中国科学: 物理学 力学 天文学 2024 年 第 54 卷 第 8 期: 289512
SCIENTIA SINICA Physica, Mechanica & Astronomica physcn.scichina.com
《中国科学》杂志社 SCIENCE CHINA PRESS
论 文

基于迁移学习的Vision Transformer网络对伽马射线暂现源分类

张燕婷[1,2*], 马想[1], 黄跃[1], 刘佳聪[1,2], 熊少林[1], 张鹏[1,3], 赵小芸[1]

1. 中国科学院高能物理研究所, 北京 100049;
2. 中国科学院大学, 北京 101408;
3. 同济大学电子与信息工程学院, 上海 201804
*联系人, E-mail: ytzhang@ihep.ac.cn

收稿日期: 2024-01-18; 接受日期: 2024-01-29; 网络出版日期: 2024-07-03
国家自然科学基金(编号: 12273042)、国家重点研发计划(编号: 2022YFF0711404)和中国科学院空间科学战略性先导科技专项(编号: XDA15360000)资助项目

摘要 伽马射线暂现源包括伽马射线暴(GRB)、软伽马射线重复暴(SGR)等极端天体爆发现象, 主要由空间伽马射线监测器(例如GECAM卫星)开展探测研究, 是天文学重要的研究前沿. 另外, 太阳活动和复杂的空间环境也会在空间伽马射线监测器产生各类爆发事件(统称为触发). 在诸多触发事件中对GRB和SGR进行快速分类识别是开展后续物理研究的重要前提. 传统的分类研究常使用贝叶斯方法, 利用多个特征信息建模计算各个类别概率, 但其需要大量的先验知识与合理的模型设想, 且不同卫星间的传统分类模型面临迁移难、适用窄等问题. 为高效快速地对触发进行分类, 本文提出利用Vision Transformer网络, 基于迁移学习和单流多模态的思想, 使用较少的计算资源和数据对触发进行分类. 本文将该方法应用于GECAM触发数据, 实验结果表明, 模型在测试集中准确率达到了89%, 且模型能够理解类别间的区分与相似性. 本文结果表明, 这种新的方法对于伽马射线暂现源以及其他天文现象的分类具有良好应用前景.

关键词 伽马射线暂现源, 迁移学习, 触发分类

PACS: 95.85.Pw, 07.05.Mh, 95.55.Ka

1 引言

伽马射线暂现源是当今天文学研究的重要前沿, 主要包括伽马射线暴(Gamma-Ray Burst, GRB)和软伽马射线重复暴(Soft Gamma-Ray Repeater, SGR)等极端天体爆发现象. GRB是宇宙中最强烈的爆炸现象之一, 短时间内可释放大量的伽马射线, 在天空中随机爆发, 平均每天可探测到数例[1]. GRB 221009A是迄今发现的最亮伽马射线暴, 全球大量望远镜开展了观测研究, 我国的空间和地面观测设置发挥了重要作用[2]. SGR主要来自银河系或近邻星系, 产生于极强磁场中子星(称为磁陀星)[3]的爆发. SGR1935+2154是一颗银河系

引用格式: 张燕婷, 马想, 黄跃, 等. 基于迁移学习的Vision Transformer网络对伽马射线暂现源分类. 中国科学: 物理学 力学 天文学, 2024, 54: 289512
Zhang Y T, Ma X, Huang Y, et al. Classification of gamma-ray transients using vision transformer network based on transfer learning (in Chinese). Sci Sin-Phys Mech Astron, 2024, 54: 289512, doi: 10.1360/SSPMA-2024-0020

© 2024 《中国科学》杂志社

内的著名磁陀星, 近年来非常活跃, 不仅产生大量X射线暴, 而且产生快速射电暴[4]. 这些高能爆发现象的研究对于理解宇宙的演化、星系的形成、黑洞和中子星的物理性质具有重要意义, 因此一直是天文学的研究热点.

引力波暴高能电磁对应体全天监测器(GECAM, 命名为怀柔一号极目卫星)是由中国科学院针对引力波研究重大机遇部署研制的空间项目, 入选“空间科学”(二期)先导科技专项. GECAM包含2颗微小卫星, 2020年12月发射入轨, 轨道高度600 km, 倾角29°[5]. 每颗GECAM卫星的有效载荷包括25个伽马射线探测器(GRD)[6]与8个荷电粒子探测器(CPD)[7]. 为了测量伽马射线暴的宽能段能谱, GRD探测能量范围设计为8–5000 keV, 且结合CPD共同识别伽马射线触发与带电粒子触发, 其中CPD可以对200 keV以上的荷电粒子(电子)进行测量, 而CPD对伽马射线的探测效率比对荷电粒子低得多[8]. GECAM的触发判定主要利用GRD计数计算信噪比, 其显著性大于规定阈值则判定为触发事件[9,10]. 其中GRB、SGR、亮源掩食、太阳耀发[11]以及空间粒子事件等都可能造成触发. 对于这些诸多触发事件, 快速响应并分类, 判断GRB与SGR的触发并引导其他望远镜进行后随观测, 是GECAM卫星的主要观测任务之一, 也是捕捉引力波高能电磁对应体和快速射电暴高能辐射的重要环节之一.

目前常用的触发分类方法根据有效载荷设计, 利用贝叶斯方法建模, 综合多个特征信息计算分类概率, 这种方法需要大量的先验知识, 寻找适合的模型, 且由于不同卫星间探测效率和能量范围等的不同, 模型间不可共用. 例如基于硬度比、McIlwain L坐标、地心角以及事件的赤经(RA)和赤纬(Dec)等参数进行贝叶斯建模, 对触发事件进行分类[12]. GECAM有效载荷CPD可监测环境荷电粒子变化, 对于能量较高的荷电粒子导致的触发的判断更加直观有效, 基于硬度比、地心角与定位的赤经和赤纬信息, 依照经验设置阈值判断触发类别.

