

doi: 10.3969/j.issn.1000-8349.2022.04.05

基于小波变换与卷积神经网络的自动搜索 X 射线天文暴事件的方法

马嘉卉^{1,2}, 马森^{1,2}, 邹自明^{1,3}, 李云龙^{1,3}

(1. 中国科学院 国家空间科学中心, 北京 100190; 2. 中国科学院大学, 北京 100049; 3. 国家空间科学数据中心, 北京 101407)

摘要: 提出了一种混合小波变换和卷积神经网络模型的时序数据自动寻峰方法, 可用于光变曲线峰的快速识别, 从海量数据中快速发现潜在暂现源。在硬 X 射线调制望远镜真实观测数据上的实验结果显示, 相比于光谱寻峰、化学谱寻峰等问题中常用的小波变换寻峰方法, 该方法得出的寻峰查准率提升了 42%, F1 值提升了 41.3%, 误报率降低了 42.1%, 而寻峰时间仅增加了 0.18 s, 基本满足实时检测的要求。所得结果证明了该方法在光变曲线寻峰问题上的有效性。

关键词: 寻峰方法; 光变曲线; 卷积神经网络; 小波分析

中图分类号: P141.5 **文献标识码:** A

1 引言

光变曲线是天文研究中用于判断观测对象类别、分析对象物理属性与过程的重要可观测量, 其变化记录可用于了解恒星或恒星系统内的工作过程, 并确定恒星事件的特定类别。光变曲线分析也是第一时间寻找暂现源的方式, 能够快速识别和定位光变曲线峰的位置, 从而提供准确预警, 对触发机遇科学事件协同响应有重要意义。

巡天观测项目产生的海量光变曲线数据中, 仅有小部分时段的数据存在与瞬变现象相关的峰值, 如在 HXMT 卫星 2017—2019 年间观测到的光变曲线数据中, 与暂现源产生的峰相关数据段仅占 0.001%。当前对光变曲线的分析与峰的识别多基于人工筛选, 尚未进行自动识别, 效率较低, 难以满足科学研究的需要。而使用简单的比较法、阈值分析等方法虽然寻峰速度快, 但容易将曲线中的噪声判别为峰, 稳定性较低。因此, 需要开发高效准确的自动寻峰方法, 以解决海量光变曲线数据难以分析的问题。

收稿日期: 2021-12-24; 修回日期: 2022-05-06

资助项目: 中国科学院“十四五”网络安全和信息化专项 (WX145XQ07-06)

通讯作者: 邹自明, mzou@nssc.ac.cn

目前以光变曲线数据为对象的研究多为周期性分析、分类及异常检测等。如 Bi 等人^[1]通过使用 Grubbs 准则和改进的 ARIMA 模型,检测短时间尺度内的 GWAC 光变曲线异常,并用于微引力透镜事件的预测和预警,该方法在 mini-GWAC 数据及人工插入异常的数据集中都能够有效预测异常事件,并根据特定情况使用额外的默认阈值来过滤或减少误报情况的发生。Ishida 等人^[2]使用自适应学习技术从天文光变曲线数据集中检测具有异常特性的超新星,此外,该方法可以按需捕捉专家定义的不同异常,具有足够的灵活性。Minor 等人^[3]开发了一种基于匹配滤波的算法,通过与特定模板相比较来检测光变曲线中由微透镜事件引发的异常,检测算法具有较高的精度,并且支持 GPU 加速。在光变曲线寻峰方面, Li 和 Fenimore^[4]提出了一种在已知伽马暴发生的光变曲线片段中寻峰并分析其峰值通量与峰位间隔分布的方法,该方法能够发现一次伽马暴发生时间内产生的所有峰。

在大量光变曲线中实施自动寻峰,一般思路是采用信号处理或光谱分析中较成熟的寻峰方法。常见的寻峰算法有导数寻峰法、多项式拟合法、连续小波变换法和高斯曲线拟合法等^[5]。其中,导数法和多项式拟合法易于操作,但精度较低;连续小波变换法因不需要预处理过程,且对噪声有良好的抑制作用,应用范围相对较广,但连续小波变换的参数相对固定,而光变曲线的尺度变化较大,对每一个不同的光变曲线都需要通过经验和实验调整小波参数以达到较好的寻峰效果。

近年来随着深度学习的快速发展,很多深度学习模型被应用于各个领域的研究中,且能够根据新加入的数据不断调整模型,对数据有很好的适应性。在深度学习各类算法中,一维卷积神经网络算法在许多针对信号数据的分类和识别的问题中都有出色的表现,因此本文拟在传统小波变换寻峰的基础上,将一维卷积神经网络引入光变曲线寻峰研究中,实现对峰的高效筛选。与单纯使用小波寻峰的方法相比,本文方法具有更高的检测准确率及更低的误报率,同时能够通过调整模型参数适应不同长度时标的事件。

2 时序寻峰方法

本文所提出的寻峰方法由三部分组成,首先对光变曲线数据进行预处理,包括离群点处理、通过离散小波变换进行降噪及形态学变换等;然后使用连续小波变换方法对光变曲线峰进行预选,即通过小波变换从预处理后光变曲线上初步检测出候选峰;再将包含这些候选峰的原始曲线和对应预处理后的曲线叠加后输入卷积网络构成的判别模型,滤除其中的假峰,得到更准确的结果。寻峰流程如图 1 所示。

2.1 数据预处理

采集到的光变曲线数据是随机且非平稳的,除了暂现源等目标造成的峰外,由于背景、仪器本底等噪声影响,数据中存在大量“假峰”,影响寻峰算法的准确率。通过对光变曲线进行降噪以及去除低频成分等操作,尽可能减少“假峰”对算法的影响。

