



论文

基于多模态特征融合的太阳耀斑预报模型

李蓉¹, 吴颖智¹, 田奇辉¹, 黄鑫^{2*}

1. 北京物资学院信息学院, 北京 101149;

2. 宁波大学信息科学与工程学院, 宁波 315211

*联系人, E-mail: huangxin@nbu.edu.cn

收稿日期: 2024-05-22; 接受日期: 2024-07-26; 网络出版日期: 2024-10-24

国家重点研发计划(编号: 2021YFA1600504)和中国科学院战略性先导科技专项(编号: XDB0560000)资助项目

摘要 本文提出了一种基于多模态特征融合的太阳耀斑预报模型STCNet, 其输入为太阳光球纵向磁图及其对应的磁场特征参数. 该模型旨在使用两者之间的关联信息, 充分利用不同模态信息的互补性, 以增加训练数据的多样性和丰富性. 本文采用了层级式结构以及高效窗口化策略的Swin Transformer来处理太阳光球纵向磁图, 在高效提取图片特征的同时减少计算复杂度, 采用一维卷积神经网络对磁场特征参数进行特征提取, 将两种模态的特征向量融合并输入全连接层进行分类. 在主要评估指标中, STCNet模型的F1分数为0.2342、真实技巧统计(TSS)值为0.8251、发生耀斑报准率为0.9227、发生耀斑虚报率为0.0976、AUC值为0.96、模型准确率为90.27%. 该模型拥有较高的报准率和较低的虚报率, 其预测性能优于以太阳光球纵向磁图为输入的单模态Swin Transformer模型、深度残差网络(Deep Residual Networks, ResNet)模型, 以及与STCNet输入相同的多模态ResNet模型. 在与现有文献研究的比较中, STCNet模型的TSS值也有着非常出色的表现.

关键词 太阳耀斑预报, 深度学习, 多模态, Swin Transformer模型**PACS:** 94.05.Sd, 96.60.qe, 96.60.Q-

1 引言

太阳耀斑是太阳大气释放能量的最显著表现^[1], 也是空间天气预报需要研究的重要内容之一. 太阳耀斑爆发会引发地球电离层的剧烈扰动, 使其电子密度分布突然变化^[2], 其影响不仅局限于人类的空间高科技活动, 例如对人类太空探索和技术设备构成潜在风险, 还可能会破坏电离层结构, 导致地球上的无线电波在电离层中反射失效, 从而使无线电通信受到干扰

甚至中断^[3]. 因此, 太阳耀斑的预报研究具有重要的实用价值和科学意义, 为人类应对灾害性空间天气事件提供关键的预警信息.

太阳耀斑预测模型的建模方法主要分为物理方法、统计与机器学习方法. 物理方法需要建立研究对象的物理模型, 通过数值模拟计算预报参量的空间分布和演化. 太阳耀斑爆发是一种复杂的动力学工程, 其主要的能量释放机制研究已经取得一定的进展^[4-6], 但目前仍没有获得可用作预报的物理模型. 现有的预

引用格式: 李蓉, 吴颖智, 田奇辉, 等. 基于多模态特征融合的太阳耀斑预报模型. 中国科学: 物理学 力学 天文学, 2024, 54: 129611

Li R, Wu Y Z, Tian Q H, et al. Solar flare forecasting model based on multi-modal feature fusion (in Chinese). Sci Sin-Phys Mech Astron, 2024, 54: 129611, doi: [10.1360/SSPMA-2024-0192](https://doi.org/10.1360/SSPMA-2024-0192)

报模型主要基于统计和机器学习方法, 经历了基于物理特征参量和自动特征提取两个研究阶段.

基于物理特征参量的预报方法研究中, 主要应用统计、神经网络、支持向量机和决策树等方法. Wheatland^[7]使用了1976年–2003年的太阳耀斑软X射线数据, 应用贝叶斯统计方预测太阳耀斑, 虽然可以根据以往的耀斑事件预测未来事件的概率, 但这种方法假设数据服从某种统计分布, 可能无法应对太阳活动的复杂性和非线性特征. Falco等人^[8]根据太阳黑子群特性, 结合一些形态参数和统计技术建立了太阳耀斑预测模型, 对于较强事件具有最佳的性能, 在应对高维度和复杂的非线性数据时表现不佳, 对数据的多样性适应性较差. Raboonik等人^[9]应用磁图的Zernike距建立了基于支持向量机(SVM)的太阳耀斑预报模型, 证明了Zernike距能够从二维图像中提取独特的特征, 使分类更加准确, 然而SVM对大规模数据的处理效率较低, 训练时间长且对噪声敏感. Liu等人^[10]训练了随机森林(RF)算法来预测24 h内给定活动区域中某一耀斑的发生, 表明了使用HMI参数和RF是一种有效的耀斑预测方法, 随机森林虽然在处理高维数据时表现较好, 但对异常值和噪声仍然敏感, 且在实时预测时计算效率可能不足. 这类方法可以建立磁场参数与太阳耀斑爆发的关系, 但难以全面描述太阳观测图像的丰富特征和参量之间的相关性. 对发生耀斑的报准较高, 同时虚报率也高.

深度学习方法在大数据支持下能够自动提取特征并构建预测模型, 直接处理各种类型的数据, 如图像、视频或文本. 深度学习方法不仅能够从原始数据中提取特征, 还能够捕捉复杂的非线性关系. 近年来, 越来越多的研究将深度学习方法应用到太阳耀斑预测中^[11–14].