近年来, 深度学习技术在图像识别、自然语言处理等领域取得了显著的成就, 其强大的特征学习和分类能力为处理复杂的高维数据提供了新的思路. 深度学习在天文数据对分类、预测和分割等任务上均有应用[13–15]. 因为卷积神经网络处理图像数据的优越性与目前技术成熟性, 神经网络在天文数据上的应用常使用图像数据, 而像GECAM这样的非成像的探测器得到的数据本身不具备图像信息的特性. GECAM有效载荷具有空间上的排列关系, 如图1所示[16], 伽马射线的来源方向会导致相邻GRD的计数显著地上升[17], 并且对于粒子导致的触发可以依据CPD相对于GRD的光变特征进行判断. 基于上述GECAM有效载荷设计, 本文旨在利用深度学习技术, 提出基于Vision Transformer (ViT)[18]的基本模型, 对卫星观测到的伽马射线触发事件进行分类, 以期能够提高对触发的识别准确性和分类效率.

ViT网络是2021年由Google Brain团队提出的一种

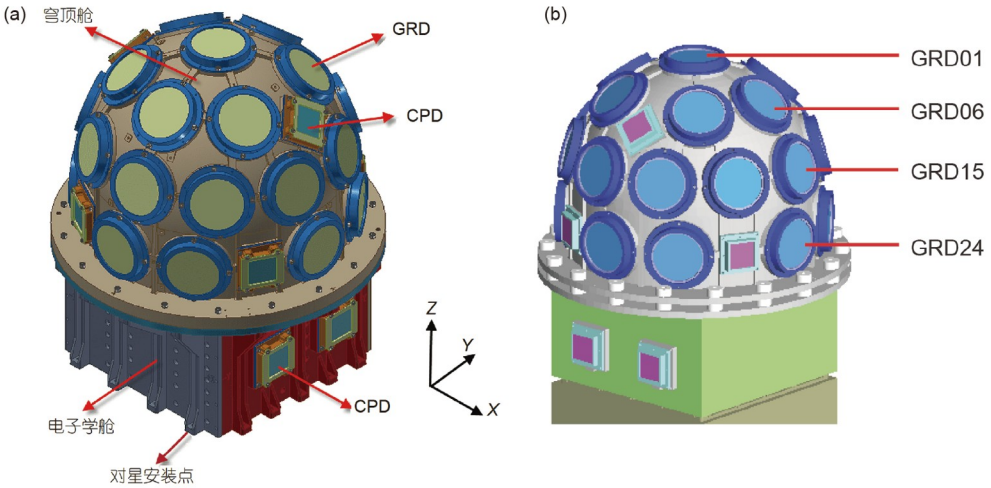


图 1 (网络版彩图) GECAM有效载荷(a)和探测器编号(b)[16]

Figure 1 (Color online) The payload of GECAM (a) and detector ID (b) [16].

用于处理视觉数据的深度学习模型. ViT旨在克服传统卷积神经网络在处理大规模图像数据时的局限, 并探索Transformer模型在计算机视觉领域的应用. 核心思想是将图像数据切割为一系列图像图块(patch), 然后将这些图像图块经过线性转换转为序列数据, 使用Transformer模型进行处理. 这种方法使得ViT模型能够在处理图像时摆脱传统的卷积操作, 直接利用自注意力机制捕捉图像中的全局和局部特征, 并在多个计算机视觉任务上媲美甚至超越传统卷积神经网络.

因为ViT网络对比卷积神经网络(CNN)模型缺少了平移不变性与局部性的特性, 所以需要大规模预训练数据集训练后才能释放ViT在图像上分类的能力. 而本文所使用的数据为多能段的光变序列数据, 数据本身不具有图像信息所要求的两个特性, 具体的数据处理在第2节介绍. 期望将基本的Transformer结构应用于多通道的光变数据, 同时GRD的空间排列信息能够帮助区分已知源(太阳与SGR1935+2154).

本文采用了ViT网络, 基于单流多模态的思想, 同时处理GRD, CPD光变数据以及已知源相对于探测器法线的夹角变化(后文都称入射角). 利用25个GRD与CPD的光子计数信息, 由于不同方向触发与探测器计数之间的相关关系, 还利用了入射角信息, 以单流多模态学习的思想将三者的信息交互, 训练网络进行触发分类任务. 由于个别类别的数据较少, 利用泊松随机概率对光变数据进行数据增强, 采用了迁移学习的方法以提高模型的性能.

2 数据集准备

为了将ViT网络与预训练模型应用到触发事件数据中, 需要对原始事例数据进行选择与处理. 本节将详细描述获取样本数据与标签.

2.1 数据选择

统计GECAM-B星2021年7月到2023年10月星上触发分类数目, 如图2所示, 选择数目较多的五类: 粒子事件(PARTICLE)、伽马射线暴(GRB)、太阳(SFLARE)、仪器效应(Instrument Effect)和SGR1935+2154(一颗活跃的磁陀星). 其中仪器效应主要是数采设备或偏压调节等导致的误触发, 不考虑在分类类别中, 最终选择其余四类作为本文的分类类别.

基于涉及的信息, 对GRD事例数据文件、CPD事例数据文件和卫星轨道与姿态文件进一步进行评估. 对于数据缺失, 涉及两类情况: 一类是数据本身存在缺失, 可能由于数采设备或数据生产流程导致; 另一类是卫星开关机导致部分时段数据为0. 两者原因导致的数据缺失作为过滤条件, 对现有的四类触发事件进行初步清洗.

由于样本间数目不均衡, 最终选择2022年1月到9月的粒子事件, 其余数据较少的三类, 选择了2021年1月到2022年9月的触发数据作为初筛后的数据集, 见表1.