2.1.1 离群点处理

部分光变曲线中存在一些远高于周围点的孤立异常点,可能是噪声叠加引起的峰,也可

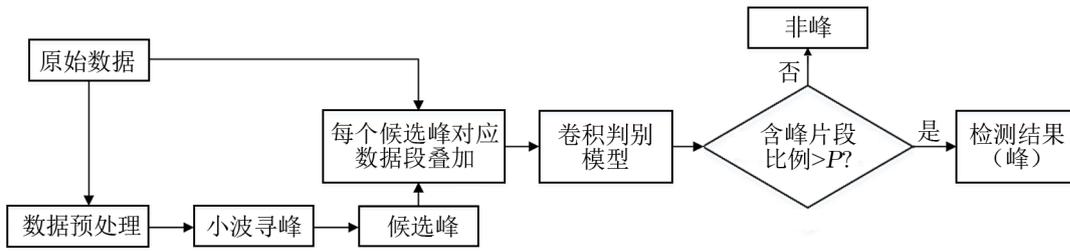
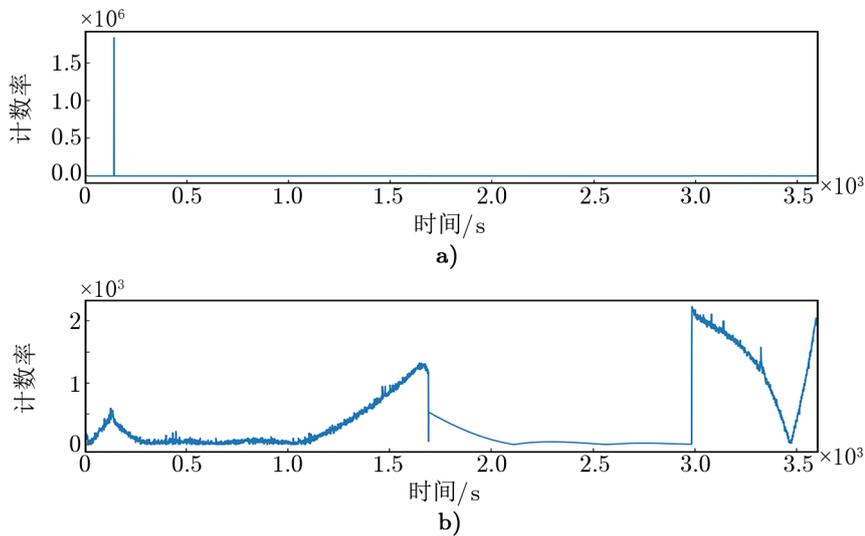


图 1 光变曲线寻峰流程图

能是暴发源快速光变产生的峰。由于设备的时间分辨率较低, 峰被压缩成一个孤立异常点, 这些异常点在样本中具体表现为, 该点的值超过邻域点平均值 3 个数量级以上, 视觉上的直观表现如图 2 a) 所示。本文对这种孤立点不进行峰的判断, 在应用中将这此点视为离群点, 用其前后各 10 个点的均值代替。处理前后的光变曲线如图 2 所示, 该样本中离群点对应的是一个噪声峰, 按上述方法处理后, 该处光变曲线表现为仅有一个较缓和的起伏。



注: 观测日期为 2017-12-15。伽马暴对应的峰值位于曲线中第 3 327 s。a) 原始光变曲线; b) 将 a) 中的离群点去除后的结果。

图 2 光变曲线样本

2.1.2 曲线降噪

除离群点的影响外, 光变曲线中还存在较多噪声产生的峰, 为减少噪声对寻峰的影响, 本文使用小波阈值降噪方法对曲线进行降噪。

小波阈值降噪^[6]是对原始光变曲线进行离散小波变换后, 得到一系列小波系数 $w_{j,k}$, 其中包括真实信号对应的小波系数和噪声对应的小波系数。当小波系数值大于设定的阈值时, 视为有用信号分解得到的系数, 予以保留; 否则视为噪声对应的系数, 将其去除^[7]。使用保留的小波系数进行小波逆变换重构可得到去噪后的曲线。阈值和阈值函数的选择会直接影

响去噪效果。常见的阈值函数有软阈值、硬阈值^[8]。软阈值法获得的重构信号更光滑，但与原始信号之间存在一定的偏差^[10]；硬阈值法获得的重构信号保留更多的尖峰特征，但会产生跳跃点，相对更加振荡^[11]。软硬阈值折衷的方法一定程度上克服了软阈值和硬阈值法的固有缺点。为提高去噪阈值的自适应性和准确性，本文采用软硬阈值折衷法^[12]，表示为：

$$\hat{\omega}_{j,k} = \begin{cases} \operatorname{sgn}(\omega_{j,k}) \cdot (|\omega_{j,k}| - g \cdot \lambda), & |\omega_{j,k}| \geq \lambda \\ 0, & |\omega_{j,k}| < \lambda \end{cases}, \quad (1)$$

其中， $\omega_{j,k}$ 为去除离群点之后的光变曲线的小波系数， $\hat{\omega}_{j,k}$ 是软硬阈值法降噪后小波系数， j 为分解尺度， k 为信号点的位置， g 为控制阈值函数去噪效果的调节参数，取值范围为 $[0, 1]$ ，本文使用 $g = 0.5$ 。 λ 是应用最为广泛的 VisuShrink 阈值，其表达式为：

$$\lambda = \sigma \sqrt{2 \ln N}, \quad (2)$$

其中， σ 为噪声的标准差， N 为一个样本中的采样点数量。 σ 根据小波系数进行计算^[9]：

$$\sigma = \frac{\operatorname{median}(|\omega|)}{0.6475}. \quad (3)$$

本文选用 sym8 小波作为基函数，离散小波降噪后的曲线形态如图 3 b) 所示。

2.1.3 形态学变换处理

形态学变换是数字图像处理中一种广泛应用的技术，用来解决噪声滤除、特征提取、边缘检测、图像分割等问题。其中形态学顶帽变换具有高通滤波的特性，适用于处理具有暗背景、亮物体特征的图像，光变曲线中的峰可视为一维图像中的“亮物体”，因此对小波降噪后的光变曲线进行形态学顶帽变换，可进一步去除曲线中的低频背景，提升峰的显著性。其具体步骤如下。