Li和Huang^[15]使用SOHO卫星MDI拍摄的观测图像作为输入, 利用卷积神经网络(Convolutional Neural Networks, CNN)的自动图像特征提取能力建立了太阳耀斑预报模型. Huang等人^[16]提出了采用两个卷积层的CNN从太阳活动区的磁图中自动提取所需参数进行预报. Liu等人^[17]利用耀斑历史特征构建了基于磁参数的太阳耀斑LSTM预测模型. Bhattacharjee等人^[18]发现CNN集中关注活动区内相反极性之间的区域, 并且其输出主要由活动区的总无符号磁通量决定. Landa和Reuveni^[19]建立了一维CNN预报模型来预测M级和X级太阳耀斑事件在不同时间范围内发生的概率, 该

模型使用GOES的X射线时间序列数据. 传统深度学习模型虽然可以自动提取磁图特征, 减少特征提取工程的复杂性, 但对于已有的专家和物理经验不能很好的利用, 当存在噪声和异常值的情况下预测性能显著下降.

近期的研究工作对传统深度学习预报模型提出了改进优化方法, 取得了一定的效果. Deshmukh等人^[20]研究了一种两阶段混合机器学习架构, 第一阶段基于CNN模型从磁图的时间堆栈中提取特征, 产生耀斑概率. 第二阶段使用上一阶段产生的磁图特征向量和耀斑概率来训练极端随机树(ERT)模型. 混合模型有效降低了发生耀斑预报的虚报率. Tang等人^[21]建立了基于深度神经网络、卷积神经网络和双向长短期记忆神经网络的预测融合模型, 可以预测太阳活动区在未来24 h或48 h内是否会发生M级或C级以上的耀斑事件, 其真实技能评分(TSS)值和F1分数优于传统的预测模型. Li等人^[22]开发了基于知识信息的深度学习耀斑预报模型, 将活动区面积、磁分类与耀斑发生的产率作为先验知识, 结合卷积神经网络构造混合模型, 预测未来48 h是否发生M级耀斑. 混合模型的准确率有所提高, 但发生耀斑的报准率较低, 虚报率较高. Zheng等人^[23]开发了应用注意力机制的混合双向长短期记忆(HBiLSTM-Attention)模型, 对未来24 h内多类耀斑进行预测. 该模型是第一个基于磁场参数和深度学习的多类耀斑预测模型, 并取得了良好的预测性能.

综上所述, 目前的太阳耀斑预报研究主要依赖于单一模态的数据建立预报模型. 然而, 单一模态数据可能无法提供全面的信息描述太阳耀斑爆发的特征, 而且还可能受到噪声和偏差的影响. 为了进一步提高预报模型的综合性能, 同时针对太阳光球纵向磁图和磁场特征参数两种模态数据相结合的挑战, 本文提出了一种应用Swin Transformer处理太阳光球纵向磁图, 一维卷积神经网络处理磁场特征参数的多模态太阳耀斑预报模型STCNet. 本文将介绍数据集的来源及内容、STCNet模型所用的一些方法, 以及使用多模态模型与其他模型进行对比实验, 证明STCNet模型出色的性能. 最后对本文工作的总结以及对未来的展望.

2 数据

当太阳日冕中储存的磁能突然释放时, 会发生太

阳耀斑, 观测到的太阳活动区的光球磁场(太阳光球纵向磁图和磁场特征参数)可以作为建模的输入. 目前, 太阳活动区数据主要有SDO/HMI^[24]数据和SOHO/MDI^[25]数据. 自1996年来, 这两种数据提供了持续、高质量的活动区数据. 其中, SDO/HMI自2010年4月30日开始日常观测至今.

太阳耀斑的分类通常分为光学耀斑分类和软X射线耀斑分类. 由于地球电离层对1–8 Å范围内软X射线强度的变化非常敏感, 能够更全面和准确地反映太阳耀斑的能量释放情况. 相比之下, 光学观测只能看到太阳耀斑在可见光范围内的表现, 可能无法反映出整个能量释放过程, 因此国际上广泛采用此范围波长的软X射线进行等级划分. 太阳耀斑的软X射线水平反映了其产生电离层效应的能力. 根据美国地球静止环境业务卫星(GOES)测量的1–8 Å峰值流量的软X射线^[26], 耀斑分为5个级别: A, B, C, M, X, 具体细分见表1. M级及以上耀斑对地球和空间天气影响较大, 可能干扰通讯、导航、地磁和电网, 甚至威胁航天器和宇航员安全. 相对而言, C级耀斑影响较小, 不会显著干扰地球. 预报模型应专注于对实际有显著影响的事件进行预警, 避免因过于敏感而预报大量无关的C级耀斑, 确保预报的高应用价值. 故本文对于太阳活动区的耀斑标记: “1”表示在从磁图观测开始的48 h内至少发生一个M级或更大的耀斑, 表明该太阳活动区是一个耀斑样本. “0”表示在从磁图观测开始的48 h内没有发生M级或更大的耀斑, 表明该太阳活动区是一个非耀斑样本.

