可获得所有太阳活动区的局部图片, 活动区有独立的编号。从白光图

表 1 Wilson 黑子磁类型分类
Table 1 Mount Wilson sunspots classification

类型	释义
α	单极黑子群
β	一个黑子群具有正负两种磁场极性, 并且相反极性之间的划分界限简单明显
γ	与 β 类不同, 该活动区较为复杂, 这种类型的黑子群正负极性分布非常不规则
β - γ	此种类型的黑子群分布十分复杂, 相反极性之间没有明显的边界
δ	在此类型的双极黑子群中, 存在相反极性本影共用同一半影的情况, 且其间距小于 2°
β - δ	包含一个或多个 δ 黑子的 β 磁类型黑子群
β - γ - δ	包含一个或多个 δ 黑子的 β - γ 磁类型黑子群
γ - δ	包含一个或多个 δ 黑子的 γ 磁类型黑子群




图 1 (a) 为 α 类型的太阳黑子群磁场观测图像, (b) 为 β 类型的太阳黑子群磁场观测图像, (c) 和 (d) 为 β - x 类型太阳黑子群磁场观测图像, (e) 为 (a) 相应的 α 类型太阳黑子群白光观测图像, (f) 为 (b) 相应的 β 类型太阳黑子群白光观测图像, (g) 和 (h) 为 (c) 和 (d) 相应的 β - x 类型太阳黑子群白光观测图像

Fig. 1 (a) Magnetogram of sunspots group of α , (b) magnetogram of sunspots group of β , (c)(d) magnetograms of sunspots group of β - x , (e) the image of sunspots group of α corresponding to (a), (f) the image of sunspots group of β corresponding to (b), (g)(h) the images of sunspots group of β - x corresponding to (c)(d)

像可清晰看出黑子的本影和半影部分以及黑子群的分布,磁图可以看出黑子的不同极性。本文使用的是2010年5月至2017年5月期间的观测数据^{*}。

根据 Fang 等^[5]人工标记过的磁类型信息^[5],筛选了2010年5月至2017年5月间具有磁图和白光图的黑子数据共15641张,其中 α 类型5276张, β 类型7849张, $\beta-x$ 类型2516张。由于出现在一个活动区的黑子群的演变较缓慢,同一个黑子群在一定时间内不会出现磁类型的变化,为保证数据的多样性,选择数据时间精度为96 min。在划分训练集、验证集和测试集时,将2010年5月至2015年5月间的双通道数据作为输入训练(包含4709个 α 类型,7353个 β 类型,2407个 $\beta-x$ 类型),将2015年6月至2017年5月间的双通道数据作为测试集(包含567个 α 类型,496个 β 类型,109个 $\beta-x$ 类型)。输入训练数据中按照8:2的比例分为训练集和验证集,其中训练集包含3767个 α 类型,5882个 β 类型,1926个 $\beta-x$ 类型;验证集包含942个 α 类型,1471个 β 类型,481个 $\beta-x$ 类型,具体情况见表2。

3 深度学习方法

3.1 ResNet 神经网络模型

神经网络的设计一般遵循深度优先的原则,但是越深的神经网络越难以训练。2015年He等^[8]提出了ResNet模型,其核心思想是在学习 x 到其特征 $H(x)$ 的映射时,机器不再学习这两者间的基本映射关系,而是学习其间的差异,也就是残差。假如定义残差 $F(x) = H(x) - x$,那么该网络开始学习 $F(x) + x$ 而不是 $H(x)$ 。实践证明显示ResNet网络可以避免深度神经网络中的梯度消失问题,从而可以构建层数更

深的网络。常用的ResNet模型包括ResNet34、ResNet50、ResNet101等。

3.2 Inception 神经网络模型

与ResNet网络追求更深的层数不同,Inception^[9]网络是在不牺牲计算成本的前提下构建更宽的网络,Inception的核心思想是通过精心的设计,将大小不同的卷积层组合在一起,矩阵经过这些大小不同卷积层处理后,可以形成一个更深的矩阵。这样做的优点是可以在深度和宽度两个维度对网络进行扩充,从而使得Inception网络既提高了模型的准确性,又防止过拟合现象的发生。

