



机器学习在地面引力波瞬态噪声数据处理中的应用

谢群英^{1*}, 康瑞春¹, 李佳桐¹, 郭意扬^{2,3}, 赵少东^{2,3}, 张学昊^{2,3}, 邹晓博^{2,3}

1. 兰州大学信息科学与工程学院, 兰州 730000;

2. 兰州理论物理中心, 量子理论及应用基础教育部重点实验室, 兰州 730000;

3. 兰州大学物理科学与技术学院, 兰州 730000

*联系人, E-mail: xieqy@lzu.edu.cn

收稿日期: 2024-09-01; 接受日期: 2024-10-09; 网络出版日期: 2024-11-08

国家重点研发计划(编号: 2021YFC2203003)资助项目

摘要 2015年LIGO首次探测到双黑洞并合事件GW150914, 开辟了引力波天文学新纪元. 地面激光干涉引力波探测器灵敏度极高, 易受到来自仪器和环境的各种瞬态噪声(glitch)数据影响. 尽管在引力波信号处理和分析中已经利用各种手段, 开发出各种工具来加强瞬态噪声数据的表征和识别, 以便最终移除, 但LIGO源源不断输出的数据量足以使任何科研小组不堪重负. 因此, 开发强健的方法来表征和识别glitch, 对于提高引力波信号探测的可靠性和科学价值具有至关重要的意义. 本文首先回顾一般的地面噪声数据处理方法的优缺点, 然后概述各种机器学习方法在地面噪声数据处理中的应用. 最后, 本文介绍机器学习在glitch数据处理实例——Gravity Spy项目上的最新应用, 目的是介绍机器学习技术在glitch的识别、建模和去除方面的最新进展, 以便为科研工作者在地面引力波瞬态噪声数据处理方面提供一些参考.

关键词 引力波, 数据处理, 噪声, 人工智能

PACS: 04.30.-w, 07.05.Kf, 85.40.Qx, 07.05.Mh

1 引言

2015年9月14日, LIGO (Laser Interferometer Gravitational-Wave Observatory, 美国激光干涉引力波天文台)和Virgo (Virgo Interferometer Gravitational Wave Observatory, 意大利室女座激光干涉引力波天文台)科学合作组织^[1]首次观测到来自双黑洞并合产生的引力波信号, 这一发现不仅证实了爱因斯坦关于引

力波的预言, 也标志着引力波天文学新时代的到来.

引力波探测器主要分为两大类, 即地面激光干涉引力波探测器和空间激光干涉引力波探测器. 目前, 正在运行的激光干涉引力波探测器都属于地面型设施, 主要包括LIGO, Virgo和KAGRA (Kamioka Gravitational-Wave Detector, 神冈引力波探测器)^[2]. 这些探测器共同组成了地面激光干涉引力波探测网络, 致力于捕捉来自宇宙深处的引力波信号. 此外, 全球正

引用格式: 谢群英, 康瑞春, 李佳桐, 等. 机器学习在地面引力波瞬态噪声数据处理中的应用. 中国科学: 物理学 力学 天文学, 2025, 55: 230408
Xie Q Y, Kang R C, Li J T, et al. Application of machine learning in ground-based gravitational wave transient noise data processing (in Chinese). Sci Sin-Phys Mech Astron, 2025, 55: 230408, doi: [10.1360/SSPMA-2024-0369](https://doi.org/10.1360/SSPMA-2024-0369)

在积极部署空间引力波探测计划. 2024年7月份, 欧洲空间局(ESA)正式立项了激光干涉仪空间天线(Laser Interferometer Space Antenna, LISA)项目^[3]. 与此同时, 中国的太极计划^[4]和天琴计划^[5,6]也在积极部署中.

迄今为止, 地面激光干涉引力波探测器已经完成了三轮观测运行, 发现了90例引力波事件^[7], 在第四轮观测运行的前半段时间(O4a, 2023年5月至2024年1月), 地面引力波探测网络观测到了81个重要的新引力波候选波源. 引力波的直接探测技术开辟了一个全新的宇宙观测领域, 这项技术不仅以前所未有的精确度证实了广义相对论的诸多预言, 还为我们探索宇宙中的极端事件, 如致密双星并合等现象, 提供了独特的研究途径. 此外, 它也为探索宇宙的未知领域提供了强有力的工具^[8]. 随着未来灵敏度更高的地面引力波探测器、多探测器联合探测^[9]以及空间引力波探测器的投入使用, 预计将会探测到更多的引力波事件, 这要求我们进一步提升引力波数据处理能力, 以便从海量数据中筛选出真正有意义的引力波信号.

引力波信号的处理和分析在引力波天文学研究中占据着举足轻重的地位. 然而, 地面激光干涉探测器的灵敏度极高, 为了探测引力波, LIGO需要在4 km长的探测臂中对质子直径的千分之一长度变化做出响应, 这导致激光干涉仪器探测到的时间序列数据中除了引力波信号外, 还包括各种来自仪器和环境的噪声信号. 噪声信号有多种, 其中有一类是瞬态的、非高斯的, 一般称为“non-stationary”“transient”或“glitch”(“小毛刺”“小故障”信号), 其危害最大, 为了方便, 本文把它们统一叫做“glitch”.

