

GUO Dalei, ZHANG Zhen, ZHU Lingfeng, XUE Bingsen. Generative Model-based of Flare Hierarchic Recognition and Forecast of Extreme Ultraviolet Images in Solar Active Region (in Chinese). *Chinese Journal of Space Science*, 2023, **43**(1): 60–67. DOI:10.11728/cjss2023.01.220214015

太阳活动区 EUV 图像的生成式模型 耀斑分级与预报*

郭大蕾^{1,2} 张 振^{1,2} 朱凌锋¹ 薛炳森³

1(中国科学院自动化研究所 北京 100190)

2(中国科学院大学人工智能学院 北京 100049)

3(国家卫星气象中心 北京 100081)

摘 要 近年来,不断发射的空基观测台持续传回海量日面图像及日地间气象数据,为采用人工智能技术对太阳活动进行预报预警提供了数据基础。但是,极端天气爆发少,样本量较少;中等程度爆发稍多,样本量较多;常规无爆发天气常见,样本较为集中,样本不均衡状况严重影响机器学习方法在空间天气领域的广泛应用。本文面向多源多通道多尺度日面图像信息,构建了来自 SOHO 和 SDO 的 1996–2015 年日面活动区图像数据集;针对数据分布的不平衡,对太阳活动区图像作耀斑分级与预报。在对比分析元学习算法的基础上,设计了结合分类头设计和卷积核初始化的生成式模型;在使网络轻量化的基础上,能够将 M 和 X 级耀斑预报的检测率指标相较于普通的深度学习模型和无监督度量式模型分别提升 10% 和 7%。

关键词 日面图像, 耀斑, 分级, 生成式模型, 人工智能

中图分类号 P353

Generative Model-based of Flare Hierarchic Recognition and Forecast of Extreme Ultraviolet Images in Solar Active Region

GUO Dalei^{1,2} ZHANG Zhen^{1,2} ZHU Lingfeng¹ XUE Bingsen³

1(Institute of Automation, Chinese Academy of Sciences, Beijing 100190)

2(College of Artificial Intelligence, University of Chinese Academy of Sciences, Beijing 100049)

3(National Satellite Meteorology Center, Beijing 100081)

Abstract In the past 20 years, massive solar images and space meteorological data that have been

* 国家自然科学基金项目资助 (11272333)

2022-02-13 收到原稿, 2022-10-14 收到修定稿

E-mail: dalei.guo@ia.ac.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/>)

transmitted back continuously and constantly with increasing space-based observatories launched, provide a promising material basis for the application of artificial intelligence technology to forecast and early warning solar activities. However, due to the less the extreme solar eruption and therefore the smaller relevant sample size, a slightly more the moderate solar activities outbreak and a little more the sample data set size, and the common routine non-outbreak space-weather always occurring and thus the samples become concentrated, thereby these condition and phenomenon result in sample imbalance and unlabeled data and so on which seriously affects the wide application of machine learning methods in the field of space weather forecasting and early warning. To handle the imbalance disturbance of sample data set for flare hierarchic recognition and forecast, this paper designs artificial intelligence algorithms for extreme ultraviolet images of solar active regions. Firstly, a dataset of extreme ultraviolet images of solar active regions from SOHO and SDO from 1996 to 2015 was constructed. Then the generated models combined classification head and initialization of convolution kernel are well-designed, and better index of accuracy for M and X flare are experimentally achieved and proved. Simultaneously, in terms of lightweight networks for deep learning, some comparison and analysis of multi algorithms on Meta learning were also discussed, this proposed method achieves finally 10% and 7% increments in POD accuracy compared with ordinary deep learning based method and unsupervised metric learning method, respectively.