3.3 Xception 神经网络模型

Xception是在Inception基础上发展而来的。Xception^[10]网络是Google在2017年提出的对Inception v3网络的改进,也被称为是一种极端的Inception。其核心思想是使用深度可分离卷积去观察输入数据,与传统方法相比,在网络宽度相同的情况下可大大降低参数量,加快网络的训练速度。但是提出Xception的目的并不是在于对模型进行压缩,而是要提高模型的性能。

3.4 MobileNet 神经网络模型

MobileNet^[11]网络同样也是由Google公司于2017年提出的卷积神经网络模型,可称之为轻量级网络中的Inception。MobileNet具有与Xception相同的网络模块结构,都用到了大量的深度可分离卷积,但两者主要的目的不同。在Xception模型中将普通卷积替换成深度可分离卷积主要是为了分类效果,并不是为了训练速度。而MobileNet的目的恰好相反,该模型并没有加宽网络,而是通过深度可分离卷积对参数量进行压缩和提升训练速度,以便于实际应用。然而MobileNet在实际使用时还存在例如模型训练完后发现有不少卷积核为空,以及模型在低维度上效果不好等问题。针对这些问题,Google提出了将ReLU替换成线性激活函数以及引入倒置残差模块。基于这两点改进,Google公司于2018年提出第二代MobileNet模型,即MobileNetV2^[12]模型。

4 实验结果

4.1 评价指标

为了评估模型在每一类黑子上的分类能力,计算

表2 训练、验证、测试集的分布
Table 2 Distribution of training, validation and test sets

磁类型(时间区间)	α	β	$\beta-x$
训练集(2010年5月至2014年5月)	3767	5882	1926
验证集(2014年6月至2015年5月)	942	1471	481
测试集(2015年6月至2017年5月)	567	496	109
总计(2010年5月至2017年5月)	5276	7849	2516

* <http://jsoc.stanford.edu/>

单类样本的评估指数时将三分类问题简化为二分类问题。表 3 为对 α 类型黑子使用混淆矩阵定量评价模型的结果。其中, T 表示真阳性(Ture Positive), F 表示假阴性(False Negative), N 表示假阳性(False Positive), C 表示真阴性(True Negative)。

从表 3 进一步计算可以得到召回率(Recall) R , 精确率(Precision) P 和 F_1 分数:

$$R = T/(T + F), \quad (1)$$

$$P = T/(T + N), \quad (2)$$

$$F_1 = 2PR/(P + R). \quad (3)$$

一般来说, 召回率和精确率是一对矛盾的度量, 精确率越高, 召回率就越低; 召回率越高, 精确率就越低。例如, 若希望将 α 类型黑子尽可能多地识别出来, 则可以将所有的黑子预测为 α 类, 那么 α 类型黑子的召回率为 1, 这样精确率就会很低。若希望 α 类型的黑子识别精确率高, 则可将最有可能是 α 类型的黑子识别为 α 类, 但这样会导致一些 α 类型黑子被漏选, 使得召回率较低。因此, 综合考虑召回率和精确率, 采用式(3)的 F_1 分数来评估模型的准确性。 F_1 分数越高, 说明学习器的性能越好。

4.2 实验细节

在具体的实验中, 由于原始太阳黑子图片的大小不一致, 不能直接输入网络模型。为满足网络输入要求, 首先对原始太阳黑子图片变换为相同的像素大小(160 pixel×320 pixel)。此外, 考虑到黑子的磁类型识别主要是基于黑子群的形状进行识别, 对其进行旋转等操作并不会改变其磁类型。为此, 在训练时考虑使用数据扩充的策略(对训练样本进行旋转, 翻转和缩放等操作)来增加训练样本的数量以及多样性, 提升模型鲁棒性。损失函数选择交叉熵损失, 一次训练所抓取的数据样本数量设定为 8, 迭代轮次设定为 30, 每个迭代轮次迭代 1000 步。检验集上损失最小的模型当作最优模型。