本文数据集采用空间环境预警和AI技术跨学科创新工作组提供的SOLAR-STORM2: Solar Flare Forecasting数据集^[16], 来源于SDO/HMI 数据, 以未来48 h是否发生大于等于M级太阳耀斑事件作为类别标签¹⁾. SOLAR-STORM2数据集包括73810张太阳光球纵向磁图和与之对应的十个磁场特征参数, 时间范围从2010年5月4日至2019年1月26日. 十个磁场特征参数来源于SDO/HMI的 SHARP (Spaceweather HMI Active Region Patch)数据, 已被证明是太阳活动区磁场特性的重要指标, 具有较高的预测效果和可观测性, 包括总无符号电流螺度、总光球磁自由能密度、总无符号垂直电流、净电流螺度绝对值、正负极净电流绝对值加和、总无符号磁通量、活动区强磁场面积、平均光

表 1 太阳耀斑软X射线分级标准

Table 1 Soft X-ray grading criteria for solar flares

耀斑级别	峰值流量 (Watts m ⁻²)
A	[10 ⁻⁸ , 10 ⁻⁷)
B	[10 ⁻⁷ , 10 ⁻⁶)
C	[10 ⁻⁶ , 10 ⁻⁵)
M	[10 ⁻⁵ , 10 ⁻⁴)
X	[10 ⁻⁴ , ∞)

球磁自由能、剪切角大于45°的像素比例、中性线磁通量. 十个磁场特征参数及意义详见表2. 由于太阳耀斑事件的天然特性, 数据集的数据分布不平衡, 发生太阳耀斑的样本量远远小于未发生太阳耀斑的样本量, 两种类型的数据样本数分别为3184和70822.

3 方法

3.1 STCNet太阳耀斑预报模型

基于太阳光球纵向磁图和磁场特征参数两种模式的数据, 本文提出融合Swin Transformer和CNN的多模态太阳耀斑预报模型(STCNet), 该模型接受太阳光球纵向磁图和与之对应的磁场特征参数作为输入, 输出未来48 h发生大于等于M级太阳耀斑的概率.

STCNet模型的构建流程如图1所示, 以Swin Transformer为主干网络, 由三个模块组成, 第一部分为原始图像特征提取网络, 主要由Swin Transformer构成, 对输入的太阳光球纵向磁图进行特征提取, 并将磁图特征向量展开为一维向量; 第二部分为磁场特征参数的特征提取网络, 由CNN构成, 对输入的太阳光球纵向磁图所对应的磁场特征参数进行特征提取, 并将提取后的磁场参数特征向量展开为一维向量; 第三部分为分类网络, 将第一部分得到的太阳光球纵向磁图一维特征向量与第二部分得到的磁场特征参数一维特征向量进行拼接, 最后将拼接得到的特征向量输入全连接层进行分类.

3.2 Swin Transformer模块

Vaswani等人^[27]在2017年提出了Transformer模型, 其利用像素与像素之间的自注意力机制构成多头注意

1) <https://tianchi.aliyun.com/competition/entrance/531804/introduction>.

表 2 十个磁场参数

Table 2 Ten magnetic field parameters

参数	描述	公式
TOTUSJH	总无符号电流螺度	$H_{C_{\text{total}}} \propto \sum B_z \cdot J_z $
TOTPOT	总光球磁场自由能密度	$\rho_{\text{tot}} \propto \sum (B^{\text{Obs}} - B^{\text{Pot}})^2 dA$
TOTUSJZ	总无符号垂直电流	$J_{z_{\text{total}}} = \sum J_z dA$
ABSNJZH	净电流螺度绝对值	$H_{c_{\text{abs}}} \propto \left \sum B_z \cdot J_z \right $
SAVNCPP	正负极净电流绝对值加和	$J_{z_{\text{sum}}} \propto \left \sum_{B_z^+} J_z dA \right + \left \sum_{B_z^-} J_z dA \right $
USFLUX	总无符号磁通量	$\varphi = \sum B_z dA$
AREA_ACR	活动区强磁场面积	$\text{Area} = \sum \text{Pixels}$
MEANPOT	平均光球磁自由能	$\bar{\rho} \propto \frac{1}{N} \sum (B^{\text{Obs}} - B^{\text{Pot}})^2$
SHRGT45	剪切角大于45°的像素比例	$\text{Area with shear} > 45^\circ / \text{total_area}$
R_VALUE	中性线磁通量	$\varphi = \sum B_{\text{Los}} dA \text{ within } R \text{ mask}$

力机制, 能够在全局的角度提取图像特征, 广泛应用于自然语言处理、图像处理等领域. 2020年, Dosovitskiy 等人^[28]将Transformer应用在计算机视觉领域, 提出了Vision-Transformer (ViT). ViT模型具有强大的特征提取能力, 其性能高于当前一些主流模型. 随后, 借鉴CNN的先验知识和设计理念, Liu等人^[29]提出了Swin Transformer. Swin Transformer则是一种分层Transformer结构, 其特点在于能够在小窗口内部进行自注意力的计算, 并利用移动窗口建立跨窗口连接来实现更高效的自注意力计算. Swin Transformer优秀的性能和灵活性使其成为医学图像检测与分割、智能交通、智能制造等领域^[30–32]的研究热点和应用场景之一.

Swin Transformer (SwinT)网络的架构图如图2所示, 各模块描述如下.