(1) 首先对原始光变曲线 $x(t)$ 进行腐蚀运算：

$$E[x](t) = \min_{b \in \mathcal{B}} x(t+b), \quad (4)$$

其中， \mathcal{B} 为形态元素，本文采用的形态元素结构为 $\mathcal{B} = \{-2, 1, 0, 1, 2\}$ 。

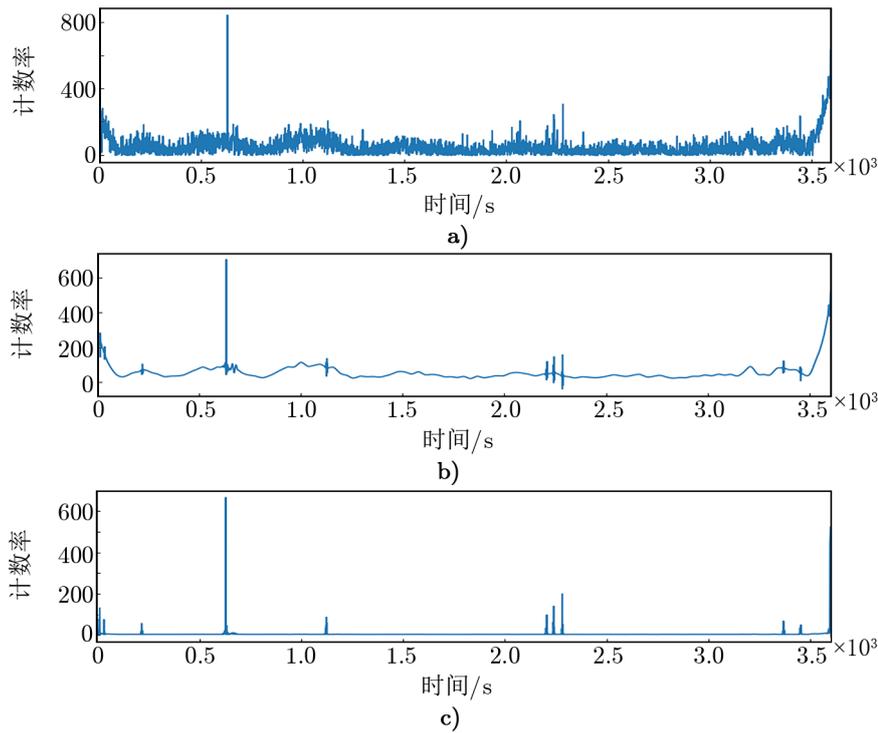
(2) 对 $E[x](t)$ 进行膨胀运算：

$$D[E[x]](t) = \max_{b \in \mathcal{B}} E[x](t+b). \quad (5)$$

(3) 最后用原始曲线 $x(t)$ 减去腐蚀膨胀后的曲线 $D[E[x]](t)$ ，得到最终变换结果：

$$\hat{x}(t) = x(t) - D[E[x]](t). \quad (6)$$

形态学变换后的光变曲线如图 3 c) 所示。



注: 观测日期为 2017-11-03。伽马暴对应的峰值位于曲线中第 632 s。a) 原始光变曲线; b) 将 a) 中曲线进行小波降噪; c) 将 b) 中曲线进行形态学变换。

图 3 光变曲线样本

2.1.4 数据标准化

在卷积网络模型训练及检测阶段, 为提升模型精度及训练速度, 对数据集进行简单的标准化。映射转换的过程如式 (7) 所示:

$$x^* = \frac{x - \mu}{\sigma}, \quad (7)$$

其中, x^* 是标准化后的光变曲线, μ 是原光变曲线的均值, σ 是原光变曲线的标准差。标准化操作不会改变光变曲线的形态特征。标准化后的数据仅用于神经网络模型部分, 小波寻峰所使用数据不需要进行标准化。

2.2 基于小波变换的候选峰提取

本文使用连续小波变换将光变曲线信号分解为一系列小波函数的叠加, 表现出信号的局部特性。经过变换后, 小波系数表示小波函数与信号的相似度, 系数越大说明相似度越大, 则可以将寻峰问题转变为对小波系数最大值的检索。附录 A 给出连续小波变换方法。

小波变换方法可以直接在预处理后的曲线上寻峰, 但易检测出较多的“假峰”, 因此, 通过阈值法对得出的峰进行筛选。首先对光变曲线的数值按从小到大的顺序排序, 然后取第

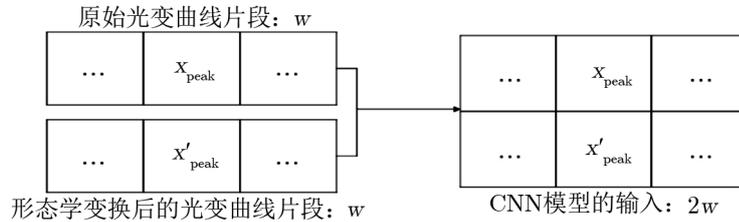
M 个值作为阈值, 仅保留小波变换寻峰结果中大于该阈值的峰。阈值的计算方法为:

$$M = \lfloor L \times q \rfloor, \quad (8)$$

其中, L 为光变曲线的长度, q 为分位数。

2.3 基于卷积网络的候选峰判别

通过小波变换寻峰可以得到若干个候选峰的最大值点, 针对每个候选峰位点, 在原始光变曲线和预处理后的光变曲线上分别用宽度为 w , 步长为 $s = 1$ 的滑窗截取多个包含候选峰 x_{peak} 的片段, 将对应位置的片段进行叠加后得到多个维度为 $2w$ 的数据段, 作为卷积判别模型的输入 (如图 4 所示), 逐一进行是否包含峰的判别, 如果这些片段中包含峰的概率超过预设值 p , 则保留对应的峰。对每个候选峰进行上述判别后, 留下的峰为最终结果。



注: x_{peak} 为连续小波变换寻峰得到的候选峰。

图 4 数据叠加过程

3 卷积判别模型的构建

使用小波变换寻峰得到一系列候选峰后, 使用卷积网络模型对包含候选峰的片段进行筛选。这里采用监督学习的方法构建判别模型, 主要途径是, 对数据进行切分和标注, 并使用切分后的数据片段训练一个二分类模型。