在做预测时, 采用了测试时增强(TTA)^[13] 算法,

通过牺牲测试时间来提高模型的准确率。TTA 算法的核心思想是通过对原始图像通过水平和垂直翻转的方法进行扩充, 然后将多个版本的图像双通道分别输入模型得到多个预测值, 并将多个预测值的平均值作为最终的预测值。这样做可以帮助模型进一步提取图片的重要特征, 从而提高模型的准确率。

4.3 实验结果

为了验证提出策略(数据扩充和 TTA)的有效性, 进行了如下 4 组消融试验: (1)无数据扩充无 TTA 的深度学习模型, (2)无数据扩充有 TTA 的深度学习模型, (3)有数据扩充无 TTA 的深度学习模型, (4)有数据扩充有 TTA 的深度学习模型。其中, 深度学习模型包括当前较为流行的 Xception、MobileNetV2、MobileNet、ResNet50、Inception ResNetV2 网络。此外, 本文采用了 Fang 等^[5] 的网络架构作为实验对比。不同网络模型在测试集上的 F_1 分数如表 4 所示。实验结果表明, 加数据扩充和 TTA 策略后, 绝大部分网络模型都有一定的性能提升。其中 Xception 网络加数据扩充和 TTA 策略后在测试集上 α , β 和 $\beta-x$ 的 F_1 分数分别达到了 96.50%, 93.20%, 84.65%, 在 α 和 β 类型黑子分类上达到最优。与之对比, MobileNetV2 网络在加数据扩充和 TTA 策略后在测试集上 α , β 和 $\beta-x$ 的 F_1 分数分别达到了 95.44%, 92.57%, 86.54%, 在 $\beta-x$ 类型黑子分类上有较好的效果。其他深度网络架构 MobileNet、ResNet50、Inception ResNetV2 在太阳黑子分类上虽然不如 Xception、MobileNetV2 网络的效果好, 但在测试集上 α , β 和 $\beta-x$ 的 F_1 分数也能分别达到 90%, 90%, 80% 以上, 远超过 Fang 等^[5] 的三层网络架构(三类 F_1 分数均未达到 70%)。这表明了使用深度网络模型的有效性。此外, 为证明输入双通道数据的有效性, 分别使用白光图作为单通道输入和磁图作为单通道输入训练 Xception 模型。实验结果表明仅使用白光图当作输入, Xception 网络在测试集上 α , β 和 $\beta-x$ 的 F_1 分数分别达到 95.21%, 90.03%, 75.86%。然而, 仅使用磁图当作输入, Xception 网络的 F_1 分数可达到 91.53%, 86.09%, 76.84%。双通道效果相对于白光图单通道输入的网络在 α , β 和 $\beta-x$ 三种类型上分别提升 1.29%, 3.17%, 8.79%; 相对于磁图单通道输入的网络在 α , β 和 $\beta-x$ 三种类型上分别提升 4.97%, 7.11%, 7.81%。这表明使用双通道数据能够提升网络性能。需要指出的是, 本文的 3 层

表 3 二分类混淆矩阵

Table 3 Definition of confusion matrix on binary classification

名称	识别的 α	识别的非 α
真实的 α	T	F
真实的非 α	N	C

表 4 不同深度学习模型的 F_1 分数 (%)
Table 4 F_1 score (%) of different classification methods