2.2 标记数据

初筛得到的数据集其类别是由目前的触发分类系统得到, 标签不完全正确, 需要对其标签进行二次的人工确认. 人工依据触发定位, GRD和CPD的光变信息、卫星轨道位置和外部触发等再次确认类别, 最后得到最终的类别. 其中PARTICLE主要依靠CPD的光变信息和卫星轨道位置是否处于高粒子计数区或SAA异常区[19]; SFLARE和SGR1935+2154类别是要依靠触发定位和GRD光变信息, 更多地依靠定位信息以及其他观测设备的观测确认; GRB主要依赖光变、能谱、定位以及是否有其他卫星在相同的时段且定位相近的触

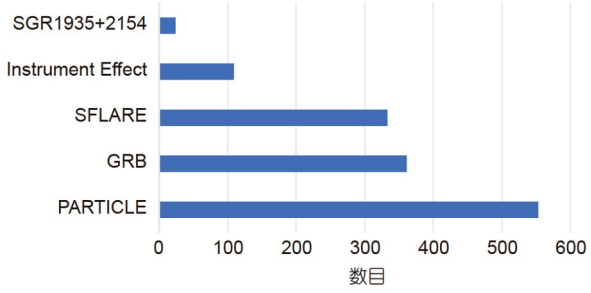


图 2 (网络版彩图) GECAM星上触发类别统计
Figure 2 (Color online) GECAM in-flight trigger category statistics.

表 1 数据集
Tabel 1 Dataset

Label	Number	Training set	Validation set	Test set
PARTICLE	229	240	25	25
SFLARE	269	240	25	25
GRB	98	240	25	25
SGR1935+2154	48	240	25	25

发. 且对于类别中存在分类系统与人工意见相左且人工也难以分辨其确切的类别时, 此样本不再被采纳入数据集中. 其中主要关注触发来源, 最后清洗得到229例PARTICLE, 269例SFLARE, 48例SGR1935+2154爆发和98例GRB.

2.3 数据预处理

GECAM有效载荷25个GRD均匀分布同一穹顶舱上, 其中穿插了6个CPD, 另有2个CPD安装在电子学舱上, 如图1(a)所示, GRD编号随极角与方位角呈螺旋式分布, 如图1(b)所示. GRD主要探测伽马射线信号, CPD主要探测荷电粒子. 对于不同触发事件, 探测器的计数表现不同. 例如太阳耀斑主要会导致对应方向上的GRD低能段触发, 而GRB和SGR因为其爆发性质不同, 不同的GRB和SGR事件在GRD触发能段的信号也存在多样性, 而粒子事件通常会导致CPD和GRD同时触发, 但对于一些较低能量的电子, CPD也可能没有信号而只在GRD留下信号, 从而与伽马射线触发事件的表现具有一定的相似性.

描述一个触发事件的要素通常由三个方面组成: 触发定位、光变和能谱表现. 对触发分类传统方法总是围绕触发定位, 利用定位与已知源坐标误差范围的比对, 判断其是否来自已知的源, 在很大的程度上可以直接判断触发的类别与来源, 甚至是成因. 光变主要描述触发持续的时间和上升与下降的剧烈程度, 粒子事件在光变上的表现大部分表现为缓慢的上升与下降, 一般不会出现明显的峰. 能谱表现则描述了触发光变特征主要表现的能量范围以及各个能段的信号强弱关系.

基于GECAM载荷设计和传统办法对触发分类信息的利用, 且计数率定位根据不同GRD计数建模定位天区, 根据入射关系, 越倾向于正入射, 其计数越多. 尽可能保留触发事件在不同能量范围内的光变特征信息, 将观测数据处理为多能段的光变信息, 利用GRD光变数据、CPD光变数据与已知源对于GRD入射角三个部分的信息作为数据.

使用信息包含了三方面: GRD, CPD和入射角. 其中GRD与CPD均为事例数据, 为了使用网络的数据输入接口, 本文将这两者的数据按照GECAM能量分界经验, 将事例按照能量范围分为三个通道(图3(a)): 10–30 keV, 30–60 keV, >60 keV, 其中>60 keV部分并不包括超高事例(超高事例指超过探测能量范围的事例). 为了尽可能涵盖光变特征与背景计数, 选取相对触发时刻T0的T0−50 s到T0+206 s的时间范围, 以0.25 s间隔进行并道, 得到长度为1024的三通道的光变数据. 每个GRD探头三通道的光变数据作为一个图像图块, PARTICLE主要是依据CPD光变的涨落辅助分类, 所以只选取均值作为一个图像图块.

入射角信息包含了两个已知源, 分别是太阳与SGR1935+2154, 如图3(b)所示, 其为SGR1935+2154相对于25个GRD法线的夹角(即入射角). 利用卫星轨道姿态数据与已知源在同时刻位置计算入射角, 其中卫

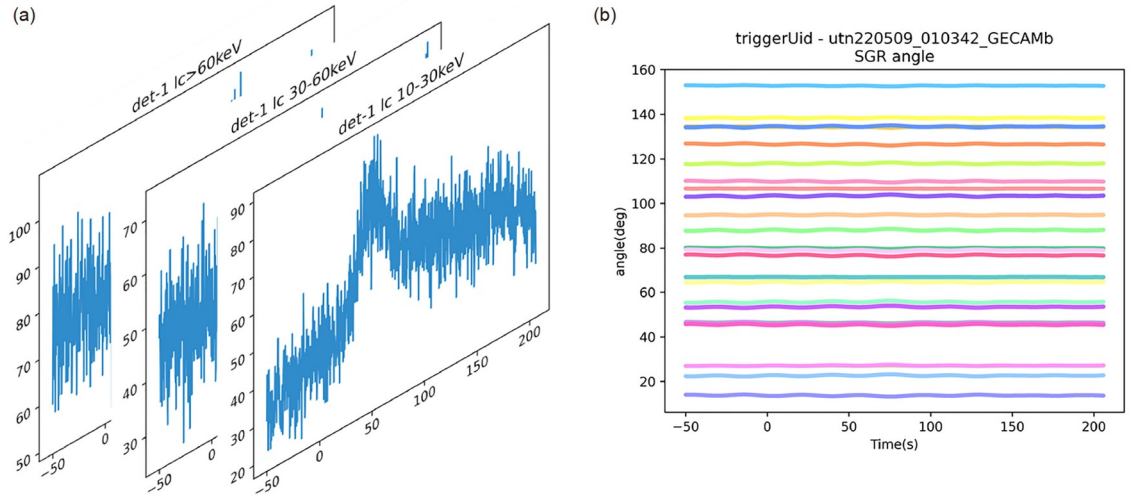


图 3 (网络版彩图)光变数据(a)与入射角数据(b)示例

Figure 3 (Color online) Example of light curve data (a) and incident angle data (b).