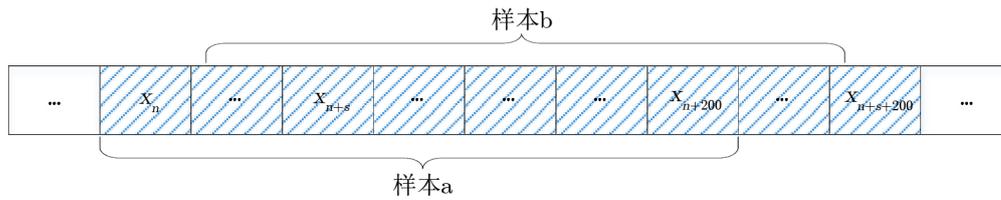
3.1 数据切分及标注

模型的输入为 2×200 大小的光变曲线片段, 因此使用宽度为 $w = 200$, 步长为 s 的滑窗分别对原始光变曲线和预处理后的光变曲线进行切分, 再将对应位置的数据段进行叠加, 得到可用的训练数据。切分后的数据段中, 包含峰的片段为正样本, 设置标签为 1; 不包含峰的片段为负样本, 设置标签为 0。数据切分方式如图 5 所示。

3.2 卷积网络结构及训练设置

光变曲线寻峰问题可以视为对光变曲线片段是否包含峰的判别问题, 即二分类问题, 可以使用卷积网络模型进行分类。本文使用的卷积网络模型结构在附录 B 中。

在模型训练阶段, 选择分类问题中常用的 softmax 作为损失函数, 并采用自适应矩估计 (adaptive moment estimation, Adam)^[13] 作为参数优化器, 调节模型的权重, 使损失函数取极小。模型训练过程中, 优化器的初始学习率为 $lr = 10^{-4}$, batch_size 设置为 600, 每次分



注: 空白部分表示不含峰数据段, 标签为 0; 阴影部分表示含峰数据段, 标签为 1。

图 5 数据切分图示

类实验均进行 2000 次迭代优化。网络中的 dropout 层可以提高网络模型的泛化性^[14]。确定网络结构和初始参数后, 用 3.1 节所述方法对数据切分后得到的数据集来训练和评估模型。

4 实验与结果

4.1 实验数据

4.1.1 数据选择

硬 X 射线调制望远镜 (Hard X-ray Modulation Telescope, HXMT) 卫星是我国第一个空间天文卫星^[15], 具有三种观测模式: 指向、扫描和低增益模式。其高能望远镜^[16]的 CsI 探测器也可以作为伽马暴监测仪, 在正常模式及低增益模式下均能探测到瞬变现象的发生。本文主要针对正常模式下的数据进行分析。这里选取 2017—2019 年 HXMT 高能载荷的 1B 级数据产品解算的光变曲线作为寻峰模型的实验数据, 并根据全球伽马暴坐标网 (GCN) 选出 HXMT 确认发生伽马暴起始时刻对应前后 30 min 左右, 总长度为 1 h 的数据作为一个样本。按照该方法, 从 2017—2019 年的观测数据中提取出 106 个光变曲线样本, 其中包括 107 个认证的伽马暴。

4.1.2 训练集、验证集、测试集划分

从全部 106 个光变曲线数据中随机选取 30 个作为测试集, 其中包含 30 个峰, 用于网络模型的测试; 剩余 76 个光变曲线作为模型的训练样本, 其中包含 77 个峰。按 3.1 节所述方法, 根据 GCN 中伽马暴的发生时间及时长记录, 对光变曲线采用不同的滑动步长进行切分。对于包含伽马暴的片段设置滑动步长 $s = 1$, 并设置曲线片段的标签为 1; 对于不包含伽马暴的片段分别设置滑动步长 $s = 1, s = 10, s = 20$ 切分数据, 并设置曲线片段的标签为 0。再在保证正负样本比例的情况下, 按照 7:3 随机划分为训练集和验证集, 分别用于网络模型的训练和验证, 各数据集分布如表 1 所示。

表 1 中, 滑窗步长取 $s = 1$ 和 $s = 10$ 时正负样本数量相差较大, 训练出的卷积网络模型应用于新数据时, 更容易将其分类为训练样本数量多的类别, 准确性和鲁棒性较差, 但能够更全面地覆盖光变曲线的各个部分; 滑窗步长取 $s = 20$ 时, 正负样本数相对均衡, 能够训练出准确性更好的模型, 但是对样本的认识不够全面, 4.4 节中会对不同滑窗步长切分的数据训练得到的模型性能进行比较。

表 1 取不同滑窗步长时的数据集分布

滑动步长	训练样本数	正样本数	负样本数	训练集	验证集
1	241 580	12 711	228 869	169 106	72 474
10	36 014	12 711	23 303	25 209	10 805
20	24 397	12 711	11 686	17 077	7 320

4.2 实验平台及评价指标

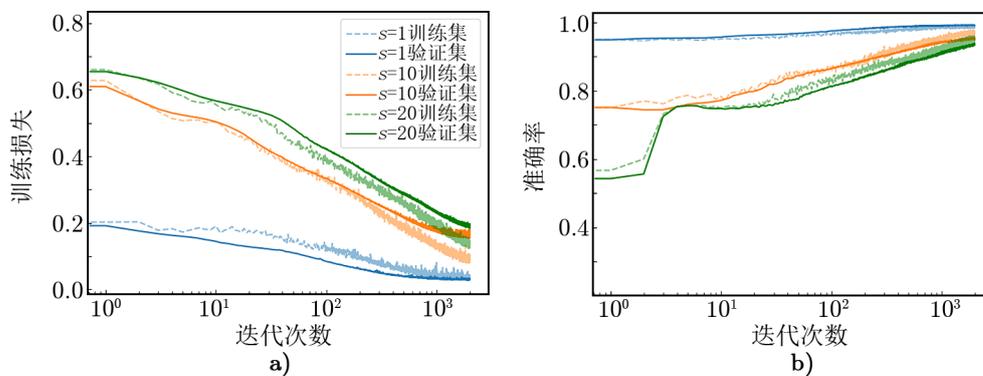
卷积神经网络基于 TensorFlow 1.14 搭建, 使用 1 块 Tesla K80 显卡完成训练。

对于光变曲线片段是否包含峰, 如果卷积神经网络模型输出的预测值 y' 与实际值 y 相同, 则认为该模型能够正确识别出光变曲线片段的峰。通过比较卷积神经网络模型输出的预测值 y' 和实际值 y 可以评估本文所提出的方法在 HXMT 光变曲线寻峰问题上的有效性。使用分类问题中常用的 5 种评估指标对本文卷积神经网络模型的性能及本文提出方法的寻峰性能进行评价, 包括准确率、精确率、召回率、误报率和 F1 值, 其中准确率仅在评估 CNN 模型的性能时使用。各评价指标的计算方法在附录 C 中。