类型	α				β				$\beta-x$			
数据扩充	×	✓	×	✓	×	✓	×	✓	×	✓	×	✓
TTA	×	×	✓	✓	×	×	✓	✓	×	×	✓	✓
Xception	94.52	96.04	94.96	96.50	89.33	92.32	90.53	93.20	82.10	82.94	83.41	84.65
MobileNetV2	94.35	94.37	95.79	95.44	90.63	91.49	92.43	92.57	83.11	87.08	83.57	86.54
MobileNet	94.34	95.51	94.65	94.65	90.86	90.26	90.51	89.85	85.05	77.68	82.35	81.06
ResNet50	93.35	93.31	94.19	93.72	86.53	88.78	87.84	89.38	71.84	76.33	71.97	78.34
Inception ResNetV2	95.06	93.60	96.28	94.18	90.00	88.35	91.48	89.30	80.52	76.36	80.00	77.78
3层CNN ⁸	69.64	—	—	—	64.90	—	—	—	64.54	—	—	—
白光Xception	—	—	—	95.21	—	—	—	90.03	—	—	—	75.86
磁图Xception	—	—	—	91.53	—	—	—	86.09	—	—	—	76.84

注 ✓和×分别表示有和没有使用数据扩充和TTA策略,其中在 α 、 β 和 $\beta-x$ 上 F_1 分数最高的用黑体加粗表示。

CNN 网络的准确率并未达到 Fang 等^[5] 的准确率,这是由于本文基于黑子演化时间的缓变性,将数据训练集和测试集按照时间划分,这样训练出来的模型是真实可信且可使用的,而 Fang 等^[5] 在划分数据集时是随机划分的,这样做会导致模型的假准确率较高,即将新数据输入 CNN 模型后的实际分类准确率并不高,即模型的泛化性能不高。

4.4 讨论

通过对大量的 Wilson 山磁分类的太阳黑子的白光图和磁图分析,发现 α 类一般出现在单个太阳黑子中,且 α 类的黑子结构较为单一,所以识别的准确率较高; β 类一般在一个相对规则的黑子群中,并且有较为明显的相反极性之间的划分界限,但也有一些结构特殊的 β 类型黑子,图 2 给出了两种容易被误判的 β 类黑子。从白光图 2(a) 中只能看到一个较为明显的有本影和半影的黑子结构,从磁图 2(c) 中可以看到存在两个相反的极型,但此处的负极性黑子(黑色阴影)群的部分在白光图中并不明显,所以对于此种 β 类型的黑子,很容易被误判为 α 类型。另外从白光图 2(b) 中可以看到存在多个黑子群,从磁图 2(d) 中可以看到不同极性黑子之间的界限并不明显,容易被误判为 $\beta-x$ 类型。这部分特殊结构的 β 型黑子会影响模型对 β 类型分类的准确率,这也是 β 类型的 F_1 分数没有 α 类型的 F_1 分数高的原因; $\beta-x$ 主要出现在一个相对较大且分布不规则的太阳黑子群中,在本实验中,由于 $\beta-x$ 的样本数量较少,还不到 α 类数量的一半,所以在测试集上的准确率不如前两种分类准确

率;此外 $\beta-x$ 类的黑子结构越复杂,出现误判的可能性就越大。

值得一提的是,对于 $\beta-x$ 的分类问题,在测试集上不使用 TTA 数据增强策略会进一步提高准确率,且使用 MobileNetV2 网络的效果优于 Xception。由于深度学习是黑盒模型,难以探究其背后的真正原因。但是,因为 Xception 在 α 和 β 类黑子的分类的 F_1 分数均优于 MobileNetV2,且这两类黑子的数据量更多,所以,在一定程度上可以认为 Xception 网络对黑子磁类型分类的综合性能是最好的。

5 结论

本文基于多种深度学习网络构造太阳黑子 Wilson 山磁分类的自动识别模型,使用 2010 年 5 月至 2015 年 5 月的 SDO/HMI 磁图和白光图作为输入数据学习模型,2015 年 6 月至 2017 年 5 月的双通道图片对模型进行测试。实验结果表明,Xception 模型能进行最优的 Wilson 山磁分类, α 、 β 和 $\beta-x$ 的 F_1 得分分别达到了 97.05%, 93.74%, 84.65%。其中 $\beta-x$ 的 F_1 得分较低的主要原因是其数据量较少。

