

基于 PCT 模型的快速射电暴搜索算法

李俊霖^{1,2}

LI Junlin

摘要

快速射电暴 (FRB) 是一种神秘的天文现象, 在射电天文学领域, FRB 的研究对于理解宇宙中的极端物理过程和天体演化机制具有重要意义。针对现有面向真实 FRB 信号的搜寻算法存在资源耗费大、搜寻效率低等问题, 提出了一种基于小波卷积与 Former 结构的搜索算法。采用图像金字塔构建不同尺寸下的图像特征, 利用小波卷积特征提取器和 Former 特征提取器分别对不同尺寸的图像特征进行特征提取, 随后使用特征采样注意力机制对不同特征提取器提取的特征结果进行特征融合, 以判断当前信号帧图像中是否存在快速射电暴信号。实验结果表明, 所提出的方法能减少时间开销, 提高分类准确率。在公开的真实数据集上进行了迁移训练, 将算法应用到真实 FRB 信号的搜寻中, 测试结果表明, 算法对真实 FRB 信号搜寻的准确率达到 0.996, F_1 指标达到了 0.986, 代码和实验公开在 <https://github.com/aoxipo/PCT> 网站上。

关键词

attention; Transformer; 深度学习; FRB 搜索

doi: 10.3969/j.issn.1672-9528.2024.04.020

0 引言

快速射电暴 (fast radio bursts, FRB) 是射电中低频段最为剧烈的爆发现象, 至今起源未知, 蕴含了基础物理和天文学科方面重大突破的机遇。FRB 的搜寻, 是一项需要大量计算资源且耗时的任务, 如何提高 FRB 的搜寻效率是当前面临的重要问题之一。当前常采用的机器学习算法有随机森林等^[1-3]。传统机器学习算法的搜寻效果比较依赖消色散算法, 消色散可以提升算法效果, 但是也大大增加了算法时间开销。

传统搜寻方法产生的较多候选体, 需要通过人工辨别。利用深度学习算法可以提高人工辨别的效率。Connor 和 Van Leeuwen 等人将消色散动态谱、DM - 时间阵列、时间序列以及多波束探测信噪比信息作为 2 维 CNN、1 维 CNN 和 FNN 的输入, 分别单独提取特征, 然后在全连接层整合对候选体分类, 脉冲星的单脉冲识别达到 99.7% 的召回率^[6]。Devansh 等人组合了 11 种混合模型, 构建分类网络结合消色散和色散 - 时间信息在候选体中识别 FRB 信号^[7]。Zhang 提出显著图可以通过增强瞬态特征的亮度变化图像提高模型精度, 其构建了简单的 DNN 模型并通过预测的概率分数影响像素排序, 从而对给定像素进行梯度积分, 捕捉脉冲中平滑像素的亮度

变化, 进而对抗复杂的背景噪声, 识别出 FRB 信号^[8]。

利用深度学习算法在原始信号上直接搜索 FRB 信号, 可以避免复杂的消色散步骤。Zhang 等人提出了一个由 17 个卷积层组成的 ResNet 结构, 在未消色散的原始信号上训练并识别 FRB 信号。Liu 等人提出了一个 FRB 信号的分散动态光谱搜寻 (DDSS) 管道, 直接在原始数据上搜寻 FRB 信号, 将 ResNetV2 与 XceptionNet 模型作为其处理流程的特征提取部分。其算法准确精度达到了 99.6% 以上^[9]。但是针对的数据集色散范围仅在 $100 \sim 500 \text{ pc} \cdot \text{cm}^{-3}$ 。

在现有的 FRB 搜索算法中, 机器学习算法精度较低且去色散算法时间开销较大, 深度学习算法精度虽高但却对弱信号不敏感, 效果受限于仿真信号的好坏, 不能应用到真实 FRB 信号的搜寻中。本文提出了一种基于小波卷积与 Former 结构的搜索算法, 在真实 FRB 数据集中最高能获得 0.960 的准确率, F_1 值达到了 0.968, 模型代码整理公开在 <https://github.com/aoxipo/PCT> 网站上。

1 仿真数据集

由于真实 FRB 信号较少, 不够用来训练深度学习模型, 本文在真实 FRB 信号基础上, 生成部分模拟信号后一起制作成数据集。FRB 模拟信号是以 FAST^[10] 观测数据为背景, 叠加 FRB 仿真信号得到的。FRB 信号仿真方法参考论文 [11-12]。仿真参数包括采样时间、起止频率、色散值、通道数, 生成公式为:


1. 水电工程智能视觉监测湖北省重点实验室 湖北宜昌 433000

2. 三峡大学计算机与信息学院 湖北宜昌 433000

$$F_{sim}(x) = \frac{D \times D_m}{T} \times \left(\frac{1}{x^2} - \frac{1}{f_e^2} \right) \quad (1)$$

式中: $x \in (f_s, f_e)$, D 表示常数 4 148.8, D_m 表示色散值, f_s 表示起始频率, f_e 表示终止频率, T 表示单位采样时间。

