

YIN Yao, LI Yiyang, HUANG Shiyong, XU Sibao, YUAN Zhigang, WU Honghong, JIANG Kui, XIONG Qiyang, LIN Rentong. Magnetic Type Classification of Sunspot Groups Based on Deep Learning (in Chinese). *Chinese Journal of Space Science*, 2025, 45(2): 253–265. CSTR:32142.14. [cjss.2024-0100](#). DOI:10.11728/cjss2025.02.2024-0100

基于深度学习的太阳黑子群磁类型分类*

尹耀 李依洋 黄狮勇 徐思博 袁志刚
吴红红 姜奎 熊启洋 林仁桐

(武汉大学地球与空间科学技术学院 武汉 430072)

摘要 太阳活动作为太阳大气层中能量释放和物质运动的显著表现形式, 是空间天气的主要扰动源, 以太阳黑子为代表的剧烈太阳活动可能导致近地空间环境的剧烈变化, 进而对人类的生产生活产生深远影响. 准确、高效地预报空间天气有助于减少其对人类生产生活的影... (text continues)

关键词 太阳黑子, 深度残差网络, 压缩激励模块, 数据增强, 类激活映射
中图分类号 P354

Magnetic Type Classification of Sunspot Groups Based on Deep Learning

YIN Yao LI Yiyang HUANG Shiyong XU Sibao YUAN Zhigang
WU Honghong JIANG Kui XIONG Qiyang LIN Rentong

(School of Earth and Space Science and Technology, Wuhan University, Wuhan 430072)

Abstract Solar activity, as a significant manifestation of energy release and material movement in the solar atmosphere, is the main disturbance source of space weather. The violent solar activity represented by sunspots may lead to drastic changes in the near-earth space environment, and then have a profound impact on human production and life. Accurate and efficient prediction of space weather is helpful to reduce its impact on human production. In this paper, a magnetic type classification model of sunspot Mount Wilson based on squeeze-and-excitation module and deep residual network is established by us-

* 科技部重点研发项目 (2022YFF0503700) 和国家自然科学基金项目 (42430203, 42441811) 共同资助

2024-08-07 收到原稿, 2024-12-21 收到修定稿

©The Author(s) 2025. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

ing the continuum map and magnetogram map data observed by the HMI instrument on the Solar Dynamics Observatory (SDO) from 2010 to 2017. In order to effectively avoid the problem of model overfitting caused by the continuity of time series, this paper uses the time series segmentation method to divide the data set, and applies the data augmentation strategy combined with the characteristics of sunspot images to improve the generalization ability of the model. The experimental results show that the model proposed in this study can perform the task of sunspot classification accurately, especially in the recognition of complex sunspots, and its recognition ability has been significantly improved compared with traditional methods. In addition, this paper uses the class activation mapping method to visualize the test set samples, analyzes the feature images extracted from the model and the classification basis, so as to improve the interpretability of the model.

Key words Sunspots, Deep residual network, Squeeze-and-excitation block, Data augmentation, Class activation mapping

0 引言

太阳黑子是太阳表面上的阴暗区域,一般成群出现于太阳大气中的光球层,是光球层中温度较低、气压较低、辐射较弱的区域,同时也是磁通量聚集的区域^[1]. 太阳黑子的数量通常用作表征太阳活动强弱的指标. 在太阳活动周期的高年,太阳黑子的数量会明显增多. 长期观测发现,太阳黑子活跃的区域可以产生爆发性的扰动,例如太阳耀斑和日冕物质抛射,从而对地面通信设施和空间中的航天器产生严重危害. 太阳活动区是太阳活动现象汇聚的区域,黑子既是活动区的核心,也是活动区最明显的标志. 在空间环境预报和研究中,活动区的形态特征和磁场特征通常被用作太阳风暴预报的主要影响因子. 因此,准确高效地识别和监测太阳黑子具有重要的研究意义.

太阳黑子的分类问题在 20 世纪初便受到关注. 太阳黑子群随时间不断演化,从而呈现出复杂的结构. 因此,研究提出了一些太阳黑子分类方案,以便于描述太阳黑子群的形态结构信息和磁性信息,目前普遍使用的有 3 种方案,分别是威尔逊山 (Mount Wilson) 分类方案、苏黎世 (Zurich) 分类方案和麦金托什 (McIntosh) 分类方案.

传统的基于统计学的太阳活动研究依赖于观测数据特征的手动提取,然而随着太阳观测数据的不断累积,传统方法无法从海量数据中准确提取太阳活动数据的有效信息. 近年来,机器学习技术取得了长足的发展,机器学习不仅为空间天气预报和建模提供了强大的工具^[2,3],也为太阳活动研究提供了新的研究方向^[4]. 针对以上分类方案,许多研究使用机器学习技

术开展了太阳黑子的识别和分类研究. Nguyen 等^[5]使用苏黎世分类方案,较早地将机器学习技术应用在太阳黑子分类研究中,对数据集中的 2589 个对象和 20 个属性应用了决策树、KNN、LEM2 等算法,结果表明大多数类别都可以取得较高的精度,这表明使用机器学习技术可以实现太阳黑子的特征学习和自动分类. Abd 等^[6]使用支持向量机来解决太阳图像中黑子和黑子群的提取问题. 在对 SOHO/MDI 的全日面连续谱图进行二值化平滑处理和无监督分割后,该方法在太阳黑子的改良苏黎世分类方案上达到了 88.56% 的识别率,同时指出数据集的无监督分割质量是影响分类率的原因之一. Fang 等^[7]基于 SDO/HMI 的数据和威尔逊山分类方案,提出了一种利用卷积神经网络 (Convolutional Neural Network, CNN) 自动识别太阳黑子群磁类型的方法,并研究了以磁图、连续谱图和双通道图像分别作为输入的识别效果,其结果表明以连续谱图单独作为输入数据时识别效果最好, α 型黑子的识别准确率可达 98%. Wang^[8]对 SDO 卫星的 HMI 和 AIA 图像数据做了校正和太阳黑子截取操作,从而建立了包括 7 种太阳黑子类型的数据库,统计了太阳黑子的参数分布特征,研究使用 ResNet-50 作为归类模型,初步实现了太阳黑子的威尔逊山分类方案的自动归类. He 等^[9]提出了 CNSS (CornerNet-Saccade-Sunspot) 模型,以实现太阳黑子群威尔逊山磁分类任务,该模型改进了原始 CornerNet-Saccade 的目标定位和目标检测功能,从而提高了检测性能,其精度大约提升了 6%. 此外,还分析了不同类型太阳黑子群与不同等级太阳耀斑的