在深度学习模型的构建中,选择适合的网络模型和策略(数据扩充、TTA 等)对黑子磁类型的分类精度有很大的提升。尽管对图片进行旋转操作来扩充数据,可能对于活动区物理过程的研究不合理,但本文主要任务是根据静态图片来识别黑子的磁类型,从这个角度上来说旋转图片增加数据量是可行的。




图2 两种特殊的 β 类黑子图像。(a)(b)为白光图, (c)(d)为磁图(顶部标注为相应的活动区信息)

Fig. 2 Two kinds of special β -type sunspot images. (a) (b) are white light diagrams, (c) (d) are magnetograms. The top notes are activity area information

在下一步工作中, 计划使用融合集成策略与注意力机制来进一步提高模型精度, 尤其是 β - x 类型的分类准确率, 并且尝试从可解释性机器学习的角度去解决黑子磁分类问题。

致谢 磁图和白光图数据由 SDO/HMI 卫星提供; FITS 文件由 <http://jsoc.stanford.edu/> 提供; SRS 文件由美国海洋局空间天气预报中心(NOAA/SWPC)网站(<https://www.swpc.noaa.gov/>)提供; 数据资源由国家科技基础条件平台—国家空间科学数据中心 (<http://www.nssdc.ac.cn>) 提供。

参考文献

- [1] MCINTOSH P S, The classification of sunspot groups[J]. *Solar Physics*, 1990, **125**(2): 251-267.
- [2] PADINHATTEERI S, HIGGINS P A, BLOOMFIELD D S, *et al.* Automatic detection of magnetic δ in sunspot groups[J]. *Solar Physics*, 2016, **291**(1): 41-53
- [3] FU Xiaona, LIAO Chengwu, BAI Xianrong, *et al.* A detection method for sunspots based on convolutional neural network LeNet-5[J]. *Astronomical Research & Technology*, 2018, **15**(3): 340-346
- [4] LI Ling, CUI Yanmei, LIU Siqing, *et al.* Automatic detection of sunspots and extraction of sunspot characteristic parameters[J]. *Chinese Journal of Space Science*, 2020, **40**(3): 315-322 (李玲, 崔延美, 刘四清, 等. 太阳黑子自动识别与特征参量自动提取[J]. *空间科学学报*, 2020, **40**(3): 315-322)
- [5] FANG Y H, CUI Y M, AO X Z. Deep learning for automatic recognition of magnetic type in sunspot groups[J]. *Advances in Astronomy*, 2019, **2019**(123): 1-10
- [6] HALE G E, ELLERMAN F, NICHOLSON S B, *et al.* The magnetic polarity of sun-spots[J]. *The Astrophysical Journal*, 1919, **49**: 153
- [7] SAMMIS I, TANG F, ZIRIN H. The dependence of large flare occurrence on the magnetic structure of sunspots[J]. *The Astrophysical Journal*, 2000, **540**(1): 583-587
- [8] HE K M, ZHANG X Y, REN S Q, *et al.* Deep residual learning for image recognition[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 770-778
- [9] SZEGEDY C, LIU W, JIA Y Q, *et al.* Going deeper with convolutions[C]//Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015: 1-9
- [10] CHOLLET F. Xception: Deep learning with depthwise separable convolutions [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Hawaii: IEEE, 2017: 1251-1258
- [11] HOWARD A G, ZHU M L, CHEN B, *et al.* MobileNets: efficient convolutional neural networks for mobile vision applications[J]. arXiv preprint arXiv: 1704.04861, 2017
- [12] SANDLER M, HOWARD A, ZHU M L, *et al.* MobileNetV2: inverted residuals and linear bottlenecks[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 4510-4520
- [13] WANG G, LI W, OURSELIN S, *et al.* Automatic brain tumor segmentation using convolutional neural networks with test-time augmentation[C]//Proceedings of international MICCAI Brainlesion Workshop. Cham: Springer, 2018: 61-72

(责任编辑: 孙伟英)