4.3 模型训练结果

本文使用 4.1.2 节中划分得到的训练集和验证集进行卷积神经网络模型的训练。在光变曲线数据输入网络之前, 先按 2.1 节所述方法对其进行数据预处理操作, 并将原始数据和预处理后的数据同时输入网络, 作为光变曲线的两个特征。

图 6 展示了使用不同滑窗步长的数据集模型的训练过程, $s = 1$ 时模型收敛速度最快且准确率最高, 随着 s 增大, 模型收敛速度变慢, 训练趋于平稳时的损失增大, 准确率减小。三种滑窗步长的切分方案下, 经过 2000 轮训练后, 模型的损失函数值和准确率都趋于平稳。



注: a) 训练损失曲线; b) 训练准确率曲线。

图 6 卷积神经网络的训练过程

图 7 展示了将模型用于测试集分类时的各项指标值。随着滑窗步长的增加, 模型在测试集上的准确率逐渐下降, 召回率和 F1 值逐渐上升, 是由于增大滑窗步长会减少对负样本的数量, 训练数据集中正负样本数更为均衡, 模型不容易“偏向”数量较多的样本类别。由以

上实验结果可以证明, 卷积神经网络用于光变曲线片段的分类具有一定的可行性。

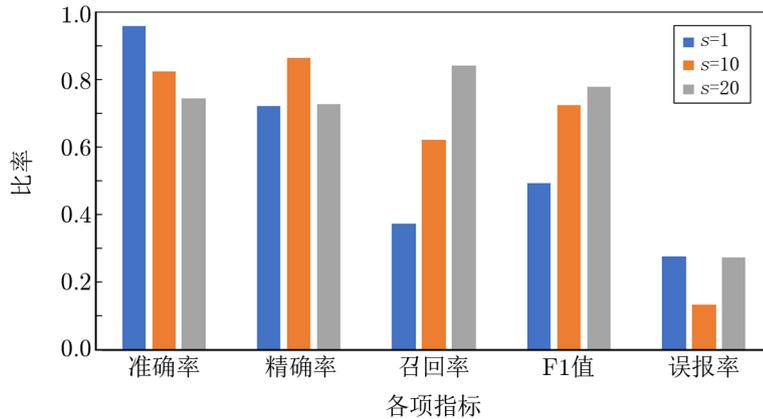


图 7 卷积网络模型在测试集上的分类表现

4.4 实验结果分析

4.3 节得到的模型分别在测试集上进行测试。卷积神经网络判别光变曲线片段分类的依据为其是否包含峰的概率: 如果概率较大, 说明峰在该片段中较为显著, 易于分辨; 如果概率较小, 说明该片段中的峰并不明显或不存在峰。因此可以将神经网络的输出概率值作为峰的显著性度量, 在实验中同时对测试集数据的模型输出概率进行统计。以滑动步长为 20 的模型为例, 取测试集中所有含峰片段, 并随机选取相同数量的无峰片段, 含峰概率统计结果如图 8 所示。

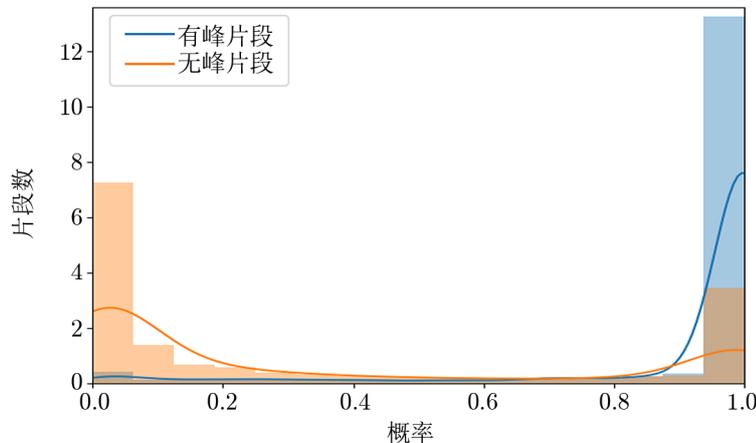


图 8 测试集光变曲线片段 (已归一化) 含峰概率分布

由图 8 可以看出, 对大部分含峰片段, 模型判断其含峰概率在 0.9 ~ 1 之间, 而大部分无峰片段的含峰概率在 0 ~ 0.1 之间, 有少量标注为无峰的片段, 模型给出了大于 0.9 的含峰概率, 可能是由于这些片段中包含在预处理阶段无法去除的噪声峰。

针对训练集取不同步长所得到的模型，设置每组测试中含峰片段的概率阈值 p 的取值为 $[0.5, 0.99]$ ，不同滑动步长和判别概率阈值 p 对寻峰结果的影响如图 9 所示。