星轨道姿态数据的时间分辨率为1 s, 利用三次样条插值后以0.25 s间隔抽取得到入射角. 不同探头与已知源入射角的大小应当与此类别GRD光变特征和计数相关. 但其只是一维的随时间变化的序列, 不符合三通道的要求. 为了符合通道需求且不超出剩余图像图块数目, 将三组入射角作为一个图像图块进入网络.

自此, 一共占用了44个图像图块, 剩余5个图像图块未加入其余数据信息, 设置为0, 图4为最终触发事件数据的块分布, 光变和入射角数据经过重新调整形状拼合而成. 由于CPD计数在大多数触发事件中一个时间并道内计数仅有个位数或几十, 相较于GRD的计数过于小. 对结果可视化时发现, 直接以目前的数值作为样本数据, 网络训练最后得出CPD所占有的块对最后决策几乎没有贡献, 所以对目前数据张量中大于0的值取对数作为最后的样本数据, 以此平衡数据本身, 可视化结果较之前, CPD数据参与了结果贡献.

2.4 数据增强

由于SGR1935+2154与GRB这两类数目较少, 样本存在不均衡的情况, 为了防止模型可能对样本较少的类别表现不佳, 本文使用了对光变数据经过泊松概率分布后得到新的光变数据的数据增强策略. 光变数据通常具有随机性和不确定性, 而泊松分布则能够很好地描述这种随机性.

$$\mathrm{prob}(n \mid u) = \frac{u^n}{n!}\mathrm{e}^{-u}, \tag{1}$$

其中, u为原始的光变数据, n是通过采样获得的新的计数. 这样的数据增强策略有助于扩展原始数据集, 增加数据的多样性, 从而提高模型对于不同光变模式的识别能力.

由于清洗处理得到的样本中SGR1935+2154类别最少, 仅有48例, 所以各类别随机选取了25例样本组成测试集, 剩余的样本利用泊松随机分布数据增强后重新划分为训练集与验证集, 如表1所示. 各类别数据增强时同一样本使用的随机种子不重复, 单个随机种子会对刨除测试集的样本一一进行泊松随机分布得到新光变, 若未达到规定数, 则进入下一个随机种子的循环, 直到数目满足规定数目. 分别测试了训练集数目200, 240, 300, 350, 其中240得到的模型准确率最高.

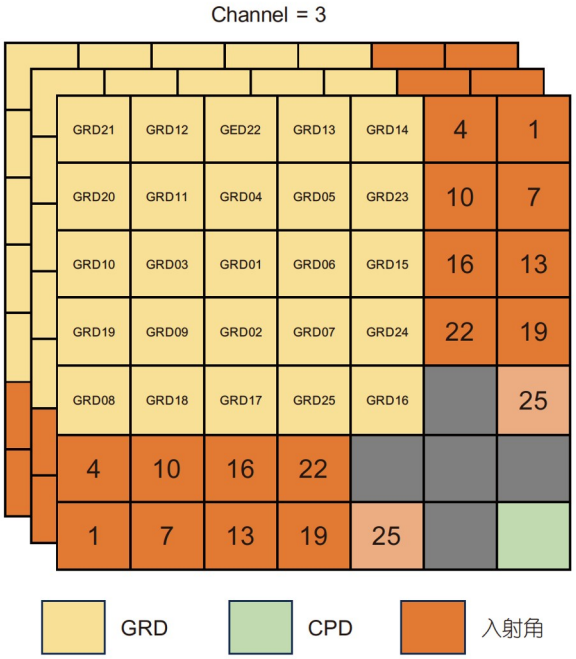


图 4 (网络版彩图)数据处理与结构(右上为太阳入射角, 左下为SGR1925+2154入射角)

Figure 4 (Color online) Data processing and structure (the upper right part is the solar incidence angle, and the lower left part is the incidence angle of SGR1925+2154).

3 方法

3.1 模型架构

本文采用的是ViT-Base/32规模的网络结构, 网络最后一层线性层替换为四分类的线性层, 其中还包含12层变换网络编码器(Transformer Encoder). 图像被分为了7 × 7的图像图块, 每个图像图块有32 × 32像素, 额外添加的类别标记(Class Token)为模型提供整体数据的全局信息以实现分类目的, 最后模型结构如图5所示. 基于单流多模态思想[20], 使得多种信息交互融合, 但未使用区分不同模态的类型嵌入. 受限于计算与存储资源, 并未对规模更大的ViT-Large和ViT-Huge网络进行实验.

3.2 迁移学习与训练

以公开的预训练模型作为基础, 在实验中, 使用来自ViT模型的预训练权重, 该模型是通过使用DeiT网络[21]训练方法, 在ImageNet-1k数据集上进行训练得到的. 将预训练模型作为基准模型, 并在其基础上进行微调以适应本实验任务.

首先加载ViT的预训练模型参数, 利用清洗并数据

增强后的GECAM触发数据集进行迁移学习. ViT网络由Transformer Encoder基础结构构成, 经过大量数据的训练后, 其在图像分类的准确率优于卷积神经网络. 理论上若使用ViT网络, 迁移学习处理的对象应当是图像数据, 而Transformer Encoder结构常用于处理文本与音频等序列数据. 基于事例文件的特性, 其描述了一个光子被探测到的时间与能量, 则在时间与能量尺度上, 可以二维地描述光变数据, 数据经过简单的变化则可以吻合ViT网络的输入数据.