如图 1 所示, 通过仿真得到正样本为 5711 张, 负样本为 1816 张, 共 7527 样本数据集。



(a) 正样本 (b) 负样本

图 1 切分成 4096×4096 图像示意图

2 研究方法

由于自然的射电信号可能存在不同强弱、色散等表现特征, 本文提出使用图像金字塔构建多尺度信息, 通过多尺度分解, 可以获取图像在不同尺度下的特征信息, 从而更全面地感知信号。能够有效地提取图像的特征, 提高模型的表达能力。小波变换卷积模块可以捕捉到图像在不同尺度、不同频域、不同方向上的细节和纹理信息, 为模型提供了丰富的特征表示, 提高了模型的表达能力。Former 特征提取结构的模块能够自适应地学习全局语义信息, 提高了信号搜寻的精度和效率。不同的特征提取器可以有效学习不同分布的数据。利用采样自注意力机制可以很好地融合不同特征提取器的特征结构图。相比于传统的方法, 有效减小了模型参数, 增强了模型对不同数据分布, 局部、全局区域的关注度, 算法流程图如图 2 所示。




图 2 Parallel convolutional and transformer 模型的快速射电暴搜索算法

2.1 小波卷积模块

小波分解常用来解决滤波、信号增强等任务^[13], 具有在时域和频域表征信号局部信息的能力, 利用小波多级分解的特性, 可以对各向异性的信号特征进行初级特征提取。并且小波变换具有多分辨率分析的特性, 可以自适应地处理不同尺度的信号, 能够更好地捕捉信号在不同尺度上的特征, 有效过滤信号中的噪声, 提高信号信噪比。小波卷积结构如图 3 所示。




图 3 小波卷积结构

2.2 Former 模块

Former 模块^[14] 常被用于各种任务的语言特征提取, 为了更好地使模型理解信号帧中可能存在的语义信息, 提出使用重叠窗口 Former 特征提取结构, 通过重叠窗口, 可以让每个像素点做注意力计算的窗口块处于变化之中, 从而提升感受野。通过这种方法, 降低了计算复杂度, 同时解决了不重合的窗口之间缺乏信息交流的问题。交叉重叠 Former 结构如图 4 所示。




图4 交叉重叠Former结构

2.3 采样特征注意力模块

特征融合一般用于不同的特征层之间的混合，可以捕捉到更丰富的特征信息，从而提高模型对数据的拟合效果。提出的采样特征注意力模块，如图5所示，采样特征注意力模块使模型更好地关注当前任务中最有用的特征通道，提高了特征表征能力。特征融合结构可以很好地结合不同信息维度的特征结构，并加速模型收敛速度，降低了通道数量，可以有效地压缩模型检测所需要的时间和内存占用。特征采样融合模块如图5所示。




图5 特征采样融合模块

2.4 训练超参数

在训练部分，本文分别在仿真数据集上进行训练和测试，并且设置训练集、验证集，其分别来自80%、20%的仿真数据，最后在新的测试集下进行模型测试。对比前人所提出的算法如Conv17、Inception Resnetv2和Dense121模型上进行的实验，模型均使用自适应二阶矩梯度下降算法，设置模型学习率统一为0.000 01，权值衰减率设置为0.001，损失函数为交叉熵损失函数，为了防止模型因训练次数过多导致过拟合的情况，设置了早停法，并均设置窗口超参数为5。

3 实验结果

为了有效测量各类模型的性能，在独立的带有仿真FRB信号的真实背景测试数据集上评估了每个模型的性能，计算了每个模型在测试集上的准确率、查重率、查全率、召回率，直观地展示了PCT模型的优点，有效地证明所提出的算法检测工作是有意义的。训练与测试准确率如表1所示。

表1 训练集训练结果

模型名称	训练准确率/%	测试准确率/%
Conv17	97.29	98.76
Inception-Resnetv2	98.45	85.39
Dense121	94.39	89.33
PCT(Ours)	99.09	98.57

分别对训练的模型Conv17、Dense121、Inception-Resnetv2、PCT模型进行测试，在进行整体测试时，使用另外的背景重新制作了7527张4096×4096大小的测试集。

F_1 得分常用来评价模型预测的效果好坏，其表达如下所示：

$$Acc = \frac{T_P + T_N}{T_P + F_P + T_N + F_N} \quad (2)$$

$$P_r = \frac{T_P}{T_P + F_P} \quad (3)$$

$$R_e = \frac{T_P}{T_P + F_N} \quad (4)$$

$$F_1 = \frac{2 \times P_r \times R_e}{P_r + R_e} \quad (5)$$

式中： T_P 、 F_P 、 T_N 、 F_N 分别表示正样本被判定为正样本的数量，负样本被判定为负样本的数量，正样本被判定为负样本的数量，负样本被判定为正样本的数量， A_{cc} 为准确率， P_r 表示查准率， R_e 表示查全率。