(1) Patch Partition模块

将图像输入到Patch Partition模块中进行分块处理, 每块为一个 4×4 的相邻像素集合, 之后在通道方向展开(Flatten). 对于输入的太阳光球纵向磁图, 由于

是单通道的灰度图像, 图像在经过调整尺寸、随机水平翻转后的尺寸为(224, 224), 每块包含 4×4 个像素, 每个像素有一个灰度值, 因此展开后的维度为 $4 \times 4 \times 1 = 16$. 经过Patch Partition处理后, 图像的高度和宽度都变为原尺寸的1/4, 即图像的形状由 $[224, 224, 1]$ 变为 $[56, 56, 16]$.

(2) 构建特征图

Linear Embedding层对每个像素的通道数据进行线性变换, 将维度变成预先设置好的值, 在Swin Transformer论文中, 这个超参数为 C . 不同参数大小的Swin Transformer版本中的 C 值不同, 本文选用Tiny版本的 C 值为96, 对于太阳光球纵向图是将维度从16转换为96, 即图像的形状再次变为 $[56, 56, 96]$.

Patch Partition模块后的四个阶段构建了不同大小的特征图. 除了第一个阶段(Stage1)中的初始 Linear Embedding层外, 其他三个阶段都先经过一个Patch Merging层进行下采样, 每经过一次Patch Merging层, 图片的高度和宽度都会变为原来的1/2. 在每个阶段中




图 1 太阳耀斑预报模型流程图

Figure 1 Flowchart of solar flare forecasting model.




图 2 Swin Transformer架构

Figure 2 Swin Transformer architecture.

重复堆叠 Swin Transformer Block, 这里的Block有两种结构, 分别为基于窗口的多头自注意力(Window based Multi-head Self-Attention, W-MSA)和基于移位窗口的多头自注意力(Shifted Window based Multi-head Self-Attention, SW-MSA), 如图3所示。

(3) 计算复杂度

W-MSA窗口分割可以有效地减少计算量, 假设每个窗口包含 $M \times M$ 个 Patches, 在一张含有 $h \times w$ 个 Patches 的图像上, 一个全局MSA模块和基于窗口的MSA模块的计算复杂度为(忽略了Softmax的计算复杂度):

$$\Omega(\text{MSA}) = 4hwC^2 + 2(hw)^2C, \quad (1)$$

$$\Omega(\text{W-MSA}) = 4hwC^2 + 2M^2hwC, \quad (2)$$

其中, h 为磁图高度, w 为磁图宽度, C 代表磁图的通道数, M 代表每个窗口的大小. MSA在Patch Token数为 $h \times w$ 时具有二次复杂度, 即总共有 $h \times w$ 个 Patch Tokens, 每个 Patch Token需要在全局计算 $h \times w$ 次. 相比之下, W-MSA在 M 固定的情况下具有线性复杂度, 共有 $h \times w$ 个 Patch Tokens, 每个 Patch Token在各自的局部窗口内计算 M^2 次. 对于巨大的 $h \times w$ 全局自注意力计算而言, 这是难以承受的, 而基于窗口的自注意力则具有良好的扩展性。

(4) 移位窗口划分方法

以图4太阳光球纵向磁图为例, 在第一个模块中采用了普通窗口划分策略, 从左上的像素开始, 将一个 8×8 的磁图均匀划分为 2×2 个窗口, 每个窗口大小为 4×4 ($M = 4$). 之后, 在下一个模块采用了SW-MSA




图 3 两个连续的Swin Transformer块
Figure 3 Two successive Swin Transformer blocks.

划分方法, 第二个模块使用上一层窗口的移动, 在有规则分区的窗口中用大小为 $\left(\left\lfloor \frac{M}{2} \right\rfloor, \left\lfloor \frac{M}{2} \right\rfloor\right)$ 的像素替换窗口.

连续的 Swin Transformer Blocks 的计算为

$$\hat{z}^l = \text{W-MSA}(\text{LN}(z^{l-1})) + z^{l-1}, \quad (3)$$

$$z^l = \text{MLP}(\text{LN}(\hat{z}^l)) + \hat{z}^l, \quad (4)$$

$$\hat{z}^{l+1} = \text{SW-MSA}(\text{LN}(z^l)) + z^l, \quad (5)$$

$$z^{l+1} = \text{MLP}(\text{LN}(\hat{z}^{l+1})) + \hat{z}^{l+1}, \quad (6)$$

其中 $\hat{z}^l$ 和 z^l 表示第 L 个Block的SW-MSA模块和多层感知器(Multilayer Perceptron, MLP)模块的输出特征. 移位窗口划分方法引入了先前层非重叠相邻窗口间的联系, 可以捕捉长程依赖关系、丰富特征表达, 促进多尺度信息提取, 提高模型鲁棒性, 更有利于对太阳光球纵向磁图的特征进行提取.

由图4可以观察到, 图像窗口经过偏移后变为了9个. 因此为了提高效率, 可以采用一种更有效的批处理计算方法, 即向左上方向进行循环移位, 如图5所示. 在此转换之后, 批处理窗口可能由特征映射中不相邻的几个子窗口组成, 因此采用屏蔽机制将自注意力计算限制在每个子窗口内.

具体而言, 原始磁图在进行移位后, A部分移动到右下角, B部分移位到最右边, C部分移位到最下边. 之后将每个部分合并为等同于移位前窗口大小的窗口, 即4个 4×4 窗口. 为了防止不同区域合并在一起进行多头自注意力(Multi-head Self-Attention, MSA)时导致信

息错乱, 在实际计算中使用了Masked MSA, 通过设置蒙版隔绝不同区域的信息.