Key words EUV images, Flare, Hierarchic recognition, Generative model, Artificial intelligence

0 引言

日面图像包含大量太阳活动信息。通过对活动区图像的观测,既可以获得太阳活动的周期变化规律,也可以根据相关征兆预报太阳活动事件。例如,对太阳黑子活动连续观测的结果,最终产生了 11 年太阳活动周期的重大发现^[1]。近年来,太阳动力天文台 SDO(Solar Dynamics Observatory)拍摄的更高时间与空间分辨率的多波段日面图像,为以小尺度时间和空间条件下研究太阳大气层及日地间空间天气的影响,提供了更加有利的条件。2016 年 4 月初,SDO 拍摄到太阳表面喷发的中等级别等离子体流,并预报为强烈太阳耀斑,后证实其导致了 2016 年 4 月 17 日地球无线电信号中断事件。

2006 年以来,随着多颗太阳观测卫星 STEREO A/B(Solar Terrestrial Relations Observatory A/B)日地关系观测台、SDO 发射升空,多观测源多角度多尺度日面图像数据量迅速增长。一方面丰富并提升了日地空间探索信息的数据来源和数据量级,另一方面面对与数据量增长相适应的高效数据处理手段提出了迫切需求。面向海量的太阳观测数据,人工智能技术正在显示出强大的处理能力^[2,3]。同时,卫星气象专

家在长期的观察与跟踪中积累的大量经验和知识,也构成了丰富的数据资源。合并日地观测卫星带来源源不断的数据,共同为空间天气的人工智能预报与预警提供了应用基础^[4-6]。

与通用领域或标准数据集上的模式分类不同,行星际空间物理数据与太阳活动的物理过程密切相关,包括图像及其他类型的多模态探测数据已从多个方面描述了日球和日地之间的物理现象与过程^[7,8]。在应用人工智能技术手段处理空间科学领域的问题时,需关注以下问题。

(1)数据与数据集的影响。不同时期发射的观测天文台,不仅图像清晰度和拍摄频度不同,且其数据信息包括了不同的太阳活动周期,因而在数据波段区间、帧间间隔等方面影响着规模数据集的构建。同时,由于相对温和的空间天气过程较为常见,相关数据量较大。而强烈爆发的太阳事件罕见发生且持续时间短,使得这类数据量相对较少。例如,红色预警类 X 级强耀斑爆发较少发生,使整个耀斑数据显示出明显的类别不平衡,这一现象不仅削弱了数据集的标准程度,还可能因某些计算方法失效导致结果出现谬误。

(2)智能计算方法与模型的选择。我们知道,适用于不同问题和场景的通用智能算法并不存在。应在充分了解研究对象的物理过程与机理的前提下,根据研究目的和要求选择并设计出更合理的智能计算方法,才能显示出人工智能技术的巨大作用^[9,10]。

(3)性能分析与结果对比。由于包括训练集、测试集等样本数据,以及对专用智能算法的探索等因素影响,基于人工智能的太阳事件分级与预报在性能分析与比较方面,暂无标准结果数据集,研究者们可通过详尽的设计与分析,以验证人工智能方法的效果。

本文针对太阳活动区 EUV 图像的人工智能耀斑分级与预报,给出了耀斑数据集处理与分析、元学习与生成式模型等内容,并分析讨论了分级与预报结果。

1 日面极紫外图像与耀斑数据集

太阳色球层上的耀斑爆发总是伴随着大规模的电磁辐射,在 SDO 搭载的日震与磁成像(Helioseismic and Magnetic Imager, HMI)图像中显示为以黑色部分代表的负极与白色部分代表的正极之间的相互交错。由于在耀斑发生前后黑白部分的变化非常微小,其中耀斑相关的特征很难有效提取和量化。但是,SDO 搭载的大气成像组件(Atmospheric Imaging Assembly, AIA)拍摄的日面极紫外图像波段极其丰富,且具有较高空间和时间分辨率,能够用来预测可能干扰地球的太阳风暴及耀斑事件等。

太阳和日球层探测器(Solar and Heliospheric Observatory, SOHO))搭载的极紫外望远镜(Extreme ultraviolet Imaging Telescope, EIT)提供了更