最终在测试集上的准确率与 F_1 得分如表2所示。

表 2 本文提出的算法与其他算法对比得分

模型名称	准确率	查准率	查全率	F_1 得分	Times/min
Conv17	0.949	0.933	0.991	0.944	0.383 3
Inception-Resnetv2-	0.961	0.957	0.974	0.959	0.966 7
Dense121	0.900	0.847	0.980	0.874	1.183 3
PCT(Ours)	0.959	0.976	0.973	0.973	1.166 7

迁移学习主要是让在仿真数据集上已获得最优参数的模型在相近的真实数据集上进行学习，因此对少量的真实信号进行了标注，数据信号来自 FAST 所搜索出来的 FRB 信号数据。标注出 4096×4096 大小的数据共 2661 张，其中正样本共 74 张，负样本共 2587 张。在已标注的训练集中选取部分片段作为训练集，将训练好的 PCT 模型最优参数在该数据集上仅训练了 4 个轮次。作为对比本文也对 Conv17、Inception-Resnetv2^[15]、Dense121^[16] 的最优参数进行了迁移训练，同样训练了相同的轮次。

本文在标注的真实数据上选取了少部分典型的正负样本片段进行训练，训练参数继承自最优的模拟数据模型，并在标注的真实信号文件中进行测试，结果如表 3 所示。

表 3 迁移学习后真实数据测试结果

模型名称	准确率	查准率	查全率	F_1 得分
Conv17	0.982	0.644	0.644	0.644
Inception-Resnetv2	0.983	0.895	0.932	0.905
Dense121	0.984	0.956	0.893	0.908
PCT(Ours)	0.996	0.977	0.981	0.986

由实验结果可见，本文所提出的方法在各项指标上均为最优，从查全率和 F_1 值上来说，迁移学习后的模型在真实数据上是正向且有效的。

参考文献:

[1] FARAH W, FLYNN C, BAILES M, et al. Five new real-time detections of Fast Radio Bursts with UTMOST[J]. MNRAS, 2019, 488(3): 2989-3002.

[2] FARAH W, FLYNN C, BAILES M, et al. FRB microstructure revealed by the real-time detection of FRB170827[J]. MNRAS, 2018, 478: 1209-1217.

[3] THOMPSON D R, WAGSTAFF K L, BRISKEN W F, et al. Detection of fast radio transients with multiple stations: a case study using the very long baseline array[J]. Astrophysical journal, 2011, 735(2): 395-402.

[4] FOSTER G, KARASTERGIOU A, GOLPAYEGANI G, et al. Alfaburst: a commensal search for fast radio bursts with arecibo[J]. MNRAS, 2018, 474(3): 3847-3856.

[5] MICHILLI D, HESSELS J, LYON R J, et al. Single-pulse

classifier for the lofar tied-array all-sky survey[J]. Mnas, 2018, 480(3): 3457-3467.

[6] CONNOR L, LEEUWEN J V. Applying deep learning to fast radio burst classification[J]. Astronomical journal, 2018, 156(6):1-13.

[7] DEVANSH A, KSHITIJ A, SARAH B S, et al. Fetch: a deep-learning based classifier for fast transient classification[J]. Mnas, 2020, 497(2):1661-1674.

[8] ZHANG Y G, GAJJAR V, DFOSTER G, et al. Fast radio burst 121102 pulse detection and periodicity: a machine learning approach[J]. Astrophysical journal, 2018, 866(2):1-18.

[9] LIU Y L, LI J, LIU Z Y, et al. A search technique based on deep learning for fast radio bursts and initial results for FRB 20201124A with the NSRT[EB/OL]. (2022-09-28)[2024-01-02]. <https://iopscience.iop.org/article/10.1088/1674-4527/ac833a>.

[10] FAST 巡天示范应用 [EB/OL]. [2024-01-15].<https://fast.cstcloud.cn/datavolume/detail>.

[11] LI D, WANG P, ZHU W W, et al. A bimodal burst energy distribution of a repeating fast radio burst source[J]. Nature, 2021, 598(7880): 267-271.

[12] NIU C H, LI D, LUO R, et al. CRAFTS for fast radio bursts: extending the dispersion-fluence relation with new FRBs detected by FAST[J].The astrophysical journal letters, 2021, 909(1): 1-7.

[13] JEEVAN P, VISWANATHAN K, ANANDU A A, et al. WaveMix: A Resource-efficient Neural Network for Image Analysis[EB/OL].(2022-05-28)[2024-01-05].<https://arxiv.org/abs/2205.14375>.

[14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL].(2017-06-12)[2024-01-09].<https://arxiv.org/abs/1706.03762>.

[15] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway: IEEE, 2017: 4700-4708.

[16] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-resnet and the impact of residual connections on learning[C]//Proceedings of the AAAI conference on artificial intelligence.Palo Alto:Association for the Advancement of Artificial Intelligence, 2017:4278-4284.

【作者简介】

李俊霖（1997—），男，四川遂宁人，硕士研究生，研究方向：计算机视觉等。

（收稿日期：2024-03-07）