3.3 CNN模块

由于在多模态混合模型中处理太阳光球纵向磁图所用到的Swin Transformer复杂性较高, 为了防止过拟合, 在模型的磁场特征参数处理部分选用了一维卷积神经网络, 图6为CNN模块架构图, 卷积层使用大小为3的卷积核, 分别具有16个和32个输出通道, 后跟批归一化(BatchNorm)加速网络的收敛并提高模型的性能, 以及用于增强模型非线性能力的ReLU激活函数.

3.4 分类器

STCNet模型最后的线性分类器结构如图7所示, 其中Swin Transformer提取得到的太阳光球纵向磁图特征向量展开为一维向量得到 D_{img} , CNN提取得到的磁场特征参数特征向量展开为一维向量得到 $D_{\text{parameters}}$, 随后将两个一维特征向量经过Concat操作进行拼接得到总特征向量 D_{concat} , 其公式如下:

$$D_{\text{concat}} = D_{\text{img}} \oplus D_{\text{parameters}}. \quad (7)$$

总特征向量 D_{concat} 经过多个全连接层, 每个全连接层之间都有一个用以防止过拟合并提高网络稳定性和鲁棒性的Dropout层, 最后通过一个Sigmoid层进行分类激活, 得到最终的分类概率, 即太阳耀斑预报模型输出.

4 结果与分析

4.1 实验环境

本实验环境为64位Windows10企业版系统, 处理器为Intel(R) Core(TM) i7-10700 CPU, 显卡为NVIDIA Tesla P40 24 G GPU, 内存为32 G. 采用Pytorch深度学习框架.

STCNet模型在图像处理部分的数据增强策略为调整输入图片的尺寸为(224, 224)并随机水平翻转, 转换为张量类型, 最后进行归一化处理. 模型训练所使用的优化算法为AdamW, 损失函数为交叉熵损失函数, 学习率衰减策略为每两个Epoch学习率衰减为原来的一半, 批量大小为64, 线性分类器的Dropout系数为0.4.

本文将得到的数据集按照时间以及活动区划分为




图 4 (网络版彩图)移位窗口工作模式

Figure 4 (Color online) Shifted window working mode.




图 5 (网络版彩图)左上方向循环移位操作

Figure 5 (Color online) Cyclic shift operation in the upper left direction.




图 6 (网络版彩图) CNN模块结构

Figure 6 (Color online) CNN module structure.

训练集和测试集, 训练集采取的是2010年5月–2015年10月以及2017年9月–2019年1月的数据. 为了解决正负样本不平衡问题, 训练集在未发生太阳耀斑每天的

相同活动区样本中只选择一条记录, 使其数量与发生太阳耀斑的样本量接近. 经过负样本下采样后, 得到训练集正样本数为2988个, 负样本数为5073个. 测试




图 7 线性分类器结构图

Figure 7 Linear classifier structure.

集采取的是2015年10月–2017年9月的原始数据, 其中正样本为196个, 负样本为11852个.

4.2 模型评价指标

由于太阳黑子群数据的不平衡性, 仅通过单一的评价指标难以评价模型的优劣. 本文通过使用二分类混淆矩阵(表3)评估模型的训练结果, 选用准确率(ACC)、F1 score、TP rate、TN rate、虚报率(FAR)、真实技巧统计(True Skill Statistics, TSS)指标综合判断模型性能.

各指标的计算公式如下:

$$ACC = \frac{TP + TN}{TP + FN + TN + FP}, \quad (8)$$

$$TP \text{ rate} = \frac{TP}{TP + FN}, \quad (9)$$

$$TN \text{ rate} = \frac{TN}{TN + FP}, \quad (10)$$

$$FAR = FP \text{ rate} = \frac{FP}{FP + TN} = 1 - TN \text{ rate}, \quad (11)$$

$$F1 \text{ score} = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}, \quad (12)$$

$$\text{Precision} = \frac{TP}{TP + FP}, \quad (13)$$

$$TSS = TP \text{ rate} - FP \text{ rate}. \quad (14)$$

F1 score是精确率和召回率的一种调和平均, 用于衡量模型的综合性能. TP rate反映了耀斑样本的报准率, TN rate是非耀斑样本的报准率. FAR与FP rate含义

表 3 混淆矩阵

Table 3 Confusion matrix

	真实值Positive	真实值Negative
预测值Positive	TP	FP
预测值Negative	FN	TN

相同, 均为无耀斑发生的活动区被虚报的样本, 即为虚假的正样本. TSS则是通过计算耀斑样本的报准率与虚报率之间的差值来评估模型的表现. 从上述公式可以看出, F1 score越高, 表示模型在识别耀斑样本方面的准确性越高; 而TSS综合考虑了报准率与虚报率的影响, 且对于不同的样本比例是无偏的, 特别适用于正负样本比例不平衡的耀斑测试集, 其值越高, 则意味着模型在区分正负样本方面的能力更强, 报准率高且虚报率低, 从而证明模型有更优秀的预测能力.

此外, ROC曲线^[33]作为一种坐标图式的分析工具, 在深度学习和机器学习领域的模型评估中得到了广泛应用, 用于权衡收益(True Positive)和损失(False Positive). ROC曲线对类别不平衡不敏感, 改变测试集的正负样本比例并不会改变ROC曲线, 因此在面对正负样本不平衡的太阳耀斑预测中, 使用ROC曲线评估模型是恰当的选择.