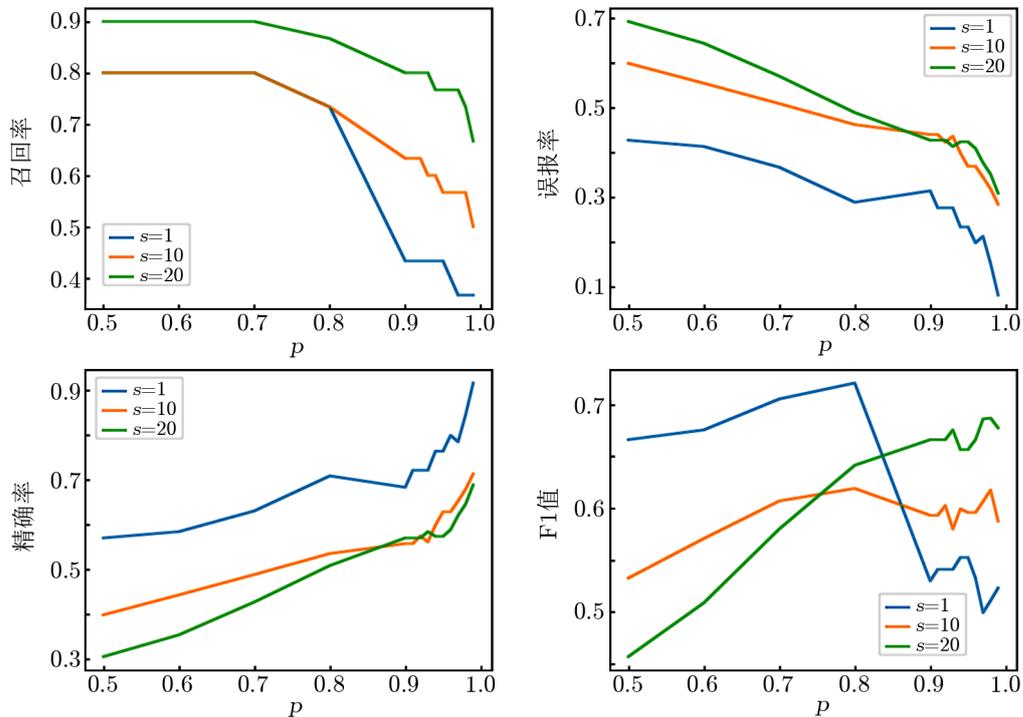


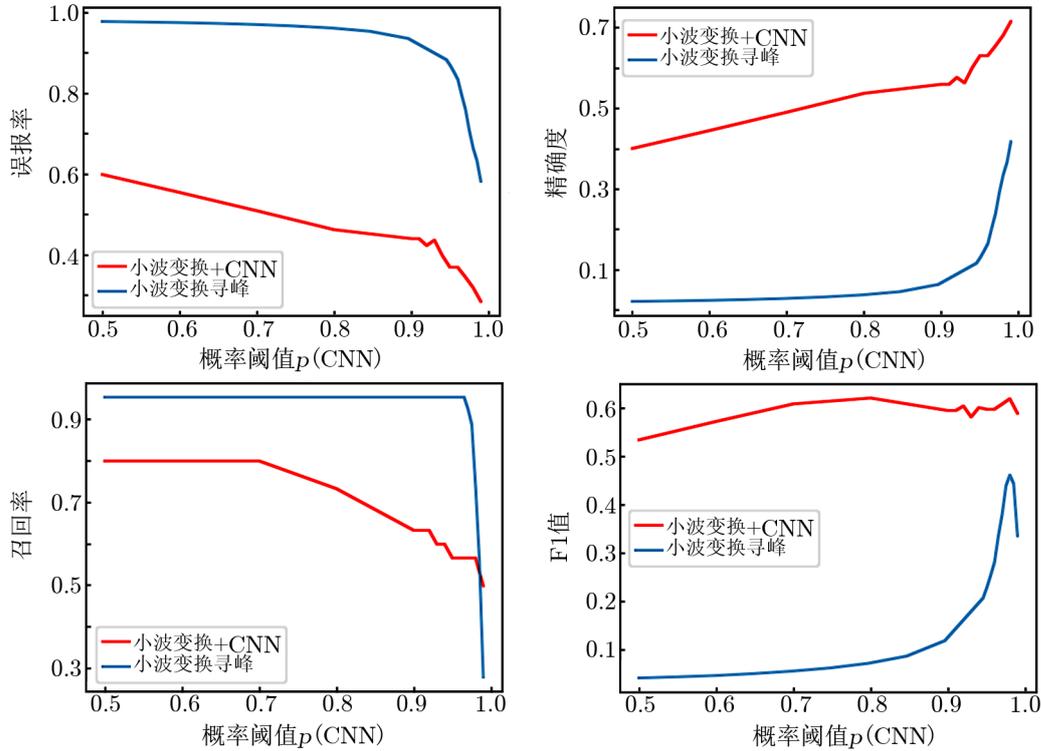
图 9 测试集上取不同滑窗步长与概率阈值 p 情况下寻峰结果的比较

随着概率阈值 p 取值的增大，数据集取不同滑窗步长切分时的模型在测试集上表现趋势较为相似，均为 F1 值先上升后下降，准确率缓慢上升，召回率和误报率逐渐下降，精确度逐渐上升，并且训练模型时数据切分的滑窗步长对模型有较大影响，可在实际应用中灵活调整。其中数据集滑窗步长为 10 的模型在各评价指标上均不如其他两种模型；滑窗步长为 1 的模型在 $p = 0.8$ 时 F1 值最高，为 0.721，同时精确率和召回率分别为 0.709 和 0.733，误报率为 0.290，检测结果比其他两种模型更为精确，但容易漏掉一些真实峰；滑窗步长为 20 的模型在 $p = 0.93$ 时 F1 值最高，为 0.676，精确率和召回率分别为 0.571 和 0.8，误报率为 0.425，检测结果能够更多地覆盖真实峰，但误报率较高，会增大后续研究工作的难度。滑窗步长为 1 的模型与滑窗步长为 20 的模型的测试结果在召回率和精确率上各有优势，都能有效解决光变曲线的自动寻峰问题。

5 讨论

本文使用传统寻峰方法中的连续小波变换寻峰方法与我们提出的方法进行实验比较。4.4 节中滑窗步长为 $s = 10$ 的数据集训练得到的模型表现最差，选取该模型的实验结果与小