出现情况,从而定量地描述太阳黑子群和太阳耀斑之间的关系,统计并分析了太阳黑子群的分布和演化规律. Tang 等^[10]使用了多种 CNN 的变体,并使用集成学习算法 XGBoost 来融合效果最好的前 10 个变体网络的分类结果,以增强网络鲁棒性. 除此之外,还讨论了输入图像尺寸和深度神经网络层数对模型分类性能的影响,以及不同层的特征图像可视化结果. Li 等^[11]基于威尔逊山磁分类方案,测试了当前广泛使用的 Xception, MobileNetV2, ResNet 等深度神经网络的太阳黑子分类性能,结果表明 Xception 网络在 α 和 β 类型黑子的分类上达到最优,而 MobileNetV2 则在 β -X 类型黑子分类上有较好的结果. Fan^[12]在 ResNet 的基础上引入了空洞卷积,通过使用深度可分离卷积替代传统卷积、增加卷积层感受野的方式提高网络的分类精度,实验结果相比传统的 ResNet 取得了更好的分类效果.

需要指出的是,虽然上述研究基于不同的分类方案对太阳黑子群开展了识别和分类,但部分太阳黑子观测数据过于稀少,这限制了基于深度学习的模型分类性能.

本文利用 SDO 搭载的 HMI 仪器观测整理得到的 SHARP 数据,基于威尔逊山分类方案构建了 α , β , β -X 三种类型的太阳黑子连续谱图和磁图数据集. 结合太阳黑子图像的特点,使用随机擦除、水平翻转、垂直翻转、随机平移和随机裁剪五种数据增强策略. 使用嵌入了压缩激励模块的 ResNet-50 作为特征提取和分类模型,实现太阳黑子的特征识别和三元分类. 最后,通过类激活映射 (Class Activation Mapping, CAM) 对测试集部分样本进行了可视化,通过

具体案例分析模型提取的特征图像,解释了模型对太阳黑子群的分类依据,从而增强了研究的可解释性.

1 威尔逊山分类方案

威尔逊山磁分类方案是一种对活动区的磁场和太阳黑子进行分类的方法,于 1919 年在美国加利福尼亚州威尔逊山天文台被提出^[13]. 威尔逊山分类方案最初只有 α , β 和 γ 三种磁性分类,后来于 1965 年增加了 δ 的分类. 根据磁场极性特点,太阳黑子群被分成不同的类型,如表 1 所示.

威尔逊山分类方案根据磁性信息和形态结构信息对太阳黑子群做了详细的分类,本文采用该分类方案进行研究. 需要指出的是,根据统计,近 10 年以来 β - γ , β - γ - δ 和 β - δ 三种类型的太阳黑子群记录次数过少 (总和约为 2000 次),而 γ , δ 和 γ - δ 类型的太阳黑子群则几乎没有记录,相比之下, α 和 β 类型的太阳黑子群出现次数较为频繁,占总记录次数的 85% 以上. 在深度学习的分类问题中,很难为极度匮乏的数据类别训练出一个强泛化能力、非过拟合的通用模型,因此在本研究中对威尔逊山分类方案进行了精简,将除 α 和 β 之外的类别统一归纳为 β -X 类.

2 数据准备

2.1 数据获取与预处理

研究所使用的太阳黑子数据来自 SDO 搭载的 HMI 仪器. 该仪器将观测得到的数据整理归纳为空间天气 HMI 太阳活动区补丁 (SHARP), SHARP 数

表 1 威尔逊山分类方案
Table 1 Mount Wilson classification scheme

类型	分类依据
α	都具有相同的磁极性,包含单颗太阳黑子或一组太阳黑子的活跃区域. 相反的极性对应物仍然存在,但强度微弱或浓度不足以形成太阳黑子
β	至少具有两个相反磁极性的太阳黑子或太阳黑子群的活跃区域. 两种极性之间存在一条简单的中性线
γ	具有磁极性完全混合的太阳黑子的活跃区域
β - γ	至少具有两个相反磁极性的太阳黑子或太阳黑子群,但没有明确定义的中性线划分相反极性的活动区域
δ	极性相反的双极性太阳黑子群,且半影的跨度小于日面 2°
β - δ	具有 β 磁场的活跃区域,并且在单颗半影内至少有一对极性相反的本影
β - γ - δ	具有 β - γ 磁场的活跃区域,并且在单颗本影内至少有一对极性相反的本影
γ - δ	具有 γ 磁场的活跃区域,并且在单颗半影内至少有一对极性相反的本影