AUC (Area Under Curve)被定义为ROC曲线下方的面积, 其数值范围在0–1之间, 代表模型性能的优劣. 由于ROC曲线通常位于 $y = x$ 直线的上方, 因此AUC的

取值一般介于0.5和1之间. 采用AUC作为评价标准的原因在于, 有时ROC曲线无法清晰地说明哪个分类器的效果更好, 而AUC作为一个数值指标, 能够更直观地反映出分类器的性能, AUC值越大, 分类器效果越好.

4.3 结果与分析

为了检验本文提出的STCNet模型的性能, 使用相同的数据集与STCNet模型进行对比实验. 对比模型分别选用深度残差网络ResNet50进行太阳光球纵向磁图特征提取, 一维CNN进行磁场特征参数特征提取的多模态模型, Swin Transformer (SwinT)进行太阳光球纵向磁图特征提取的单模态模型, ResNet50进行太阳光球纵向磁图特征提取的单模态模型. 并与目前已有文献研究进行对比, 包括Liu等人^[10]使用磁场特征参数和随机森林(RF)的方法、Huang等人^[16]使用两个卷积层的CNN模型(DL)、Li等人^[22]开发的先验知识结合卷积神经网络的耀斑预报模型(Knowledge-Informed DL), 以及Tang等人^[21]基于深度神经网络、卷积神经网络和双向长短期记忆神经网络建立并优化的融合模型F1_FFM和TSS_FFM.

由于实验所使用的数据样本数目较小, 为了防止过拟合, 多模态STCNet模型中的Swin Transformer部分和单模态Swin Transformer模型使用到的版本均为

Swin-Tiny. Swin-Tiny的规模参数与ResNet50相近, 使得实验更加具有可比性.

表4给出了本文实验四种模型的预报结果, 表5给出了一些主要评估指标, 在本文的实验中, 单模态SwinT模型与单模态ResNet50模型相比, 多数评价指标相近, SwinT的主要综合指标TSS较ResNet50高出0.0184. 相比两个单模态模型, 多模态ResNet50+CNN模型的TSS值进一步提高. 而STCNet模型与其他三个模型对比时, F1 score提高0.0807–0.0881, TSS提高0.0694–0.1024, 发生耀斑报准率与其他三个模型相当, 但发生耀斑虚报率降低了0.0625–0.0798, 未发生耀斑的报准率提高了0.0625–0.0798, 整体模型准确率提升了0.0620–0.0783. 在与目前已有文献研究的对比中, 虽然STCNet模型的F1指数不如其他模型, 但其TSS值有显著提升, 增加了0.1071–0.3501.

表 4 不同模型的预报结果

Table 4 Forecast results of different models

模型	TP	TN	FP	FN
STCNet	179	10696	1156	15
ResNet+CNN	181	9742	2100	13
SwinT	181	9750	2102	15
ResNet	174	9955	1897	22

表 5 不同模型的评估结果

Table 5 Evaluation results of different models

方法	耀斑级别	预测周期 (h)	数据集年份	评价指标					
				F1 score	TSS	TP rate	FAR	TN rate	ACC
STCNet	$\geq M$	48	2010–2019	0.2342	0.8251	0.9227	0.0976	0.9024	0.9027
ResNet50+CNN	$\geq M$	48	2010–2019	0.1463	0.7557	0.9330	0.1773	0.8227	0.8244
SwinT	$\geq M$	48	2010–2019	0.1461	0.7461	0.9235	0.1774	0.8226	0.8248
ResNet50	$\geq M$	48	2010–2019	0.1535	0.7277	0.8878	0.1601	0.8399	0.8407
RF (Liu等人 ^[10])	$\geq M$	24	2010–2016	–	0.5320	0.7470	0.2150	0.7850	0.7660
DL (Huang等人 ^[16])	$\geq M$	48	2010–2015	0.2600	0.6210	0.8100	0.1890	0.8110	0.8110
Knowledge-Informed DL (Li等人 ^[22])	$\geq M$	48	2010–2018	0.3850	0.6950	0.7300	0.0350	0.9650	0.9610
TSS_FFM (Tang等人 ^[21])	$\geq M$	48	2010–2015	0.4150	0.7180	0.8290	0.1110	0.8890	0.9600
F1_FFM (Tang等人 ^[21])	$\geq M$	48	2010–2015	0.5240	0.4750	0.4930	0.0180	0.9820	0.8900

结果表明, 在48 h内的大型太阳耀斑事件中, STCNet模型成功地综合利用了太阳光球纵向磁图和磁场特征参数两种模态信息, 通过跨模态注意力机制增强了各模态的特征表现, 实现了模态间的语义互补, 从而显著提高了最终的分类效果.

图8展示了STCNet, ResNet50+CNN, SwinT和ResNet50四种模型在测试中的ROC曲线及其相应的AUC值. 具体来说, STCNet模型的AUC值为0.96, SwinT模型的AUC值为0.94, ResNet50+CNN模型的AUC值为0.96, 而ResNet50模型的AUC值为0.90. 可以明显看出, 单模态SwinT模型的AUC值比单模态ResNet50模型高0.04, 表明SwinT模型在对太阳光球纵向磁图的特征提取方面优于ResNet50模型. 此外, 多模态STCNet模型和ResNet50+CNN的AUC值均优于两个单模态模型, 表明在预测48 h内的大型太阳耀斑事件方面, 多模态模型的性能更为出色.