迁移学习策略如图6所示, 为使模型参数迁移到目标任务数据集, 利用GECAM触发数据集微调后7层Transformer Encoder、输入层的线性映射和位置编码部分, 使输入处理适应目标数据集, 且体现有效载荷空间分布与数据交互关系. 选用交叉熵函数作为损失函数, 学习率测试了1×10^{-3}, 8×10^{-4}, 1×10^{-4}和5×10^{-5}, 最后选用了5×10^{-5}作为学习率, 迭代次数设置为50次, 批处理大小为20.

4 结果与分析

4.1 评价指标

为衡量模型的优劣, 本文采用混淆矩阵(其中SGR1935+2154简写为SGR)评估模型有效性, 但混淆矩阵仅提供了对模型性能的全面评估, 仅统计相关总

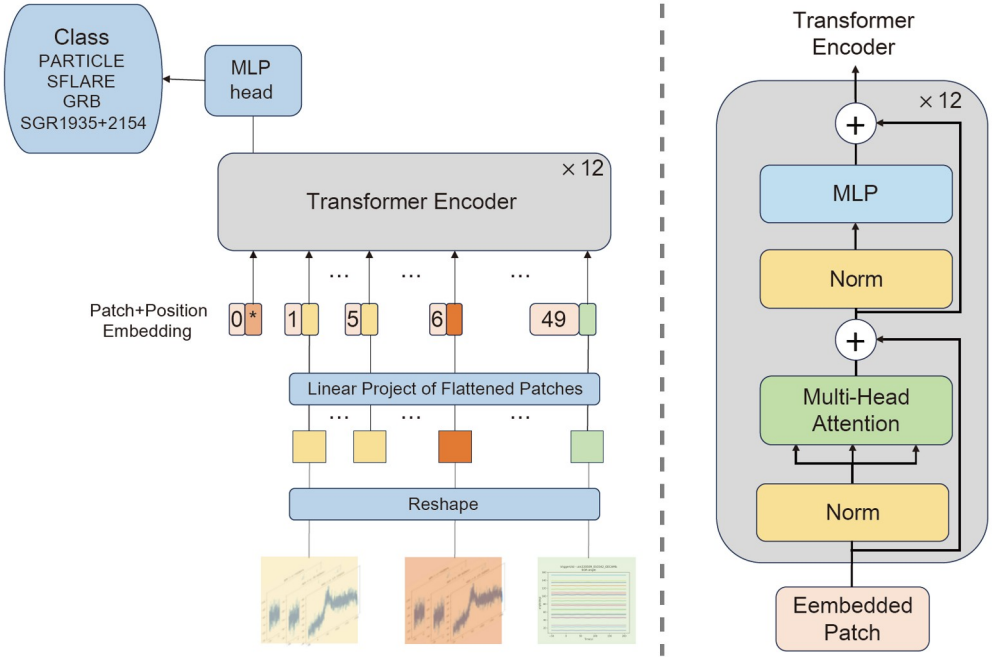


图 5 (网络版彩图)模型结构

Figure 5 (Color online) Model architecture.

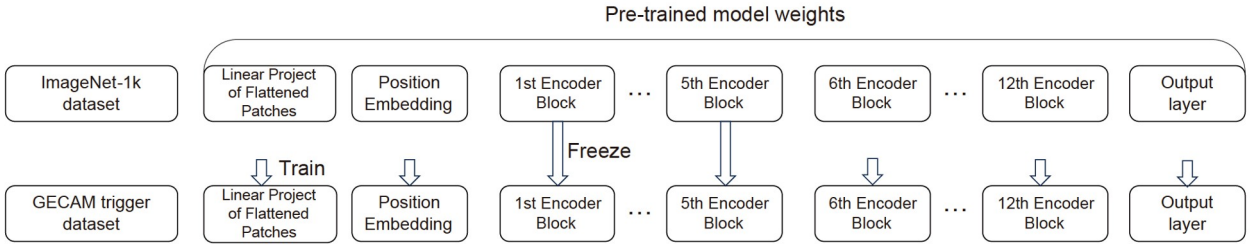


图 6 迁移学习策略

Figure 6 Transfer learning strategy.

数, 所以增加4个与类别相关的二级指标, 分别是准确率Accuracy、精确率Precision、召回率Recall和特异度Specificity, 且进一步扩展增加F_1分数.

$$\text{Accuracy} = \frac{\sum_i TP_i}{\text{Total}}, \tag{2}$$

$$\text{Precision} = \frac{TP_i}{TP_i+FP_i}, \tag{3}$$

$$\text{Recall} = \frac{TP_i}{TP_i+FN_i}, \tag{4}$$

$$\text{Specificity} = \frac{TN_i}{TN_i+FP_i}, \tag{5}$$

$$F_1 = \frac{2\times\text{Precision}}{\text{Precision}+\text{Recall}}, \tag{6}$$

其中TP_i, FP_i, FN_i和TN_i为类别Class$_i$的真阳性、假阳性、假阴性和真阴性, Total为测试集样本总数.

混淆矩阵(图7)可以直观查看测试集分类的情况, 其中大部分的类别都能得到正确的分类, 这体现在混淆矩阵的对角线上, 对角线上的数值代表了模型对该类别的正确分类数量. 然而, 混淆矩阵也展示了存在误分类的情况, 即模型将某些样本错误地分类到了其他类别. 这些误分类的情况可以在混淆矩阵的非对角线元素中体现出来, 帮助我们了解模型在不同类别上的分类表现. 根据混淆矩阵与评价指标(表2)结合分析, 类别F_1分数均达到了0.8以上, GRB类别较其余三类分类效果最弱, 25例中有6例误判, 其余类别仅1–2例误判. 具体某些样本误分类的情况, 需要后续详细地分析.