数据集的数据计算间隔为 12 min. 由于太阳黑子群的演化存在一定过程, 在短时间内观测到的形态结构不会发生剧烈变化, 因此为了防止数据集过于臃肿, 保证数据集中太阳黑子群形态结构的多样性, 每隔 96 min 选取一次太阳黑子图像. 为了降低投影效应的影响, 只考虑位于中心子午线 $\pm 75^\circ$ 的数据样本. 此外, 与太阳耀斑数据类似, SHARP 以 FITS 的格式存储了太阳黑子数据和文件头信息, 文件头中的 NOAA_NUM 参数标识了该活动区可能对应的 NOAA 活动区的数量, 为了保证数据源的确定性, 仅选择从属于单个特定的活动区的 SHARP 数据. SHARP 为观测到的每个太阳活动区提供了连续谱图 (Continuum) 和磁图 (Magnetogram) 数据, 因此可以掌握太阳黑子群的形态结构信息和磁极性信息, 从而满足威尔逊山分类方案的需求. 最终收集的数据集包括连续谱图和磁图两种存储格式, 这两种图像一一对应, 表示对同一时间、同一区域内的太阳黑子群的不同观测方式. 数据集的时间范围为 2010 年 5 月 1 日至 2017 年 12 月 12 日, 包括 5276 个 α 类、7849 个 β 类以及 2516 个 β -X 类太阳黑子群. 在面对观测数据量有限, 特别是 β 类样本的稀缺性时, 模型的泛化能力可能会受到显著影响. 为了克服这一难题, Sun 等^[14] 通过深度学习模型对庞大的 3 亿张图像数据集进行了深入分类, 其实验结果揭示了一个重要趋势: 深度神经网络的性能随着训练数据量的增加而呈现出对数增长的模式. 这一发现通过扩展数据集规模, 可以显著提升模型的学习能力. 此外, Tang 等^[10] 采取了一种综合方法, 通过应用集成学习算法 XG-Boost 并结合数据增强技术, 有效提升了模型的性能. 即便在 β 类样本数量不足的情况下, 该方法也能够实现满意的预测效果.

在本研究中, 借鉴了前人所使用的方法, 采用数据增强技术, 旨在通过这一策略, 来应对样本不平衡的挑战. 这些图像的尺寸并不统一, 不能直接输入网络模型. 为了满足深度学习网络的输入要求, 在图像预处理阶段, 调整图像尺寸是一个关键步骤, 尤其是在处理太阳黑子图像时, 保持图像的真实性和完整性至关重要. 原始图像的宽高比可能与本文设定的目标尺寸 (如 224×224 pixel) 不一致, 直接调整尺寸可能会导致图像的形变, 这种形变可能会影响后续的特征提取和分类准确性. 为了最小化这种形变和信息丢

失, 采用了双线性插值技术. 双线性插值是一种在图像缩放中广泛使用的插值方法, 其通过对目标像素周围的 4 个最近邻像素进行加权平均来估算目标像素的值. 这种方法能够有效地减少图像在放大或缩小过程中的失真, 尤其是在保持图像细节和边缘信息方面表现优异. 与传统的最近邻插值相比, 双线性插值提供了更平滑的图像过渡, 减少了锯齿效应, 同时避免了过度模糊的问题. 在先前的许多研究工作中, 例如 Li 等^[11] 基于威尔逊山磁分类方案, 将输入图像调整为 160×320 pixel, 以适应 ResNet, Inception, Xception 和 MobileNet 等神经网络模型的输入要求. 本文调整后的连续谱图和磁图按照时间顺序以 8:2 的比例划分为训练集和测试集. 以 2015 年 7 月 28 日为基准, 基准日前的数据作为训练集, 基准日后的数据作为测试集. 这些数据集的分布详见表 2.

按照时序分割而非随机分割数据集的原因是同一活动区内的太阳黑子群在短时间内的形态结构相似, 随机分割方法可能会出现同一活动区内的太阳黑子图像被同时划分到训练集和测试集中, 从而导致数据泄露的问题. 在深度学习中, 模型训练之前一般要对输入的图像数据进行归一化, 也即将图像的特征值大小调整到相近的范围, 从而可以采用统一的学习率来加速模型训练, 保证模型的无偏性和平稳收敛. 本研究中, 输入图像包括连续谱图与磁图. 对于连续谱图, 使用 MinMaxScaler 进行如下归一化处理:

$$X_{\text{std}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}}, \quad (1)$$

$$X_{\text{scaled}} = X_{\text{std}} \times (X_{\max} - X_{\min}) + X_{\min}. \quad (2)$$

其中, X_{std} 表示标准化结果, X 表示要归一化的连续谱图数据, $X_{\max}$ 和 $X_{\min}$ 分别表示要映射到的区间的最大值和最小值, X_{scaled} 表示归一化结果. 在本研究中, 将连续谱图归一化到 0~1, 因此 $X_{\max}$ 取 1, $X_{\min}$ 取 0, 此时标准化结果即为归一化结果. 相比磁图, 连续谱

表 2 数据分布
Table 2 Data distribution

类型	总数据集	训练集	测试集
	2010年5月1日至 2017年12月12日	2010年5月1日至 2015年7月27日	2015年7月28日至 2017年12月12日
α	5276	3989	1287
β	7849	6580	1269
β -X	2516	1941	575

图记录了太阳黑子更多的形态结构信息, 这样的归一化处理方式可以将图像的背景, 即太阳黑子群外的其他信息调整为更接近 0, 从而有助于模型对太阳黑子形态结构特征的识别.

对于磁图数据, 使用 H 方法进行归一化:

$$X_{\text{nor}} = H \left(\frac{X_i}{X'_{\text{max}}} \right), \quad (3)$$

$$H(x) = \begin{cases} 1, & x \geq 1; \\ x, & -1 < x < 1; \\ -1, & x \leq -1. \end{cases} \quad (4)$$

其中, X_{nor} 表示磁图归一化后的数据, X_i 表示磁图原始数据, X'_{max} 表示磁场强度的最大阈值, 这里取 800, 表示当某像素点对应的磁场强度大于等于 800 时, 将该像素点对应的灰度值赋值为最大 255, 并在归一化后置为 1, 当磁场强度小于等于 -800 时, 归一化后的数据为 -1. 磁图样本归一化后的数据范围为 -1~1, 这样做一方面保留了原始数据的磁场极性信息, 另一方面也增加了图像不同区域的对比度, 有助于突出图像的特征.