5 结论

目前的单模态模型通常只依赖一种类型的数据源, 无法充分利用其他可能包含重要信息的不同数据源, 对异常值和噪声敏感, 从而导致预测性能下降. 而多模态方法通过综合利用多种数据源, 可以显著提升太阳耀斑预报的准确性和鲁棒性, 弥补单模态模型的信息不足和特征提取局限性. 本文基于深度学习方法, 建立了以太阳光球纵向磁图和磁场特征参数为输入的多模态太阳耀斑预报模型STCNet, 通过高效的Swin Transformer来处理磁图数据, 并用磁场特征参数进一步补充太阳耀斑爆发的特征, 对太阳耀斑进行预报.

本文将STCNet模型与以下几种模型进行性能对比: 使用ResNet50进行太阳光球纵向磁图特征提取并结合一维CNN进行磁场特征参数特征提取的多模态模型; 使用Swin Transformer进行太阳光球纵向磁图特




图8 (网络版彩图) STCNet, ResNet50+CNN, SwinT和ResNet50四个耀斑预报模型的ROC曲线

Figure 8 (Color online) ROC Curves for the four solar flare forecasting models: STCNet, ResNet50+CNN, SwinT, and ResNet50.

征提取的单模态模型; 以及使用ResNet50进行太阳光球纵向磁图特征提取的单模态模型. 实验结果表明, 在太阳光球纵向磁图的特征提取方面, Swin Transformer优于深度残差网络ResNet50. 而在TSS指数、F1分数、准确率以及AUC值上, 多模态STCNet模型的表现均优于上述三种模型. 此外, 将STCNet模型与目前已有的文献研究进行对比, 结果显示STCNet模型具有较高的报准率以及较低的虚报率, 并具有最高的TSS值, 其TSS值较其他研究提高了10%–35%. 实验结果证明, STCNet模型实现了太阳耀斑不同模态间的语义互补, 在多项重要指标上优于其他深度学习模型, 具有更好的预测性能. 然而, STCNet模型在F1分数上相比其他文献研究存在一定的差距, 这是其不足之处. 另外, 由于数据量有限, 在应用较大规模的深度学习模型时容易出现过拟合现象, 因此, 对太阳耀斑预报在不同级别和不同时间范围内进行更细致的划分, 以及在处理数据样本不平衡等问题, 将成为未来研究的重要方向.

致谢 感谢SDO团队和空间环境人工智能预警创新工作组为本文提供的数据支持, 这些数据是本研究得以开展的重要基础.

参考文献

- Lu J Y, Yang Y F, Du D, et al. Advances in space weather research (in Chinese). Adv Meteorol Sci Technol, 2011, 01: 28–38 [吕建永, 杨亚芬, 杜