早的活动区图像,例如第 23 太阳活动周期数据,其相应波段活动区数据可作为太阳耀斑图像样本集。在波段数据的选取上,一方面出于对数据融合考虑,选择一个 SOHO 与 SDO 共有或相近波段较为合适;另一方面,从耀斑预测的角度而言,经过验证 193 波段图像可以捕获耀斑过程中等离子体的动态变化,特别适用于显示明亮的等离子细丝和凸起等特征,且越亮的区域表示等离子体的密度越大^[11]。考虑到 EIT 只能提供与 193 波段相近的 195 波段图像,因此选择以 SDO/AIA 的 193 波段与 SOHO/EIT 的 195 波段极紫外图像日面图像作为模型的输入数据,相关数据来自 SunPy API^[12]。

根据耀斑记录文件下载数据,可统计耀斑级别分布情况。其中 C 级数据最多,这与实际爆发中中等程度的耀斑最常见相符合。耀斑级别数据分布如图 1 所示, C 级数据 1192 个, M 级 1084 个, X 级 126 个。从左到右依次为 B, C, M, X 等,其中 C, M, X 的频率结果更符合泊松分布, B 级数据的分布情况较为平均。可以看出,最高处的 C 和 M 分别达到 136 和 216 个数据量,分别对应 C10 和 M10 耀斑级别,且在级别跨越的边界处,即由 B 级到 C 级及由 C 级到 M 级,有一个较大的跃升,可能与数据筛选、样本量本身及真实情况差距较大等因素有关。

由于太阳高能粒子爆发方向、日地观测台站位置、对地影响差异等原因,造成观测参量之间交错关联,相关日地参数数据呈现多源、多模态、多维度和多尺度等特性。因此,面向具体预报任务,需在分析样本分布的基础上,设计合理的数据集,以满足智能分级的要求。




图 1 按耀斑级别的数据分布

Fig. 1 Data distribution by flare level

1.1 样本数据分布不平衡及其影响

在应用图像数据作耀斑等级预测中,通常将其视作分类任务,即利用模型判断输入图像属于 C, M, X 的类别。但从耀斑类别与 X 射线的峰值的对应关系来看,各个级别之间的差异在临界点处并不大。举例来讲, B99 的耀斑级别(9.9×10^{-7})与 C10(1.0×10^{-6})的耀斑级别的差异在 X 射线的数值上比 C90 与 C10 的差异还要小,但却被划分为不同类别。因此,对于现有数据各个级别出现的频率统计也是至关重要的。若在临界点处出现大量数据,还需要考虑实际类别与标签的对应关系。

1.2 按年代分割数据

深度学习模型本质上学到的是训练数据的分布,因此考察模型迁移能力的前提是训练数据和测试数据的分布情况大致相同。如果采用常用数据集上的随机分割训练集和测试集,则无须考虑数据特征的分布情况。对于耀斑预报的具体任务,由于某一活动区可能会在某个时间跨度中爆发多个耀斑,且该活动区形状可能并不发生非常明显的变化。如果这些耀斑事件分别被划分到训练和测试集中,就会导致模型在预测时判别了一个已经训练过的类似数据。若按年份分割,这种情况将不会发生。但是,年份分割也存在其他问题。例如,无法保证模型在训练集中学到的数据特征分布与测试集的特征分布具有一致性。尤其当数据量级较小时,这种现象会更加明显。目前,在综合考虑空间天气领域问题与任务的情况,按照年份分割仍是大多数研究对数据集的划分方式^[13]。

对于 B 级与 M 级均选择 1996—2012 年、2013—2016 年相应数据作为训练集和测试集, C 级数据选择 1997—2012 年、2013 年分别为训练集和测试集, X 级数据选择 1997—2012 年和 2013—2015 年分别为训练集和测试集。由于 2000 和 2002 年为第 23 太阳周期高峰年, 2013 年为第 24 太阳周期高峰年,选择数据集覆盖了强耀斑爆发年,因而包括了典型耀斑图像数据,满足智能分类任务对数据集的要求。