2.2 数据增强

数据增强是从现有数据中人工生成新数据的过程, 通过先验知识可以使用少量的数据来产生更多的相似数据, 从而丰富数据集. 一方面, 由于太阳黑子群磁类型识别与分类属于小样本学习, 用于模型训练的各类型黑子群数据量都不大, 因此样本特征的多样性不足, 难以刻画完整的样本特征分布, 甚至出现模型过拟合. 另一方面, Sun 等^[14]使用深度学习模型对 3 亿张图像进行分类, 其实验结果表明深度神经网络的性能随训练数据量的增加呈对数增长. 基于以上原因, 本研究使用数据增强技术来扩充数据以进行模型训练.

常用的数据增强方法包括图像的几何变换和像素变换. 在本研究中, 根据太阳黑子连续谱图和磁图的特点, 使用了 5 种数据增强方式, 分别是随机擦除、水平翻转、垂直翻转、随机平移和随机裁剪, 以磁图样本为例, 原始图像和使用各种数据增强后的图像如图 1 所示.

随机擦除是指随机选择图像的矩形区域, 然后使




图 1 数据增强图像

Fig. 1 Date augmentation image

用随机值擦除该矩形区域的像素,从而使原始图像出现被遮挡效果,以此帮助模型提高对遮挡等异常情况的鲁棒性^[15].当数据集中的太阳黑子均清晰可见、没有遮挡时,训练出的模型可能会得到较高的准确率,但其泛化能力却是有限的.而人为手动在数据集中设置遮挡是一个费时费力的过程,随机擦除的出现解决了这一问题.随机擦除是一种轻量级的方法,不会在深度学习模型中引入额外的参数,导致额外的内存消耗,可以方便地集成到各种深度学习模型中.图像几何变换的实施基础是CNN的位移不变性.水平翻转、垂直翻转、随机平移和随机裁剪是几种典型的图像几何变换,实现起来较为简单,但同样能够增加模型的泛化性能,使模型提高对不同角度或不同尺寸的太阳黑子图像的识别能力.

3 模型构建

3.1 SE-ResNet

Squeeze-and-Excitation Networks (SENet) 获得了2017年视觉识别挑战赛 ILSVRC 的冠军^[16].该网络相比于之前的网络,其最大的创新点是针对网络表达能力的改造,这一功能的实现依赖于SE模块(Squeeze-and-Excitation Module)的提出.在He等^[17]提出深度残差网络后,ResNet开始迅速普及,并受到广泛开发.然而以ResNet和Inception等为代表的网络属于串联型CNN模型,其特有的网络结构使得输入数据的全局信息在复杂的特征计算和提取过程中逐渐被转化或丢失,很难传递到模型的尾部.部分全局信息的丢失会导致网络的识别准确度存在或多或少的下降.而SE模块即是通过引入通道注意力机制来保证全局信息的传递.通道注意力机制将图像的全局信息压缩并在通道维度上进行特征学习,可以使网络自动地关注并提取输入中更重要的信息,如各种太

阳黑子群的形态结构特征,从而提高模型的性能和泛化能力.SE模块的主要结构如图2所示.

SE模块的过程主要分为两步,即压缩(Squeeze)和激励(Excitation).图2中输入图像数据为 x ,图像的宽度为 W ,高度为 H ,通道数为 C .SE模块的第一步是对输入数据进行全局平均池化(Global Average Pooling, GAP).全局平均池化是一种在CNN的池化层中常用的池化方法,是一种将整个特征图的信息进行汇聚的池化操作.在按通道进行特征压缩后,经过全局平均池化得到的结果可以认为是整个特征图的全局信息.GAP之后的结果称为汇聚特征向量,其维度为 $1 \times 1 \times C$,浓缩了输入图像数据的空间信息,因此具有全局感受野.压缩过程应用的全局平均池化具有很多优点,例如减少模型的参数量和计算量从而提高计算效率、较完整地保留原始图像的空间信息特征、防止模型的过拟合等,并且由于全局平均池化是在空间维度进行特征压缩,因此对输入图像或输入特征的尺寸限制并不严格.SE模块的第二步激励过程主要是通过两次全连接来实现的.引入两层全连接层的作用是表达各通道特征之间的非线性关系及提取出非互斥的关系,从而综合这些通道的特征值,最终计算出通道之间的相关性,即图2中展示的 C 个通道不同的颜色.经过压缩和激励操作之后,计算得出的通道相关性通过缩放过程加权到原始特征图中,实现“加权平均”的概念,即重新校准特征图.加权后的特征图数据为 $\tilde{x}$,其宽度、高度和通道数相比输入并未发生变化,而SE模块的作用即体现在输入数据各个通道的权重被计算并保留了下来.

SE模块较为突出的一个优点是该结构是嵌入式的,可以比较灵活地集成到之前广泛使用的网络结构中,如ResNet.SE模块被嵌入到ResNet残差结构中的残差学习分支中,经过全局平均池化、两次全连接、ReLU和Sigmoid激活函数非线性映射处理后返




图2 SE模块结构

Fig. 2 Structure of the SE module

回主分支. ReLU 和 Sigmoid 激活函数的计算公式为

$$f(x) = \max(0, x), \quad (5)$$

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (6)$$

SE 模块的结构并不复杂, 在将 SE 模块集成到 ResNet-50 网络结构中之后, 网络总体的运算量约为 3.87 GFLOPs, 而原始 ResNet-50 的运算量约为 3.86 GFLOPs, 只增加了 0.26% 的运算量, 而参数大约增加了 10%. 集成 SE 模块后的模型计算量几乎没有增加, 出现这种现象的原因是 SE 模块中的降维与升维过程, 在汇聚特征向量经过两次全连接层分别对其进行降维和升维操作, 使用压缩比参数 r 调整卫生降维比例, 以控制 SE 模块的计算量, 实验表明当 $r=16$ 时, 模型性能与计算量达到最优平衡. 经过嵌入 SE 模块后, 集成后的 ResNet-50 性能可以达到与 ResNet-101 持平的结果, 而计算量却远比 ResNet-101 小, 由此可见 SE 模块的关键作用. 通过显式地建模通道之间的相互依赖关系, SE 模块可以自适应地重新为各通道分配特征权重, 这意味着 SE 模块可以在保留输入数据的全局信息的情况下, 使用全局信息选择性地强化信息丰富的特征通道, 并弱化信息量较少的特征通道.