波变换寻峰在测试集上的实验结果进行比较, 如图 10 所示。



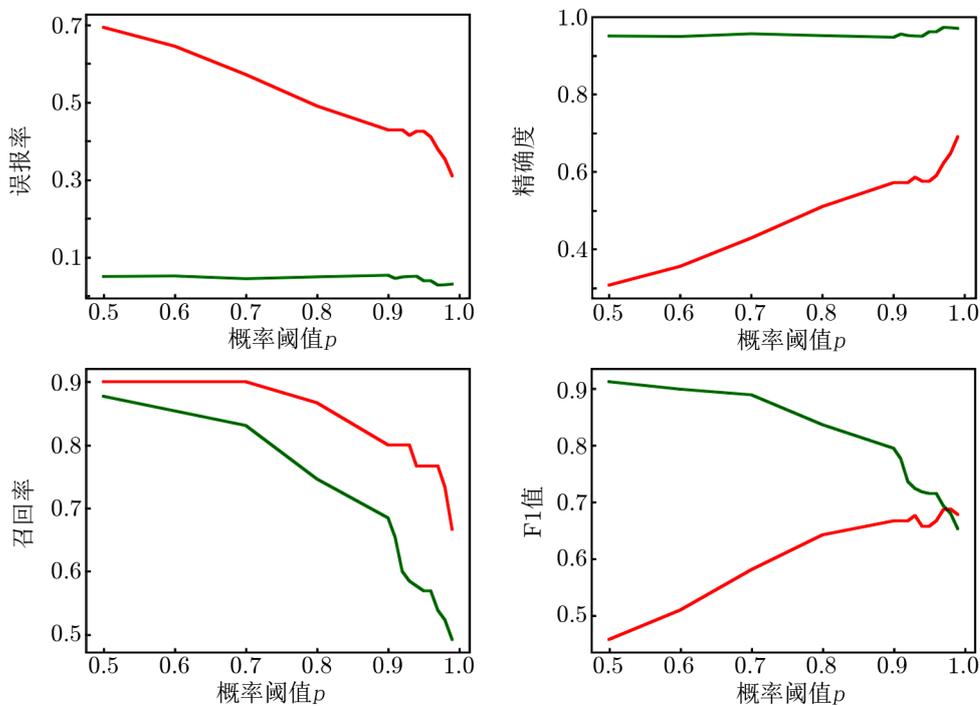
注: 蓝线表示仅使用小波变换方法寻峰, 红线表示使用本文提出的基于小波变换与 CNN 组合的方法寻峰。

图 10 滑窗步长为 $s = 10$ 的卷积网络模型与小波寻峰在测试集上的表现比较

小波寻峰方法仅在召回率上优于小波变换与 CNN 组合的方法, 在其他三个评价指标上表现明显较差。将组合方法中概率阈值取 $p = 0.8$ 与小波变换方法中分位数取 $q = 0.99$ 进行对比从而发现, 组合方法的 F1 值提高了 41.3%, 准确率提高了 42%, 误报率降低了 42.1%。当小波变换方法的分位数取较大值时, 召回率明显下降, 直至低于组合方法的召回率, 而误报率始终高于组合方法。这说明卷积网络模型的加入, 有效地去除了小波变换寻峰结果中的大量假峰, 但同时也错误地去除了部分真实峰, 这种情况可能是由于实验数据有限, 模型没有完全学习到峰的特征, 泛化性不足。在未来的观测中, 可以通过不断加入新的数据动态调整模型, 使其达到更高的检测准确率, 这一点也比小波寻峰方法更灵活。在寻峰效率方面, 处理长度为 1 h 的样本时, 小波变换寻峰所需时间平均为 0.005 s, 本文方法所需的平均时间为 0.188 s, 增加了 0.183 s, 虽然寻峰时间相对较长, 但寻峰的准确率有较大的提升, 在处理大批量的历史数据时, 可能需要较长时间, 准确率的提高能够为后续工作 (如瞬变事件的人工确认等) 节省工作量。而用于峰的实时检测时, 无需处理批量数据, 基本能够达到实时检测的要求。因此, 相较于传统小波变换寻峰方法, 将小波变换与卷积判别模型相结合能更好地解决光变曲线的寻峰问题。

在实际使用中,可能存在更长或更短时标的事件,但模型寻峰的依据是曲线变化的趋势是否符合峰形。因此针对不同时标的事件,可以通过改变数据切分长度,使其能够包含一个完整的事件长度,再采用相同的方法进行模型训练和寻峰,或通过对数据进行上采样或下采样,改变曲线中峰的宽度,再应用于已有的寻峰模型,就可以实现不同事件尺度的寻峰。如果对不同时标数据进行重采样后寻峰效果不佳,可能是由于重采样操作后的峰形态与训练集中的峰相差较大,模型无法判断,则需要根据当前时标对模型参数进行微调。而针对小于 10 ms 的极端时标事件,重采样可能无法还原峰形,则需要获取粒度更小的数据,进行预处理等操作后可应用于寻峰模型。

此外,本文使用该方法在低增益模式的数据集上进行实验。数据集采用低增益模式的观测数据,将其中峰对应时间段的数据进行适当的拉伸和收缩变换,并插入到无峰的数据段中,作为模拟数据。数据集中有 139 个光变曲线片段,包含 139 个峰,直接使用前文中取 $s = 20$ 的模型在该数据集上进行寻峰实验,并与第 4 章实验中对应模型的实验进行比较。结果如图 11 所示。



注: 红线表示在正常模式的数据集上进行实验的结果, 绿线表示在低增益模式的数据集上进行实验的结果。

图 11 在正常模式与低增益模式数据集上的实验方法比较

该方法在低增益模式的数据集上寻峰精确度更高, 误报率较低, 可能是低增益模式下的数据中噪声峰影响相对较小; 实验召回率相对较低, 且由于概率阈值 p 取值增大的同时召回率下降较快, F1 值呈下降趋势但整体表现优于正常模式数据的结果, 可能是由于该模型

是使用正常模式的数据集训练得到, 在低增益模式与正常模式数据存在差异较大的情况下, 模型对真峰的判断不够准确。总之本文提出的方法在正常模式或低增益模式的观测数据中都能高效准确地检测出光变曲线中的峰。

6 结论

本文提出一种基于小波变换和卷积神经网络模型的光变自动寻峰方法, 并在硬 X 射线调制望远镜的高能望远镜观测数据上进行了实验验证, 实现了对 HXMT 光变曲线中峰的有效检测。根据实验分析结果, 本文在以下几个方面取得了一定成果: 使用形态学顶帽变换对 HXMT 光变曲线进行处理, 去除曲线中的低频部分, 保留高频部分, 有效减少了光变曲线中的噪声及“假峰”的影响; 提出了基于小波变换寻峰与卷积神经网络的光变曲线自动寻峰方法, 相比于传统小波变换寻峰方法, 得到准确率更高的检测结果, 各评价指标表现最优; 该方法能够在未来的观测中不断根据新加入的数据重复训练调整模型和提升精度, 比其他方法有更好的可塑性。

致谢

本文使用了国家空间科学中心公共技术服务中心空间科学数据融合计算平台的计算服务。本文使用了由中国国家航天局和中国科学院资助的项目 Insight-HXMT 任务的数据。感谢国家科技资源共享服务平台-国家空间科学数据中心 (<https://www.nssdc.ac.cn>) 提供数据分析环境与应用平台支持。