1.3 引入新的级别分类定义

在耀斑记录下载数据的基础上,对所有原来的 3462 个 C 级、1863 个 M 级、142 个 X 级图像进行实验判别。可以发现, C 级和 M 级耀斑的预报性能较优,但对 X 级耀斑的预报效果较差^[14]。虽然使用了多种解决数据不平衡的方法,但对这类具有较大差异的

数据集,网络模型的实验效果仍然无法得到明显改善。为实现单一网络的三分类任务,这里引入 B 级耀斑的图像定义,定义所有无耀斑发生的图像为 B 级。初始的 C 级耀斑作为一类有耀斑情形, M 和 X 级耀斑合为一类较严重耀斑的情形,以改善数据分布不平衡状况,如表 1 所示。

1.4 视频图像数据集

耀斑数据集采用耀斑发生前 24 h 内的图像,间隔为每小时一帧,共 23 帧图像序列,对耀斑爆发前临近时间内较为集中的图像数据进行分级,也可视为对太阳活动区耀斑视频数据集的处理,因而既包含了对耀斑级别的分类,又包含了对耀斑爆发的预报,对于太阳活动区极紫外图像数据信息的应用与处理具有重要意义。

2 生成式度量学习模型

采用基于度量的元学习模型,借助其对样本数量需求小、通过支持集和查询集数据的相似度比较完成判断的特点,改善在现有数据量的驱动下,深度学习模型难以找到多分类任务判别边界的状况^[2,3],从而达到降低数据量、提升分类效果的目的。

在元学习中,将用于训练的 N 个类别称为 N -way, 每个类别中假定只使用 K 个带标注的样本,则称 K -shot, 这 N -ways K -shot 个样本合起来组成支撑集 (Support Set), 其余的样本组成查询集 (Query Set)。

基于度量的元学习模型类似于机器学习当中的最近邻算法,可以概括为:对于待测样本 x , 利用核函数 k 衡量 x 与类别已知的集合 S 中数据 (x_i, y_i) 的相似度,对标签 y_i 加权求和即得到 x 的类别为

$$p(y|x, S) = \sum_{(x_i, y_i)} k(x, x_i) y_i. \quad (1)$$

式中,核函数 k 本身是一种抽象函数,用以将两个样本映射至高维特征空间并返回该特征空间两个样本特

表 1 耀斑级别数据集分布
Table 1 Flare dataset of different levels

数据集	B	C	M+X	合计
训练集	669	958	837+98	2562
测试集	194	234	247+28	703
总计	863	1192	1084+126	3265

征向量的内积来表示数据的相似度。具体步骤如下。

步骤 1 从支持集和查询集的所有图像中提取嵌入模型,通常为卷积神经网络 (Convolution Neural Networks, CNN)。

步骤 2 对查询集中的每张图像均计算其与支持集图像的距离并进行分类。

步骤 3 每完成一次图像分类,对 CNN 按照损失函数反向传播误差更新网络权重参数。

基于度量的元学习从根本上将对图像类别的判断转换为图像与图像之间相似度的衡量,更符合耀斑图像分类数据与任务的特点。为避免单一度量模型特征提取不充分的问题,在分析太阳活动区图像及耀斑数据的基础上,本文设计了基于度量的生成式元学习模型,充分发挥元学习任务对样本数量要求低、类别配置灵活的特点,可解决现有数据集类别不平衡、样本数量少、网络知识难以迁移等问题。

生成式度量学习模型结构主要由两部分组成,即元网络(MetaNet)和目标网络(TargetNet),元网络由任务环境编码网络(Task Context Encoder)和卷积核参数生成网络(Convolution Kernel Weight Generator)组成,其目的是编码任务数据,然后生成目标网络的参数。目标网络是针对分类的网络结构,如图 2 所示。图 2 中 f_ϕ 为特征提取器,使用深度学习网络来提取特征。在训练过程中,不断地从训练集中获取不同的样本信息,使用任务嵌入网络将其表示为一