3.2 类激活映射

CAM 是一种专门为 CNN 设计的可解释性算法^[18], 广泛应用在计算机视觉领域的图像分类、图像识别等任务中. 深度学习的可解释性是目前广泛研究的一个课题. 虽然深度神经网络的结构非常明确, 但本质上仍然是一个黑盒模型, 无法得知在将输入数据送入网络后为什么会得到特定的结果, 输入数据在神经网络中的信息流动方式是不可见的. 可解释性的研究即是在模型达到较高性能的基础上, 试图理解神经网络模型做出决策的依据. 具体到太阳黑子磁类型分类研究中, 使用 CAM 开展可解释性研究有助于理解模型对不同类型太阳黑子群做出分类的依据.

由于 CNN 的特征提取过程主要在卷积层中完成, 因此其最后一层卷积层的输出即是最完整的特征图像, 含有最为丰富的图像类别信息, 可以代表网络学习的结果, 因此 CAM 的可视化对象是最后一层卷积层. Zhou 等^[18]认为全局平均池化层具有获取图片位置信息和局部定位的能力, 因此考虑使用全局平均池化层替换原结构的全连接层, 以计算每张特征图的

均值, 再对全局平均池化的结果加权求和得到类激活图. CAM 的巧妙之处在于这里的加权求和操作所用的权重即是原全连接层的权重. 设最后一层卷积层含有 n 张特征图像, 记为 $A^1, A^2, \dots, A^n$, 全连接层中的一个神经元有 n 个权重, 这里的每个神经元即对应一个类别, 设第 i 个全连接层神经元的权重为 $w_1, w_2, \dots, w_n$, 则第 x 类的 CAM 的计算公式为

$$L_{CAM}^x = \sum_{i=1}^n w_i^x A^i. \quad (7)$$

根据式 (7) 计算得到的 CAM 大小与最后一层特征图的大小一致, 之后将其上采样至原图大小即可. 类激活可视化得到的结果即为所分析类别的热力图, 通过热力图可以直观地看出模型通过图像中的哪些像素点将图片分为对应的类别, 从而使模型具有一定的可解释性.

3.3 训练过程

深度学习网络模型的性能在很大程度上受超参数设置的影响. 在本模型中主要的超参数包括 Batch size 批大小、Learning rate 学习率、Epoch 周期等. Batch size 决定了梯度下降的方向. 较小的 Batch size 可能导致模型难以收敛, 而较大的 Batch size 则容易使模型陷入局部最优, 导致性能下降. Batch size 的取值通常是 2 的幂次方. 在本模型中经过实验发现, 当 Batch size 取 16 时模型性能较好. 学习率是最重要的超参数, 在模型中引入了动态调节学习率模块 StepLrUpdater, 当连续 40 个 Epoch 的验证损失没有改善时, 学习率将降低到原来的 0.1 倍. 初始学习率与 Batch size 有关. Epoch 是指对整个数据集进行迭代的过程, 为了保证训练的有效性, 将 Epoch 设置为 100. Momentum 的作用是模拟二阶梯度, 加速优化过程, 提高优化算法的性能. 引入此参数后, 优化器参数更新的方向与当前梯度和先前累积的梯度方向都相关. 较大的动量意味着更新过程受前一次更新的影响更大. 在这里选择了经验值 0.9. 此外, 研究中在训练模型时使用了预训练权重. 预训练权重是指在大规模数据集上预先训练好的网络权重组, 由于其所使用的数据集含有数量巨大的类别, 可以学习到普遍的特征, 因此训练出的权重是普遍通用的. 使用预训练权重的模型在微调时可更快收敛, 而不使用预训练权重则会导致训练从 0 开始, 从 0 开始的训练会因为权值的随机性导致网络特征提取不明显. 本研究使用

的预训练权重是在 ImageNet 数据集上训练得到的, 具有较强的普适性.

在应用上述超参数设置后, 在未使用预训练权重时模型在前 40 个 Epoch 内的验证精度存在剧烈的振荡, 这一现象在以连续谱图为输入的模型中尤其明显, 在第 40 个 Epoch 时出现第一次学习率衰减, 此时模型趋于收敛, 但验证精度并不高. 在模型中引入预训练权重后, 整体的验证精度和训练损失有了较大程度的改善, 其中连续谱图的训练损失下降到 0.05 左右, 而磁图的训练损失则更低. 在第一次学习率衰减以前, 虽然训练损失较高, 但整体上仍然呈下降趋势, 说明网络优化的方向是正确的. 在第二次学习率衰减之后, 模型整体性能趋于稳定, 说明此时的学习率已经处于较优水平. 此外, 以磁图为输入的模型训练过程相比连续谱图更为平稳, 经分析发生该现象的主要原因是磁图样本更适合预训练模型, 即在使用大量数据的 ImageNet 上进行训练得到的预训练权重可以比较轻松地进行磁图样本的识别和分类.

4 评价体系

在分类问题中, 混淆矩阵^[19,20]常被用来总结模型分类结构和评估模型的性能, 二分类混淆矩阵的结构如表 3 所示. 其中, 被正确分类为正类的磁图样本称为真阳性 (True Positive, TP), 被正确分类为负类的磁图样本称为真阴性 (True Negative, TN), 被错误分类为正类的磁图样本称为假阳性 (False Positive, FP), 被错误分类为负类的磁图样本称为假阴性 (False Negative, FN).