- 丹, 等. 空间天气研究进展. 气象科技进展, 2011, 01: 28–38]
- 2 Temmer M. Space weather: The solar perspective. *Living Rev Sol Phys*, 2021, 18: 4
- 3 Ma J, Liu Z, Shi Y R, et al. Multi-modal solar flare forecasting model based on sunspot group data (in Chinese). *Spacecr Environ Eng*, 2021, 38: 256–262 [马健, 刘柱, 石育榕, 等. 基于太阳黑子群数据的多模态太阳耀斑预报模型. 航天器环境工程, 2021, 38: 256–262]
- 4 Wang J X. Solar activity studies: From a magnetohydrodynamics description to a plasma perspective. *Chin Sci Bull*, 2012, 57: 1362–1368
- 5 Amari T, Canou A, Aly J J. Characterizing and predicting the magnetic environment leading to solar eruptions. *Nature*, 2014, 514: 465–469
- 6 Amari T, Canou A, Aly J J, et al. Magnetic cage and rope as the key for solar eruptions. *Nature*, 2018, 554: 211–215
- 7 Wheatland M S. A Bayesian approach to solar flare prediction. *Astrophys J*, 2004, 609: 1134–1139
- 8 Falco M, Costa P, Romano P. Solar flare forecasting using morphological properties of sunspot groups. *J Space Weather Space Clim*, 2019, 9: A22
- 9 Raboonik A, Safari H, Alipour N, et al. Prediction of solar flares using unique signatures of magnetic field images. *Astrophys J*, 2016, 834: 11
- 10 Liu C, Deng N, Wang J T L, et al. Predicting solar flares using SDO/HMI vector magnetic data products and the random forest algorithm. *Astrophys J*, 2017, 843: 104
- 11 Chen Y, Manchester W B, Hero A O, et al. Identifying solar flare precursors using time series of SDO/HMI images and SHARP parameters. *Space Weather*, 2019, 17: 1404–1426
- 12 Sun P, Dai W, Ding W, et al. Solar flare forecast using 3D convolutional neural networks. *Astrophys J*, 2022, 941: 1
- 13 Zheng Y, Qin W, Li X, et al. Comparative analysis of machine learning models for solar flare prediction. *Astrophys Space Sci*, 2023, 368: 53
- 14 Abdullah Y, Wang J T L, Wang H, et al. Operational prediction of solar flares using a transformer-based framework. *Sci Rep*, 2023, 13: 13665
- 15 Li R, Huang X. Solar flare forecasting model based on automatic feature extraction of sunspots (in Chinese). *Sci Sin-Phys Mech Astron*, 2018, 48: 119601 [李蓉, 黄鑫. 一种黑子特征自动提取的太阳耀斑模型. 中国科学: 物理学 力学 天文学, 2018, 48: 119601]
- 16 Huang X, Wang H, Xu L, et al. Deep learning based solar flare forecasting model. I. Results for line-of-sight magnetograms. *Astrophys J*, 2018, 856: 7
- 17 Liu H, Liu C, Wang J T L, et al. Predicting solar flares using a long short-term memory network. *Astrophys J*, 2019, 877: 121
- 18 Bhattacharjee S, Alshehri R, Dhuri D B, et al. Supervised convolutional neural networks for classification of flaring and nonflaring active regions using line-of-sight magnetograms. *Astrophys J*, 2022, 898: 98
- 19 Landa V, Reuveni Y. Low-dimensional convolutional neural network for solar flares GOES time-series classification. *Astrophys J Suppl Ser*, 2022, 258: 12
- 20 Deshmukh V, Flyer N, van der Sande K, et al. Decreasing false-alarm rates in CNN-based solar flare prediction using SDO/HMI data. *Astrophys J Suppl Ser*, 2022, 260: 9
- 21 Tang R, Liao W, Chen Z, et al. Solar flare prediction based on the fusion of multiple deep-learning models. *Astrophys J Suppl Ser*, 2021, 257: 50
- 22 Li M, Cui Y, Luo B, et al. Knowledge-informed deep neural networks for solar flare forecasting. *Space Weather*, 2022, 20: e2021SW002985
- 23 Zheng Y, Li X, Yan S, et al. Multiclass solar flare forecasting models with different deep learning algorithms. *Mon Not R Astron Soc*, 2023, 521: 5384–5399
- 24 Pesnell W D, Thompson B J, Chamberlin P C. The solar dynamics observatory (SDO). *Sol Phys*, 2012, 275: 3–15
- 25 Domingo V, Fleck B, Poland A I. The SOHO mission: An overview. *Sol Phys*, 1995, 162: 1–37
- 26 Machol J L, Eparvier F G, Viereck R A, et al. GOES-R series solar X-ray and ultraviolet irradiance. In: *The GOES-R Series*. Amsterdam: Elsevier, 2020. 233–242
- 27 Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. In: *Proceedings of the 31st International Conference on Neural Information Processing Systems*. Long Beach, 2017
- 28 Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16 × 16 words: Transformers for image recognition at scale. arXiv: 2010.11929
- 29 Liu Z, Lin Y T, Cao Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows. In: *Proceedings of the IEEE/CVF International Conference on Computer Vision*. Piscataway: IEEE, 2021. 10012–10022
- 30 Chen Y, Feng J, Liu J, et al. Detection and classification of lung cancer cells using swin transformer. *J Cancer Ther*, 2022, 13: 464–475
- 31 Lin A, Chen B, Xu J, et al. DS-TransUNet: Dual Swin transformer U-Net for medical image segmentation. *IEEE Trans Instrum Meas*, 2022, 71: 1–15
- 32 Gong H, Mu T, Li Q, et al. Swin-transformer-enabled YOLOv5 with attention mechanism for small object detection on satellite images. *Remote*

[Sens](#), 2022, 14: 2861

33 Fawcett T. An introduction to ROC analysis. [Pattern Recogn Lett](#), 2006, 27: 861–874

Solar flare forecasting model based on multi-modal feature fusion

LI Rong¹, WU YingZhi¹, TIAN QiHui¹ & HUANG Xin^{2*}

¹ *The Institution of Information, Beijing WuZi University, Beijing 101149, China;*

² *Faculty of Electrical Engineering and Computer Science, Ningbo University, Ningbo 315211, China*

**Corresponding author (email: huangxin@nbu.edu.cn)*

This paper presents STCNet, a solar flare forecasting model based on multi-modal feature fusion. The model's inputs include magnetograms and corresponding magnetic field characteristic parameters. By leveraging the correlation information between these inputs and utilizing the complementary aspects of different modalities, STCNet aims to enhance the diversity and richness of training data. The Swin Transformer, with its hierarchical structure and efficient windowing strategy, is employed to process the magnetograms. This approach allows for efficient extraction of image features while reducing computational complexity. Additionally, a one-dimensional convolutional neural network is used to extract the magnetic field characteristic parameters. The feature vectors from both modalities are then fused and input into a fully connected layer for classification. In terms of key evaluation metrics, the STCNet model achieves an F1 score of 0.2342, a true skill statistic (TSS) value of 0.8251, a true positive rate of 0.9227, a false positive rate of 0.0976, an AUC value of 0.96, and an overall accuracy of 90.27%. These results indicate a high true positive rate and a low false positive rate for flare occurrence, demonstrating superior predictive performance compared to the single-modal Swin Transformer model and the Deep Residual Networks (ResNet) model using magnetograms as input. Additionally, STCNet outperforms the multi-modal ResNet model with the same inputs. Compared to existing studies, the STCNet model also shows remarkable performance in terms of the TSS value.

solar flare prediction, deep learning, multi-modal, Swin Transformer model

PACS: 94.05.Sd, 96.60.qe, 96.60.Q-

doi: [10.1360/SSPMA-2024-0192](https://doi.org/10.1360/SSPMA-2024-0192)