4.2 模型迁移学习前后对比

图8展示了完全未使用预训练权重参数且冻结底层Encoder层的模型表现(蓝虚线), 完全未使用预训练权重参数且所有层参数都参与梯度迭代(绿虚线), 以及使用了预训练模型且冻结底层Encoder层的模型表现(红实线).

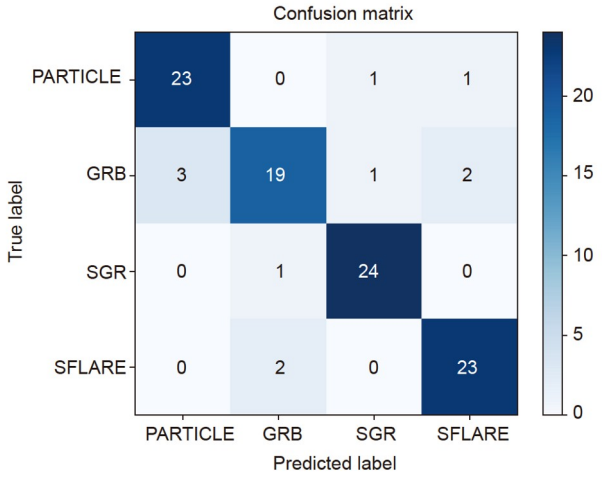


图 7 (网络版彩图)混淆矩阵

Figure 7 (Color online) Confusion matrix.

可以看到公开的预训练模型且经过微调后的效果最好, 达到了89%, 较未使用预训练模型参数分别提升了26%和31%. 这说明预训练模型底层的特征提取层与本文的实验数据是契合的, 以多通道光变数据和入射角数据作为图像图块, 在一定程度上可以被预训练模型的特征提取器提取到有效的特征, 同时利用目标数据集微调上层可以提升准确率.

4.3 可视化分析

可视化Transformer模型常见的做法是, 针对单个注意力层, 将注意力视为相关性得分; 另一种则是组合多个注意力层, 简单地平均获得每个标记的注意力权重. 其中有基于CNN可视化思想的方案[22,23], 但应用到Transformer模型时常会出现噪点或偏差的情况, 还有利用多注意力层可视化的方案[24,25]. 本文热力图采用了基于类别分离的可视化方案[26], 考虑到了残差

表 2 测试集评价指标

Tabel 2 Evaluation metrics in the test set

Class	Accuracy	Precision	Recall	Specificity	F1 score
PARTICLE	0.8900	0.8846	0.9200	0.9600	0.9020
SFLARE		0.8846	0.9200	0.9600	0.9020
GRB		0.8636	0.7600	0.9600	0.8085
SGR1935+2154		0.9231	0.9600	0.9733	0.9412

连接和正负贡献的修正.

如图9展示的热力图, 是依据网络对不同类别的分类权重给出的, 累计了多层的注意力机制. 其中可以看到不同信息对于结果均有贡献, 对PARTICLE分类的CPD的图像图块的影响相较于其余三类更高, 并且对于GRD区域的关注度也弱于其余三类. 其中对于SFLARE分类, 由于设备供电对卫星轨道姿态的设定, 太阳导致的触发常在特定的几个GRD出现计数率上升, 可以看到图中对于SFLARE类别贡献主要依靠集中的几个GRD光变信息. 而SGR1935+2154与GRB这两类关注的区域集中于具有明显光变特征的GRD区域, 且对于CPD的关注不高, 在入射角部分两者较为明显的区别在于SGR1935+2154关注左下角区域更多.

在本研究的训练阶段, 采取了解冻位置编码的策略[18]. 采取这一策略的主要原因在于希望网络能够学习到25个GRD的空间位置信息, 并且承担对不同的信息数据的模态类型嵌入.

解冻位置编码意味着网络在训练过程中对位置编码进行调整和学习, 而不是固定不变. 这样的策略能够让网络更好地理解和利用输入数据的空间位置信息, 尤其是对于包含25个GRD的数据. 通过学习位置编码, 网络可以更好地区分不同位置的信息, 从而提高对数据的理解和处理能力. 图10为位置编码的相似性分析, 计算两位置编码之间的余弦相似度, 反映了各图块与自身和其余图块的位置编码相似程度, 其中相似度越偏向于1, 则其越具有高度的相关相似.

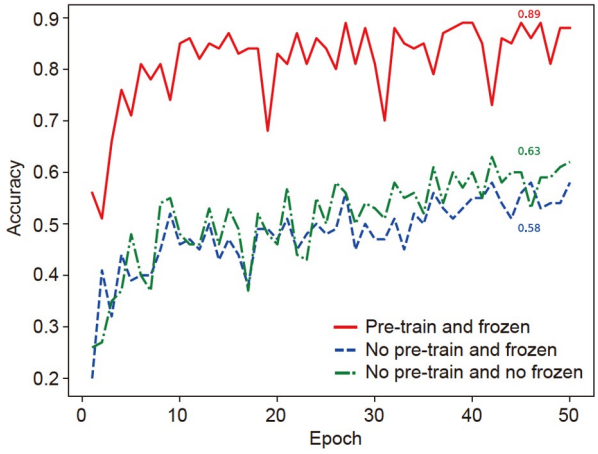


图 8 (网络版彩图)不同策略训练集准确率的变化情况

Figure 8 (Color online) Changes in accuracy of training sets with different strategies.

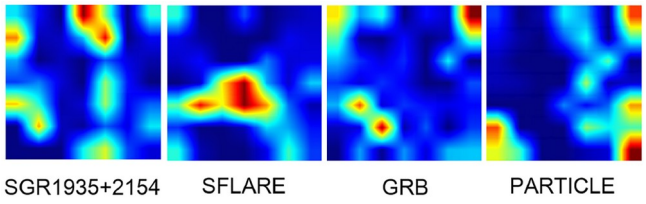


图 9 (网络版彩图)受关注信息的可视化

Figure 9 (Color online) Visualization of attention information.