附录 A 连续小波变换

连续小波变换公式为:

$$C_{a,b} = C_{\psi}[f](a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi\left(\frac{t-b}{a}\right) f(t) dt, \quad (\text{A1})$$

其中, $a, b \in \mathbb{R}$, $f(t)$ 为待分析信号, $\psi(t)$ 为小波母函数, a 为尺度参数, b 为位移参数, C 为小波系数。本文 $\psi(t)$ 使用墨西哥帽小波:

$$\psi(t) = (1 - t^2) \cdot e^{-\frac{t^2}{2}}. \quad (\text{A2})$$

附录 B 卷积神经网络结构

卷积神经网络 (convolutional neural network, CNN) 是由 Lecun 等人^[17]提出的一种经典的深度学习方法, 在图像分类和模式识别领域得到广泛应用。本文使用的 CNN 模型包括 4 个卷积层、4 个池化层和 1 个全连接层。其中输入层大小为 200×2 , 卷积层的结点个数分别

为 16, 32, 64, 128, 卷积核大小为 1×2 , 卷积步长为 2, 全连接层的结点个数为 1536。结构如图 B1 所示。网络的每个卷积层采用修正线性单元 (rectified linear unit, reLU) 激活函数。

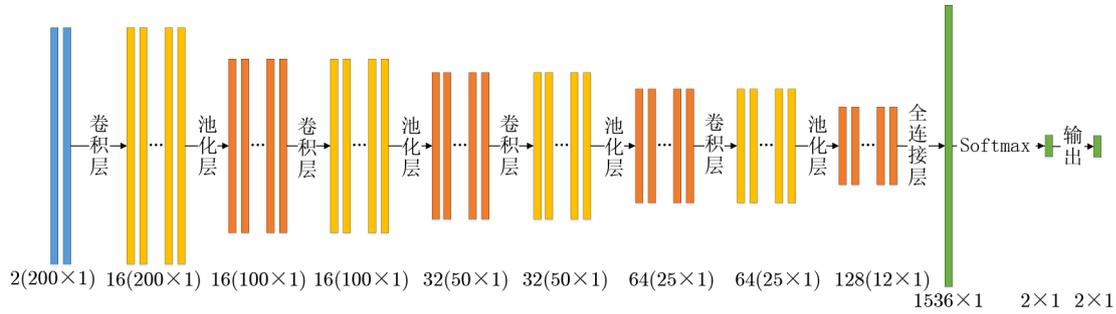


图 B1 卷积神经网络结构

附录 C 模型评价指标

式 (C1)–(C5) 分别为准确率、精确率、召回率、误报率和 F1 值的计算方法:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad , \quad (C1)$$

$$Precision = \frac{TP}{TP + FP} \quad , \quad (C2)$$

$$Recall = \frac{TP}{TP + FN} \quad , \quad (C3)$$

$$F_1 = \frac{2TP}{2TP + FP + FN} \quad , \quad (C4)$$

$$False\ alarm = \frac{FP}{TP + FP} \quad , \quad (C5)$$

其中, TP (true positive) 为真阳性, 表示正确检测到光变曲线峰的个数; FP (false positive) 为假阳性, 表示将无峰曲线错误检测为峰的个数; FN (false negative) 为假阴性, 表示未检测到的光变曲线峰的个数。精确率和召回率呈负相关。

参考文献:

- [1] Bi J, Feng T, Yuan H. COMPUT IND, 2018, 97: 76
- [2] Ishida E E O, Kornilov M V, Malanchev K L, et al. Astron Astrophys, 2021: 650
- [3] Minor A C, Du Z, Sun Y, et al. HPEC. IEEE, 2020: 1
- [4] Li H, Fenimore E E. Astrophys J, 1996, 469(2): L115
- [5] 陈志军, 白剑, 吴祖堂, 等. 光子学报, 2015, 44(11): 83

- [6] Donoho D L. IEEE, 1995, 41(3): 613
- [7] 吴艳, 张蓉竹. 光子学报, 2019, 48(10): 156
- [8] Bayer F M, Kozakevicius A J, Cintra R J. Signal Processing, 2019, 162: 10
- [9] 陈家益, 战荫伟, 曹会英, 等. 电子测量与仪器学报, 2018, 32(10): 169
- [10] Zhao J, Lee J S, Xu H, et al. IEEE, 2017, 64 (1): 705
- [11] 樊高瞻, 周俊, 朱昆莉. 振动与冲击, 2020, 39(12): 221
- [12] 赵瑞珍, 宋国乡, 王红. 西北工业大学学报(自然科学版), 2001,19(4): 625
- [13] Kingma D P, Ba J. arXiv:1412.6980
- [14] Srivastava N, Hinton G, Krizhevsky A, et al. J M L R, 2014, 15(1): 1929
- [15] Zhang S N, Li T P, Lu F J, et al. SCI C P M, 2020, 63(4): 1
- [16] Liu C Z, Zhang Y F, Li X F, et al. SCI CHINA PHYS MECH, 2020, 63(4): 1
- [17] Lecun Y, Bottou L, Bengio Y, et al. IEEE, 1998, 86(11): 2278

An Automatic Search Method for X-ray Astronomical Outburst Events Based on Wavelet Transform and Convolutional Neural Network

MA Jia-hui^{1,2}, MA Sen^{1,2}, ZOU Zi-ming^{1,3}, LI Yun-long^{1,3}

(1. National Space Science Center, Chinese Academy of Sciences, Beijing 100190, China; 2. University of Chinese Academy of Sciences, Beijing 100049, China; 3. National Space science data Center, Beijing 101470, China)

Abstract: We present an automatic peak-finding method based on the wavelet transform and convolutional neural network to identify the peaks of light curves, and it helps to rapidly discover potential transient sources from massive data. Here we use the real observation data of the HXMT as our experiment data. The experiments make comparisons with the wavelet transform peak-finding method, which is commonly used for peak-finding problems of spectral or chemical spectral. The results show that the method improves the peak-finding precision rate and the F1 value by 42% and 41.3%, and reduces the false alarm rate by 42.1%, while the peak-finding time only increases by 0.18 s. Therefore it can solve the problem of light curve peak-finding by combining the wavelet transform and convolutional neural network.

Key words: peak finding method; light curve; convolutional neural network; wavelet analysis