个任务特征,基于这个任务特征,通过参数生成器形成一个针对当前这个任务的目标网络对应层的参数,使网络具有解决当前任务的分类能力^[15]。其中,参数生成器包括卷积核参数、批量归一化参数及分类器参数等。

这类模型由于包含参数生成回路将使训练难度提升、训练结果不稳定。针对这一问题,提出一种单位卷积核初始化方法,如图 2 所示。对 VGG16 网络的权重按照网络层次逐一分析,将其中心卷积核作为单位卷积核,用于生成式模型中权重生成器的初始化,以解决此类生成式网络难以训练的问题。具体来说,在元网络结构部分,首先通过 VGG 网络求取聚类中的 4 个中心核,其中网络前段和中后段各两个单位中心核按照 0.2, 0.2, 0.3, 0.3 的比例配置。然后,为增加卷积核的多样性,使其还原到训练后卷积网络的状态,在每个中心卷积核上增加一个随机矩阵,矩阵随机数按照正态分布构成,其均值为 0,标准差为 2.5×10^{-4} ,因而生成了一个与卷积层核尺寸 $(3, 3, \text{chn}_{\text{in}}, \text{chn}_{\text{out}})$ 相同的 Backup 权重,共可形成 32 个 Backup 权重组成 Backup 权重库。

在另一条支路上,任务环境编码网络对于每个任务均生成一个 64 维的任务特征向量,将前 32 维视作均值 μ ,后 32 维视作方差 σ ,将 $e^{\sigma/2}$ 乘以一个符合标准正态分布的随机数 ε 后与 μ 相加,得到 32 维特征 z 。此特征与 Backup 权重库相乘后即得到最终的卷




图 2 包含卷积核初始化的生成式度量学习模型

Fig. 2 Generative metric learning model with kernel initialization

积核参数,也就是对应目标网络中的卷积层参数。

可见,此时目标网络中无可学习参数,其参数由元网络产生, $\theta_i^1, \dots, \theta_i^l$ 是目标网络中的参数。合适的初始化权重有效避免了梯度消失和梯度爆炸的问题,可使网络快速收敛到最优值。

3 分级与预报结果

3.1 耀斑分级与预报性能指标

由于有无耀斑或耀斑级别在样本数量上的不平衡,混淆矩阵中常用衡量分类指标,例如精确率、召回率不再适用,采用考察不平衡分类性能的参量真实技能分数 TSS(True Skill Score, 定义符号 S_{TS})来衡量模型的效果^[11,16]。在混淆矩阵中,判别为正时分别用 TP(True Positive, 定义符号 P_T), FP(False Positive, 定义符号 P_F)表示耀斑被正确分类,而非耀斑被错误分类;判别为负时分别用 FN(False Negative, 定义符号 N_F), TN(True Negative, 定义符号 N_T)表示耀斑被错误分类,而非耀斑被正确分类,表 2 给出了耀斑分类混淆矩阵。

检测率(Probability of Detection, POD)指标评估了判别预报的敏感性,为正确预报 TP 与实际类别中所有事件(P_T+N_F)的比率 $P_T/(P_T+N_F)$,其是分类任务性能分析关键指标。误报率 R_{FP} (False Positive Ratio, FPR)指标评价了模型正确预测正样本纯度的能力, $R_{FP}=P_F/(P_F+N_T)$ 值越小,性能越好。

S_{TS} 为检测率与误报率之间的差值为

$$S_{TS} = P_T/(P_T + N_F) - P_F/(P_F + N_T).$$

S_{TS} 范围为 $-1 \sim 1$, 数值越大, 模型的分类效果越好, S_{TS} 可消除数据样本在均衡性方面的干扰。这里, 有或无是指有无某级别耀斑。