4.4 全局信息UMAP降维

图11为对最后的Encoder层的输出取出特殊的全局Class Token进行UMAP[27]降维聚类, 从图11中观察

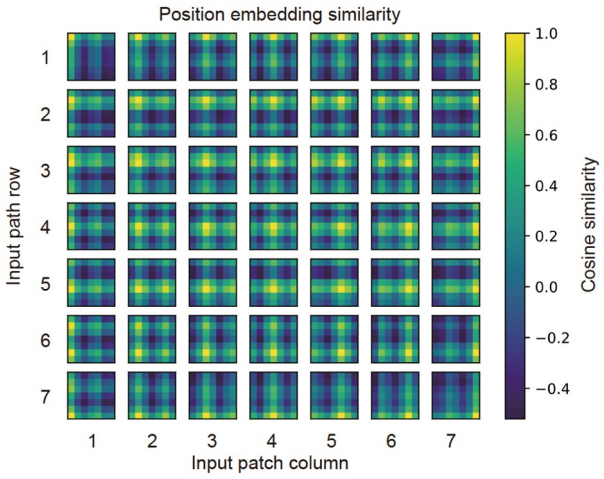


图 10 (网络版彩图)位置嵌入的相似性

Figure 10 (Color online) Similarity of position embeddings.

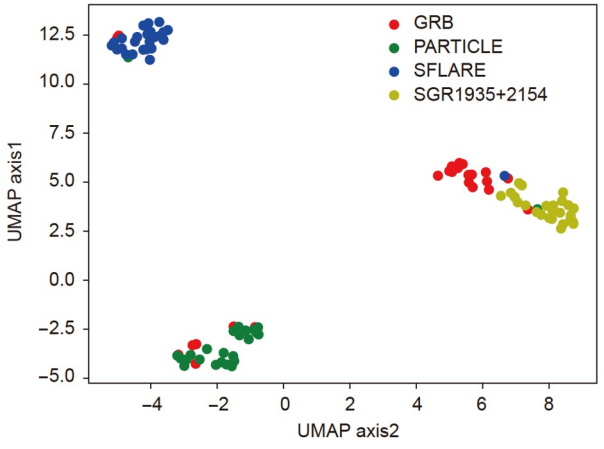


图 11 (网络版彩图)全局分类信息UMAP降维

Figure 11 (Color online) Global classification information after UMAP dimensionality reduction.

到数据被明显地分为了四个簇，PARTICLE分布在两个较近的簇，GRB和SGR1935+2154分布在同一个簇. UMAP网络在降维后将数据明显地分为了间距较远的三个簇, 显示出了簇内簇间样本之间欧氏距离的远近.

在这四个簇中, SGR1935+2154和GRB两类集中在一个簇中, 但簇内存在明显的分界, 并且与其余的簇间距离很远. 这说明它们存在相似的特性, 可能在特征空间上具有一定的相似性，可能因为GRB中本身就包含了类似SGR的触发，但是否已知位置将两者做了区分, 说明模型理解了两者之间的相似与区分. 而SFLARE和PARTICLE明显地区分于其余两类，且簇间距十分明显，说明模型对类间的区分有效果. 且注意到PARTICLE簇中分为了两个相距较近的簇，推测是否是因触发的机制不同而使PARTICLE内有了二级类别产生, 可能是粒子事件根据持续的时间和来源的远近也有区分, 因为没有对粒子事件做更细致的分类, 不再做详细的讨论.

5 结论

伽马射线暂现源是重要研究领域，是GECAM这类伽马射线全天监测器的主要研究目标. 但是GECAM在轨观测发现各种类型的伽马射线触发，包括来自太阳或者空间环境造成的触发. 对这些触发事件进行分类有助于研究人员快速判断触发事件的价值，特别是需将伽马射线暴(GRB)和软伽马射线重复暴(SGR)区分识别出来，是开展后续深入研究的重要前提.

本文提出利用ViT网络对GECAM触发事件进行分类, 其中数据包括了光变和入射角信息, 利用单流多模态的思想, 将多种信息进行整合输入同一网络中. 利用ViT-Base/32预训练模型，使用迁移学习的方法，冻结底层的特征提取层，对上层的网络参数进行训练. 最后分类准确率达到了89%. 同时利用对模型可解释性以热力图、位置编码和特征降维三方面做了解释, 模型学习到了样本间的区分与相似，能够区分差距较大的类别，且对于触发机制相似的类别，模型也能够理解.

虽然目前样本的数量与计算资源比较有限，但已显示出利用深度学习对多通道多模态数据交互达成较好的分类效果. 随着将来样本数量的增加和计算资源的扩大，有望进一步完善分类标签，根据触发机制对其进行更细致的划分. 而且可考虑将该方法应用于其他天文学领域，以探索其在不同领域的适用性和潜在价值. 最后，也可以考虑探索其他深度学习模型或改进现有模型，以提高分类的精确度，以及结合领域知识和先验信息，进一步优化模型的设计，以适应更多样化的触发事件.

致谢 感谢GECAM团队提供的数据支持和相关讨论.

参考文献

1 Zhang B. Open questions in GRB physics. C R Phys, 2011, 12: 206–225

2 An Z H, Antier S, Bi X Z, et al. *Insight*-HXMT and GECAM-C observations of the brightest-of-all-time GRB 221009A. arXiv: 2303.01203

3 Hurley K. Soft gamma repeaters. Adv Space Res, 2011, 47: 1326–1331

4 Li C K, Lin L, Xiong S L, et al. HXMT identification of a non-thermal X-ray burst from SGR J1935+2154 and with FRB 200428. Nat Astron, 2021, 5: 378–384

5 Li X Q, Wen X Y, An Z H, et al. The GECAM and its payload (in Chinese). Sci Sin-Phys Mech Astron, 2020, 50: 129508 [李新乔, 文向阳, 安正华, 等. GECAM卫星有效载荷介绍. 中国科学: 物理学 力学 天文学, 2020, 50: 129508]

6 Lv P, Xiong S L, Sun X L, et al. A low-energy sensitive compact gamma-ray detector based on $LaBr_3$ and SiPM for GECAM. J Inst, 2018, 13: P08014