在太阳黑子三元分类问题中, 若 α 类为正类, 则将 β 类和 β -X 类统一作为非正类 (负类), 因此混淆矩阵的概念仅需稍作修改即可用于本文的研究. 本研究使用 F_1 分数和准确率两种指标来评估模型的性能. 以混淆矩阵为基础, 模型的召回率 (R)、准确率 (A) 和精确率 (P) 可以由以下公式计算:

表 3 混淆矩阵
Table 3 Confusion matrix

	预测为正类	预测为负类
观测为正类	True Positive (TP)	False Negative (FN)
观测为负类	False Positive (FP)	True Negative (TN)

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}}, \quad (8)$$

$$A = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{FN} + N_{TN}}, \quad (9)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}}. \quad (10)$$

其中, 召回率的含义是在观测值为正类的样本中被预测为正类样本的概率, 反映模型正确预测正样本全面度的能力. 准确率是指在所有样本中预测正确的样本数的比例, 表示整体 (包括正样本和负样本) 的预测准确程度. 精确率是在预测值为正类的样本中实际为正类样本的概率, 表示对正样本结果的预测准确程度. 由于召回率和精确率在普遍情况下存在负相关关系, 为了综合评估分类器的性能, 可以使用 F_1 分数 (F_1 Score) 来兼容两个指标. F_1 分数是统计学中衡量模型性能的常用指标, 被定义为精确率和召回率的调和平均, 其计算公式如下:

$$F_1 = 2 \times \frac{PR}{P + R}. \quad (11)$$

F_1 分数的取值范围为 0~1, 其值越接近 1 表示模型的性能越好, 越接近 0 则表示模型的性能越差.

5 结果与分析

5.1 连续谱图结果

研究分别训练了连续谱图样本和磁图样本两个分类模型, 并分别进行了预测. 连续谱图的预测结果混淆矩阵如表 4 所示. 从表 4 可以发现, 模型正确地识别并分类了大部分连续谱图样本, 表现为以下混淆矩阵的矩形主对角线样本数占主导地位.

根据以上混淆矩阵可以计算得到模型的 F_1 分数和准确率, 为了更全面地评估模型, 表 5 列出了本模型的性能指标与 Fang 等^[7] 和 Tang 等^[10] 结果的对比. 从表 5 可以发现本研究的 α 类 F_1 分数稍低于另外两类研究, 而 β 类和 β -X 类 F_1 分数则高于 Tang

表 4 连续谱图预测结果
Table 4 Prediction results of continuum map

	α	β	β -X
α	5916	377	37
β	323	8566	525
β -X	138	179	2701

表 5 连续谱图性能指标的模型对比

Table 5 Comparison of performance metrics of continuum map by different models

模型	F_1 分数			准确率		
	α	β	β -X	α	β	β -X
本研究	0.9311	0.9242	0.8601	0.9346	0.9099	0.8950
Ref.[7]	0.9657	0.9159	0.9445	0.9850	0.8850	0.9575
Ref.[10]	0.9542	0.91	0.8219	0.9559	0.9073	0.8257

等^[10], 详细的讨论将在磁图结果的对比后进行.

5.2 磁图结果

磁图的预测结果混淆矩阵如表 6 所示. 其中在 α 类的识别中取得了较高的精度, 仅有约 3.27% 的样本被错误分类为 β 类和 β -X 类. 磁图结果的对比如表 7 所示.

本研究与 Fang 等^[7] 和 Tang 等^[10] 均采用威尔逊山分类方案, 并将太阳黑子群分为 α , β 和 β -X 三类. 其中 Fang 等^[7] 分别研究了连续谱图和磁图作为输入的模型, 而 Tang 等^[10] 则将连续谱图和磁图拼接为两帧单通道数据作为输入. 在连续谱图测试结果中, Fang 等^[7] 的结果最为精确. 但需要指出的是, Fang 等^[7] 在划分数据集时采用了随机划分的方法. 在处理太阳活动区和太阳黑子群数据时, 随机分割法可能会导致同一活动区内的太阳黑子群被分别划分到训练集和测试集中, 从而出现数据泄露, 导致模型测试结果偏高. 相比 Tang 等^[10], 本研究的优势在于 β -X 类的 F_1 分数和准确率更高, 出现这一现象的原因在于本研究使用了以随机擦除为代表的多样化数据增强策略, 导致训练后的模型拥有更强的复杂黑子群识别能力, β -X 识别能力更强的现象同样出现在磁图测试结果中.

5.3 可视化结果

在完成对模型的测试后, 本文同样开展了深度学习模型的可解释性研究, 即使用 CAM 来进行可视化,

表 6 磁图预测结果

Table 6 Predicted results of magnetogram map

	α	β	β -X
α	6123	199	8
β	423	8684	307
β -X	76	221	2721

能够帮助洞察模型在处理图像时所关注的特征. 通过将这些特征映射转换为热力图, 能够直观地观察到模型在进行分类决策时所重视的图像区域. 在这些热力图中, 颜色的深浅代表了权重的大小, 权重越大, 说明对应的特征图越重要, 对分类结果的贡献也越大. 测试集中样本的可视化结果案例一如图 3 所示.

从图 3 可以看出, 对于较简单的测试样本, 模型可以较精确地定位到黑子群的位置, 其将该样本正确分类为 α 类黑子的依据主要为热力图中的红色区域.



测试集中样本的可视化结果案例二如图 4 所示. 热力图显示模型仍然正确定位到了黑子群出现的主要区域, 与案例一 α 类黑子群不同的是, 模型在主要识别到红色区域黑色负极性黑子的同时, 也同样关注了淡黄色区域的白色正极性黑子. 由于模型同时捕捉到该样本具有双极性的太阳黑子, 并且正负极性之间具有简单而明显的区分, 因此将其正确分类为 β 类型. 分类模型的准确性通过如上识别机制得以体现.