3.2 不同类别上的分类结果

实验模型使用深度学习框架 Pytorch 进行设计, 并在实验室服务器进行训练和验证。服务器配备有 NVIDIA GeForce GTX 1060 Ti GPU 与 Intel Core

i7-9700 CPU。这里设计了无监督信息的度量模型 Unsup, 使用以 ResNet12(640)为骨干的网络, 作为 f_ϕ 而用来进行特征嵌入。嵌入后的特征直接使用 KMeans 算法进行聚类得到分类结果。同时, 还将使用卷积神经网络的深度学习模型 I3 D^[14] 作为基线对比模型。在分级与预报过程中, 对卷积核初始化参数的选择、shot 数目及中间层结果均进行了相应的调试对比, 综合选择性能较好的参数并组合为相应的模型方法。

(1) 卷积核初始化对性能的提升效果。卷积核初始化提取了输入特征图的梯度信息, 使得类别中心在中间层的输出结果较为集中且过渡平滑, 具有去噪和增强边缘的效果。

(2) shot 数目的影响。度量模型对于 shot 数目较敏感, 训练 shot 数目越大, 性能越好, 尤其是对于 B 级、MX 级, 当 shot 数目由 1 逐步增加到 15 时, TSS 值分别由 0.25 和 0.35 提高到 0.4 和 0.48。但对于 C 级影响较不明显, 当 shot 数目变化时, TSS 值保持在 0.99 左右, 如图 3 所示。另外, shot 数目对生成式度量模型性能影响不大, 增加 shot 数目无法带来预报准确率的大幅提升, 验证了生成式模型无需更多样本的元学习能力。

太阳活动区 EUV 图像的耀斑分级与预报结果列于表 3。其中, I3 D^[14] 是使用普通卷积神经网络设计的基线深度学习对比模型, 其具体结构在此不展开描述。Unsup_15 shot^[14] 是无监督度量模型在测试 shot 数目为 15 时的结果, Generate_1 shot 是生成式度量模型在测试 shot 为 1 的结果。对于无监督度量模型 Unsup_15 shot, 预报效果均好于深度学习方法, C 级效果最好, 且在 MX 上增加的效果大于在 B 上造成的衰减^[14]。因此, 度量式元学习模型与样本集 MX 合并可提升整体预报性能。

对于生成式度量模型 Generate_1 shot, 在 B 和 MX 的大多数指标上优于度量模型, 即对于 B 和 MX 的效果提升明显, 更使得类别间的性能较为平均。在三个类别上, TSS 分别为 0.54, 0.55, 0.55, 这是由于卷积核初始化设计过程可根据当前任务及时调整权重参数, 提升了原分类效果较差的判别性能。总体而言, 基于卷积核初始化的生成式度量模型带来了更好的性能。值得注意的是, B 和 MX 级分类性能提升的同时, C 级分类指标有所下降。这是因为生成式度量

表 2 耀斑分类混淆矩阵

Table 2 Confusion matrix for flare classification

	i 级耀斑(True)	非 i 级耀斑(False)
预报为 i 级(Positive)	TP	FP
预报非 i 级(Negative)	FN	TN

模型更能够平衡不同类别样本之间不均衡样本数量所带来的模型偏见。同时,其对不同类别间的样本特征表达能力更均衡,这也是生成式模型对 shot 数量较不敏感的原因之一。并且由于在实际应用中 MX 级分类性能的预报和应用意义较大,所以虽然 C 级分类




图 3 不同模型 shot 数目变化对 TSS 的影响
Fig. 3 Effect of shots number of different models on TSS

表 3 不同类别的分类结果
Table 3 Classification results of different categories

模型	Class	POD	TSS
I3 D ^[14]	B	0.52	0.33
	C	1	0.95
	MX	0.60	0.40
Unsup_1 shot	B	0.44	0.26
	C	0.99	0.99
	MX	0.63	0.35
Unsup_15 shot	B	0.55	0.40
	C	1	0.99
	MX	0.76	0.48
Generate_1 shot	B	0.69	0.54
	C	0.70	0.55
	MX	0.70	0.55