7 Xu Y B, Sun X L, Yang S, et al. The design and performance of charged particle detector onboard the GECAM mission. arXiv: 2112.05314

8 An Z H, Sun X L, Zhang D L, et al. The design and performance of GRD onboard the GECAM satellite. Radiat Detect Technol Methods, 2021, 6: 43–52

9 Zhao X Y, Xiong S L, Wen X Y, et al. The in-flight realtime trigger and localization software of GECAM. arXiv: 2112.05101

10 Cai C, Xiong S L, Xue W C, et al. Burst search method based on likelihood ratio in Poisson statistics. Mon Not R Astron Soc, 2023, 518: 2005–2014

11 Zhao H S, Li D, Xiong S L, et al. Paired quasi-periodic pulsations of hard X-ray emission in a solar flare. Sci China-Phys Mech Astron, 2023, 66: 259611

12 Perrin D J, Sidman E D, Meegan C, et al. GLAST burst monitor trigger classification algorithm. In: Proceedings of the Meeting of the High Energy Astrophysics Division of the American Astronomical Society. New Orleans: American Astronomical Society, 2004. 943

13 Dieleman S, Willett K W, Dambre J. Rotation-invariant convolutional neural networks for galaxy morphology prediction. Mon Not R Astron Soc, 2015, 450: 1441–1459

14 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. Astrophys J, 2018, 869: 91

15 Cabrera-Vives G, Reyes I, Förster F, et al. Deep-HiTS: Rotation invariant convolutional neural network for transient detection. Astrophys J, 2017, 836: 97

16 Guo D Y, Peng W X, Zhu Y, et al. Energy response and in-flight background simulationfor GECAM (in Chinese). Sci Sin-Phys Mech Astron, 2020, 50: 129509 [郭东亚, 彭文溪, 朱玥, 等. GECAM能量响应及在轨本底模拟. 中国科学: 物理学 力学 天文学, 2020, 50: 129509]

17 Liao J Y, Luo Q, Zhu Y, et al. The localization method of GECAM and simulation analysis (in Chinese). Sci Sin-Phys Mech Astron, 2020, 50: 129510 [廖进元, 罗琦, 朱玥, 等. GECAM定位方法及模拟分析. 中国科学: 物理学 力学 天文学, 2020, 50: 129510]

18 Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: Transformers for image recognition at scale. arXiv: 2010.11929

19 Li B Q, Zhu G W, Wang S J, et al. The space particle composition detector aboard FY-1C satellite and analysis of particle radiation in South Atlantic anomaly (in Chinese). Chin J Geophys, 2004, 47: 954–958 [李保权, 朱光武, 王世金, 等. 风云一号C星空间粒子成分探测器及SAA区粒子辐射实测分析. 地球物理学报, 2004, 47: 954–958]

20 Kim W, Son B, Kim I. ViLT: Vision-and-language transformer without convolution or region supervision. In: Proceedings of the 38th International Conference on Machine Learning. 2021. 5583–5594

21 Touvron H, Cord M, Douze M, et al. Training data-efficient image transformers & distillation through attention. arXiv: 2012.12877

22 Odena A, Dumoulin V, Olah C. Deconvolution and checkerboard artifacts. Distill, 2016, 1: e3

23 Xie W Y, Li X H, Cao C C, et al. ViT-CX: Causal explanation of vision transformers. arXiv: 2211.03064

24 Abnar S, Zuidema W. Quantifying attention flow in transformers. In: Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics. Association for Computational Linguistics, 2020

25 Chefer H, Gur S, Wolf L. Generic attention-model explainability for interpreting Bi-modal and encoder-decoder transformers. arXiv: 2103.15679

26 Chefer H, Gur S, Wolf L. Transformer interpretability beyond attention visualization. arXiv: 2012.09838

27 McInnes L, Healy J, Melville J. UMAP: Uniform manifold approximation and projection for dimension reduction. arXiv: 1802.03426

Classification of gamma-ray transients using vision transformer network based on transfer learning

ZHANG YanTing[1,2*], MA Xiang[1], HUANG Yue[1], LIU JiaCong[1,2], XIONG ShaoLin[1], ZHANG Peng[1,3] & ZHAO XiaoYun[1]

[1] *Institute of High Energy Physics, Chinese Academy of Sciences, Beijing 100049, China;*
[2] *University of Chinese Academy of Sciences, Beijing 101408, China;*
[3] *College of Electronic and Information Engineering, Tongji University, Shanghai 201804, China*
**Corresponding author (email: ytzhang@ihep.ac.cn)*

Gamma-ray transient sources include extreme astrophysical phenomena such as gamma-ray bursts (GRBs) and soft gamma-ray repeaters (SGRs). These phenomena are mainly studied using space gamma-ray detectors (such as the GECAM satellite) and represent an important frontier in astronomy research. Additionally, solar activity and complex space environments can generate different types of outbursts (collectively referred to as triggers) in space gamma-ray detectors. Among various trigger events, the rapid classification and identification of GRBs and SGRs are important prerequisites for subsequent physical research. Traditional classification studies often use Bayesian methods to model and calculate the probabilities of different categories using multiple feature information. However, these methods require considerable prior knowledge and reasonable model assumptions, and traditional classification models between different satellites face problems such as difficult migration and narrow applicability. To efficiently and rapidly classify triggers, this paper proposes using the vision transformer network, based on transfer learning and the single-stream multimodality concept, to classify triggers using fewer computational resources and data. We applied this method to GECAM trigger data. Experimental results show that the model achieved an accuracy of 89% in the test set and understood the similarity and distinction between categories. These results indicate that the proposed method has good application prospects for classifying gamma-ray transient sources and other astronomical phenomena.

gamma-ray transient sources, transfer learning, trigger classification

PACS: 95.85.Pw, 07.05.Mh, 95.55.Ka

doi: 10.1360/SSPMA-2024-0020