测试集中样本的可视化结果案例三如图 5 所示.

表 7 磁图性能指标的模型对比

Table 7 Comparison of performance metrics of magnetogram map by different models

模型	F_1 分数			准确率		
	α	β	β -X	α	β	β -X
本研究	0.9455	0.9379	0.8989	0.9673	0.9225	0.9016
Ref.[7]	0.9240	0.8123	0.8805	0.9575	0.7625	0.9025
Ref.[10]	0.9542	0.91	0.8219	0.9559	0.9073	0.8257

图3 案例一的黑子群 α 类型原始图与其类激活热力图Fig. 3 Original map of sunspot group α type, and the heat map of its class activation in Case 1图4 案例二的黑子群 α 类型原始图与其类激活热力图Fig. 4 Original map of sunspot group α type, and the heat map of its class activation in Case 2

热力图揭示了模型能够成功定位黑子群出现的区域。由于太阳黑子区域相对较为狭小,且包含的信息量有限,其特征不够显著。因此,在黑子周围可能会出现一些与黑子特征相似的小区域,这些区域很可能是噪声。这些噪声的存在很容易对小黑子区域的特征提取造成干扰。模型在特征提取过程中同时捕获了黑子区域和这些噪声区域的特征,这导致 α 类黑子群被误判为 β 类型。

测试集中样本的可视化结果案例四如图6所示。热力图有效地帮助模型定位了黑子群出现的区域。然而,图像的某些特性导致其清晰度不足,这使得黑子

的正负极性难以辨认,即便识别也会遇到困难。在这种情况下,模型倾向于将这些不清晰的黑子视为一个统一的区域。这种识别上的偏差可能导致 β 类黑子群被误判为 α 类型的情况发生。

测试集中案例五样本的可视化结果如图7所示。利用热力图,模型能够高效识别黑子群的分布区域。然而由于图像获取角度的限制,图像中的关键特征过于集中,具体来说,这种角度导致的信息不足使得黑子的特征变得模糊,进而影响了磁场数据的精确度。这种特征识别上的困难,尤其是在复杂的 β -X类黑子群的案例中,有时会导致模型将其误判为 α 类型。

6 结论

研究提出了一种基于SE-ResNet的太阳黑子群识别和分类模型,该模型能够对太阳黑子的连续谱图和磁图观测样本进行准确分类。研究所用太阳黑子数据来自SDO/HMI仪器观测整理得到的SHARP数据集。为了保证原始数据中太阳黑子群的多样性,每隔96 min选取一次太阳黑子图像,最终收集了2010年5月1日至2017年12月12日的太阳黑子连续谱图和磁图数据,并通过时序分割法划分数据集。对于连续谱图采用MinMaxScaler归一化策略,以突出连续谱图中太阳黑子群的形态结构信息;对于磁图则采用 H 归一化策略,以增加磁图中不同区域的对比度。为了完整刻画样本的特征分布,结合太阳黑子图像的特点,使用随机擦除、水平翻转、垂直翻转、随机


图 5 案例三的黑子群 α 类型原始图与类激活热力图

Fig. 5 Original map of sunspot group α type, and the heat map of its class activation in Case 3


图 6 案例四的黑子群 α 类型原始图与其类激活热力图

Fig. 6 Original map of sunspot group α type, and the heat map of its class activation in Case 4


图 7 案例五的黑子群 α 类型原始图与其类激活热力图

Fig. 7 Original map of sunspot group α type, and the heat map of its class activation in Case 5

平移和随机裁剪五种数据增强策略,降低了模型的过拟合风险,提高了模型的性能与复杂黑子群的特征提取能力. 基于太阳黑子的威尔逊山分类方案,将太阳黑子分为 α 、 β 和 β -X 三类,并使用嵌入了压缩激励模块的 ResNet-50 作为特征提取和分类模型. 在连续谱图的测试结果中, α 类型的 F_1 分数为 0.9311, β 类型的 F_1 分数为 0.9242, β -X 类型的 F_1 分数为 0.8601; 在磁图的测试结果中, α 类型的 F_1 分数为 0.9455, β 类型的 F_1 分数为 0.9379, β -X 类型的 F_1 分数为 0.8989, 模型对于 α 类型黑子的识别能力与前人研究持平, 在 β 和 β -X 类型黑子的识别能力上则取得了较大的突破. 此外, 本研究应用 CAM 方法验证了模型的分类结果, 通过可视化测试集的样本分析了模型提取到的特征图像, 对所使用的模型加以解释, 以此反映模型的优劣, 从而增强研究的可解释性.

CAM 的结果直观地表明, 本研究构建的太阳黑子群识别和分类模型能够较为精确地识别不同类型的太阳黑子. 以上结果表明, 本文提出的基于数据增强策略和 SE-ResNet 网络的太阳黑子群识别和分类模型可以显著提高太阳黑子群磁类型分类的精度, 并能为未来太阳黑子分类和太阳物理领域的研究提供重要的参考.

在本研究中, 采用了时序分割方法来划分训练集和测试集, 以确保模型能够在时间上保持一定的泛化能力. 然而, 对于太阳黑子群的长期演变规律的深入分析确实是研究的一个局限, 在未来的研究中可以考虑引入专门处理时间序列数据的模型, 例如长短期记忆网络 (Long Short-Term Memory, LSTM) 或时间卷积网络 (Temporal Convolutional Network, TCN), 以更好地捕捉太阳黑子群的长期演变特征. 此外, 选择 ResNet-50 模型作为基准, 对 SHARP 数据集进行了初步验证. ResNet-50 作为一个广泛认可的基准模型, 提供了一个坚实的起点, 以便能够探索和评估本文提出的方法. 为了全面评估模型的性能并进行深入的比较分析, 在未来将对比不同架构的模型, 包括最新的深度学习架构如 Transformer, 以及引入更多多样化的太阳观测数据集, 对模型性能进行全面评估. 在未来的研究中, 计划为太阳黑子群数据引入基于颜色空间变换的数据增强策略, 例如调整黑子群样本的对比度、亮度、饱和度, 以及添加高斯噪声等, 从而使数据集样本的特征趋于多元化. 此外, 部分研究表明图像样本的分辨率对模型结果存在一定影响^[21], 因此使用超分辨率技术构建较高分辨率的太阳黑子群数据集也是后续的一个重要研究方向.