精度下降,但是 MX 级的分类精度提升对实际预报预警更为重要。

3.3 拆分 MX 数据集上的分类结果

在上述实验中,将 MX 视为同一类有严重耀斑爆发的情况,在一定程度上克服了数据不平衡造成的样本学习问题,获得了较好的分类性能。由于元学习模型不再受需满足一定类别样本数量的局限,因而可尝试将其分解,即将原用于平衡样本数量的 MX 合并数据集,重新构成 4-way,即 4 个类别的分类任务。使用前述两种方法,即无监督度量模型与生成式模型测试,两种模型在 4-way 情况下的 TSS 结果如表 4 所示。

与 3-way 任务进行对比可以看出,对于无监督的度量模型,在 B 和 C 两类上与之前的效果差异不大,分别是 0.413 和 0.976,且对 C 类的预测仍然最好。同时,在实验过程中也发现, M 和 X 两类预测结果呈现出此消彼长的数量关系,总和保持在 0.36 左右。对于生成式度量模型,新类别的出现造成整体预测水平较为平均,在 4 个类别上均为 0.34~0.36,因此直接将针对合并样本集所设计的判别模型应用于原数据集的判别过程,加大了模型的判别难度,可降低分类性能。这一简单分解过程再次说明,在机器学习方法与技术的应用过程中,不存在通用模型与普适算法,应当根据目标任务、物理过程及其数据集特征进行针对性设计,才能真正发挥机器学习及人工智能技术的强大能力。

4 结论

随着多观测源、多模态、多尺度太阳数据的大规

表 4 两种模型在 4-way 情况下的 TSS 结果
Table 4 TSS index in the 4-way case under different models

模型	Class	TSS
Unsup_10 shot	B	0.413
	C	0.976
	M	0.166
	X	0.209
Generate_1 shot	B	0.345
	C	0.366
	M	0.362
	X	0.349

模增加,以传统人工经验、物理模型为主的耀斑事件预报预警方法,正在转变为与人工智能相结合的机器学习分类预报技术。由于类不平衡、类间特征区分度不明显、数据量欠缺等问题,针对太阳活动区 EUV 图像的耀斑分级与预报,建立了日面活动区 SDO/AIA 的 193 波段与 SOHO/EIT 的 195 波段极紫外图像的視頻数据集,并在此基础上,基于元学习方法,设计了包含卷积核初始化的生成式度量模型,获得了如下结论。

(1)搭建的 1996—2015 年 193 波段数据集包含了 1996—2015 年 SOHO 和 SDO 的日面活动区图像数据,涵盖了第 23 和第 24 太阳活动周期的高峰年,同时对较高等级耀斑爆发前的图像均值处理显示耀斑发生的位置区域,因而耀斑爆发前连续帧图像构建的动态视频数据集,为耀斑分类与预报提供了充分的数据量。

(2)设计了基于元学习的生成式度量模型,与普通深度学习模型相比,以元学习为基础构建模型解决耀斑预报任务,获得了不同程度的性能提升。在力图使网络轻量化的基础上,能够将 MX 级耀斑预报的检测率指标相较于普通的深度学习模型和无监督度量式模型分别提升 10% 和 7%。在不同任务配置时,度量模型显示出的 shot 数目越高,其性能越好。但是,生成式度量模型对 shot 数目不敏感,性能更佳。

(3)由于太阳物理过程的影响,活动区图像的耀斑级别分类及判断与其他一般数据集上的任务不同。耀斑等级判定依据的是太阳 X 射线流量,是一个连续值,因而造成类和类边界上的数值差异小于类内的最大数值范围。因此,对于边界数据的级别分类,只能严格按照级别的数值定义来“硬”区分。即使标签和数据特征完全对应,从特征提取的角度来看,仍存在没有明显边界的可能,在一定程度上影响了判别的精度和性能。