参考文献

- [1] CHENG Shu, SHI Yaolin, ZHANG Huai. Predicting sunspot variations through neural network[J]. *Journal of University of Chinese Academy of Sciences*, 2022, **39**(5): 615-626 (程术, 石耀霖, 张怀. 基于神经网络预测太阳黑子变化[J]. *中国科学院大学学报*, 2022, **39**(5): 615-626)
- [2] CHEN Z, LIAO W T, LI H M, *et al.* Prediction of global ionospheric TEC based on deep learning[J]. *Space Weather*, 2022, **20**(4): e2021SW002854
- [3] CHEN Z, ZHOU K C, LI H M, *et al.* Global TEC map fusion through a hybrid deep learning model: RFGAN[J]. *Space Weather*, 2023, **21**(1): e2022SW003341
- [4] YANG Q L, CHEN Z, TANG R X, *et al.* Image super-resolution methods for FY-3E X-EUVI 195 Å solar images[J]. *The Astrophysical Journal Supplement Series*, 2023, **265**(2): 36
- [5] NGUYEN T T, WILLIS C P, PADDON D J, *et al.* Learning sunspot classification[J]. *Fundamenta Informaticae*, 2006, **72**(1/2/3): 295-309
- [6] ABD M A, MAJED S F, ZHARKOVA V. Automated classification of sunspot groups with support vector machines[M]//Elleithy K, Sobh T, Iskander M, *et al.* *Technological Developments in Networking, Education and Automation*. Dordrecht: Springer, 2010: 321-325
- [7] 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**(1): 9196234
- [8] WANG Yani. Automatic Classification of Sunspots Using Convolutional Neural Networks[D]. Harbin: Harbin Institute of Technology, 2020 (王雅妮. 利用卷积神经网络自动归类太阳黑子[D]. 哈尔滨: 哈尔滨工业大学, 2020)
- [9] He Y B, Yang Y F, Bai X Y, *et al.* Research on Mount Wilson magnetic classification based on deep learning[J]. *Advances in Astronomy*, 2021, **2021**(1): 5529383
- [10] TANG R X, ZENG X W, CHEN Z, *et al.* Multiple CNN variants and ensemble learning for sunspot group classification by magnetic type[J]. *The Astrophysical Journal Supplement Series*, 2021, **257**(2): 38
- [11] LI Shuxin, ZHAO Xuebin, CHEN Jun, *et al.* Recognition method for mount Wilson magnetic type of sunspots based on deep learning[J]. *Chinese Journal of Space Science*, 2022, **42**(3): 333-339 (李书馨, 赵学斌, 陈君, 等. 基于深度学习的太阳黑子 Wilson 山磁类型识别方法[J]. *空间科学学报*, 2022, **42**(3): 333-339)
- [12] FAN Shiming. Research on sunspot classification method based on improved ResNet algorithm[J]. *Modern Electronics Technique*, 2024, **47**(5): 80-84 (樊石鸣. 基于改进 ResNet 算法的太阳黑子分类方法研究[J]. *现代电子技术*, 2024, **47**(5): 80-84)
- [13] HALE G E, ELLERMAN F, NICHOLSON S B, *et al.* The magnetic polarity of sun-spots[J]. *Astrophysical Journal*, 1919, **49**: 153
- [14] SUN C, SHRIVASTAVA A, SINGH S, *et al.* Revisiting unreasonable effectiveness of data in deep learning era[C]//Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 843-852
- [15] ZHONG Z, ZHENG L, KANG G L, *et al.* Random erasing data augmentation[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington: AAAI Press, 2020: 13001-13008
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt

- Lake City: IEEE, 2018: 7132-7141
- [17] 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
- [18] ZHOU B L, KHOSLA A, LAPEDRIZA A, *et al.* Learning deep features for discriminative localization[C]//Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 2921-2929
- [19] AMIN F, MAHMOUD M. Confusion matrix in binary classification problems: A step-by-step tutorial[J]. *Journal of Engineering Research*, 2022, **6**: T1-T12
- [20] ZHANG Kaifang, SU Huayou, DOU Yong. A new multi-classification task accuracy evaluation method based on confusion matrix[J]. *Computer Engineering & Science*, 2021, **43**(11): 1910-1919 (张开放, 苏华友, 窦勇. 一种基于混淆矩阵的多分类任务准确率评估新方法 [J]. *计算机工程与科学*, 2021, **43**(11): 1910-1919)
- [21] LIU S X, XU L, ZHAO Z R, *et al.* Deep learning based sol-

ar flare forecasting model. II. influence of image resolution[J]. *The Astrophysical Journal*, 2022, **941**(1): 20

作者简介



尹 耀 男, 1999 年 1 月出生于湖北省潜江市, 现为武汉大学地球与空间科学技术学院硕士研究生, 主要研究方向为机器学习识别磁重联和空间天气预报建模.

E-mail: yaoyin@whu.edu.cn



黄狮勇 (通信作者) 男, 1986 年 1 月出生于江西省赣州市, 现为武汉大学地球与空间科学技术学院教授, 主要研究方向为磁层物理、磁重联、等离子体湍流、地磁尾动力学过程、卫星数据处理算法、行星物理和机器学习在空间天气中的应用.

E-mail: shiyonghuang@whu.edu.cn