参考文献

- [1] GOLUB L, PASACHOFF J M. Nearest Star: The Surprising Science of Our Sun[M]. Cambridge: Harvard University Press, 2001
- [2] DUDA R O, HART P E, STORK D G. Pattern Classification[M]. Beijing: China Machine Press, 2003
- [3] CHEN Yunji, LI Ling, LI Wei, *et al.* AI Computing Systems[M]. Beijing: China Machine Press, 2020
- [4] PARK E, MOON Y J, SHIN S, *et al.* Application of the deep convolutional neural network to the forecast of solar flare occurrence using full-disk solar magnetograms[J]. *The Astrophysical Journal*, 2018, **869**(2): 91
- [5] NISHIZUKA N, SUGIURA K, KUBO Y, *et al.* Deep flare net (DeFN) model for solar flare prediction[J]. *The Astrophysical Journal*, 2018, **858**(2): 113
- [6] HUANG X, WANG H N, XU L, *et al.* Deep learning based solar flare forecasting model. I. Results for line-of-sight magnetograms[J]. *The Astrophysical Journal*, 2018, **856**(1): 7
- [7] SHEN F, YANG Z C, ZHANG J, *et al.* Three-dimensional MHD simulation of solar wind using a new boundary treatment: comparison with *in situ* data at Earth[J]. *The Astrophysical Journal*, 2018, **866**(1): 18
- [8] YANG Yi, SHEN Fang, YANG Zicai. Simulation of interplanetary solar wind with three-dimensional MHD model driven by multiple observations[J]. *Chinese Journal of Space Science*, 2020, **40**(3): 305-314 (杨易, 沈芳, 杨子才. 多种观测数据驱动的三维行星际太阳风 MHD 模拟[J]. *空间科学学报*, 2020, **40**(3): 305-314)
- [9] GALVEZ R, FOUHEY D F, JIN M, *et al.* A machine-learning data set prepared from the NASA solar dynamics observatory mission[J]. *The Astrophysical Journal Supplement Series*, 2019, **242**(1): 7
- [10] HE K M, ZHANG X Y, REN S Q, *et al.* Delving deep into rectifiers: Surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision (ICCV). Santiago, Chile: IEEE, 2015: 1026-1034
- [11] ALIPOUR N, MOHAMMADI F, SAFARI H. Prediction of flares within 10 days before they occur on the sun[J]. *The Astrophysical Journal Supplement Series*, 2019, **243**(2): 20
- [12] The SunPy Community, MUMFORD S J, CHRISTE S, *et al.* SunPy-python for solar physics[J]. *Computational Science & Discovery*, 2015, **8**(1): 014009
- [13] YE Qian, SONG Qiao, XUE Bingsen. $F_{10.7}$ index forecasting method based on area statistics of solar active regions[J]. *Chinese Journal of Space Science*, 2019, **39**(5): 582-590 (叶茜, 宋乔, 薛炳森. 基于活动区面积统计的 $F_{10.7}$ 指数预报方法[J]. *空间科学学报*, 2019, **39**(5): 582-590)
- [14] ZHU Lingfeng. Generative Model Space Weather Forecasting with Multi-Scale Solar Information[D]. Beijing: University of Chinese Academy of Sciences, 2021 (朱凌峰. 多尺度日面信息的生成式度量模型空间天气预报[D]. 北京: 中国科学院大学, 2021)
- [15] LI H Y, DONG W M, MEI X, *et al.* LGM-Net: Learning to generate matching networks for few-shot learning[C]//Proceedings of the 36 th International Conference on Machine Learning. Long Beach, USA: ICML, 2019: 3825-3834
- [16] BLOOMFIELD D S, HIGGINS P A, MCATEER R T J, *et al.* Toward reliable benchmarking of solar flare forecasting methods[J]. *The Astrophysical Journal Letters*, 2012, **747**(2): L41