Glitch信号, 通常由仪器、环境或人为因素引起, 例如探测器的材料缺陷、外部环境的微小扰动(典型的有地面的小震动)、探测器的电子噪声、传感器的热噪声、激光的量子噪声、镜面涂层和光学悬挂的热噪声等, 这些glitch信号可能会掩盖甚至模拟真实的引力波信号, 使引力波探测过程中产生假阳性结果. 它们在频域上可能与引力波信号重叠, 降低引力波事件的信噪比(Signal-to-Noise Ratio, SNR), 为参数估计带来更大的不确定性. 其较高的发生率会显著降低候选引力波信号的可用数据量, 尤其是那些无模板的引力波信号. 地面引力波搜索的灵敏度极大地受限於LIGO中频繁出现的glitch信号^[10,11], 这些信号的高频率出现严重影响了我们对引力波事件的探测和分析能力.

目前, 空间引力波探测计划包括LISA、太极和天琴, 其噪声水平需要通过实际的在轨测量数据进一步校准. 值得注意的是, 在技术验证卫星如LISA探路者的任务中, 已经观察到了两种与地面实验相似的典型glitch: 快速上升-缓慢指数下降(FRED)型和正弦-高斯(Sine-Gaussian)型^[12]. 这一发现表明, 噪声尤其是glitch, 对空间引力波探测的科学数据分析同样构成了显著挑战. 针对这些挑战的潜在应对策略和深入讨论, 可参见参考文献^[13].

为了降低glitch信号对地面引力波数据质量的影响, 我们需要深入分析形态各异的glitch信号, 明确有多少种不同形态的glitch, 总结其性质, 反向追溯其产生原因, 并最终去除它们. 这一过程将有助于提高引力波数据的可靠性. 尽管在地面引力波数据的处理和分析领域已经采用了多种手段, 并开发了各种工具来增强噪声数据的识别和去除能力, 但LIGO源源不断产生的数据量足以使任何科学小组不堪重负. 因此, 开发强健的方法来表征和识别噪声尤其是glitch, 对于提高引力波数据的可靠性和科学价值具有至关重要的意义. 随着近年来机器学习, 特别是深度学习技术的快速发展, 它们在引力波数据处理, 尤其是噪声的表征、识别、分类和去除方面显示出巨大的应用潜力^[14-26].

随着技术的持续进步和模型的不断优化, 预计未来机器学习将在引力波数据处理中发挥更加重要的作用. 然而, 当前的挑战也不容忽视, 空间引力波数据处理面临的挑战见综述文献^[13], 而地面引力波数据处理面临的挑战包括缺乏大规模高质量标签数据、模型的可解释性问题以及算法的实时性要求等. 总的来说, 机器学习等先进技术的应用为地面引力波数据处理, 特别是噪声数据处理, 提供了高效的解决方案. 通过持续研究和跨学科合作, 有望克服这些挑战, 进一步推动引力波天文学的发展^[26,27].

本文安排如下: 第2节概述一般的地面噪声数据的影响和处理方法, 第3节讨论机器学习在地面引力波噪声数据处理中的应用, 第4节给出一个具体的glitch处理应用实例——Gravity Spy, 第5节是总结.

2 一般的地面噪声数据的影响和处理方法

2.1 噪声数据对引力波数据处理的影响

地面引力波探测器的输出数据是探测器应变的时

间序列 $h(t)$, 通常表现为微小的时间-频率变化, 其振幅极低, 且持续时间短暂. 理想情况下, 探测器的灵敏度由其设计的固有物理特性决定. 然而, 在实际应用中, 探测器的灵敏度还受到不同来源的噪声数据的影响.

通常情况下, 这些噪声源是非平稳的, 即它们的统计特性会在短期或长期内发生变化. 在某些情况下, 噪声源在其起源处可能相对稳定, 但它们以非线性的方式耦合到探测器应变中. 这些非平稳和非线性的瞬时噪声(glitch), 以及以谱线形式出现的特定频率的连续噪声, 是影响引力波探测器搜索性能的两个主要因素^[10].

据统计, 在为期51.5 d的第一次观测运行(O1)期间, 信噪比大于6的glitch大约有 10^6 个, 数据中glitch的出现频率约为每小时10次^[28], 其中“Blip”类的glitch出现频率最高, 为每小时2次. 随着探测器灵敏度的逐渐提高, glitch的出现频率也在增加, 在第三次观测运行(O3)期间, glitch信号的出现频率增加到每分钟1次^[7]. 在第三次观测运行前半段(O3a)期间, LIGO Livingston中信噪比大于6.5的噪声出现频率为每分钟1.1次, 而在第三次观测运行后半段(O3b)期间, 该频率达到每分钟1.17次^[29]. 这些glitch信号的存在严重降低了探测器的灵敏度, 因此降低glitch的影响对于提高引力波搜索灵敏度至关重要.

一个典型的glitch影响引力波搜索灵敏度的案例是GW170817事件^[8]. 该引力波信号同时出现在LIGO Hanford (H1)和LIGO Livingston (L1)中, 事件信噪比为32.4, 这么强的信号很容易被当时正在运行的L1和H1同时检测到. 然而, 由于L1中出现的强glitch信号与引力波信号重叠在一起, 掩盖了真实的引力波信号, 导致L1探测器未能及时发出警报. 因此, 当时仅向天文界发布了一个不寻常的单探测器引力波检测警报. 从最初的H1警报到L1排除glitch (L1对时间序列数据先进行30 Hz–2 kHz之间的带通操作, 接着将原始探测器数据乘以反向Tukey窗口(文献^[8]图2, 该操作可以将glitch周围的数据归零), 然后用小波函数重构该glitch信号进而去除它), 再到两个探测器联合分析得到GW170817事件的精确定位图花费了4.5 h的时间^[30].

图 1所示是GW170817事件发生时LIGO Livingston探测器输出数据的时频图, 黄色是glitch信号, 绿色是真实引力波信号. 由此可见, glitch信号的出现

严重影响了引力波数据的质量和速度. 此外, 据统计, 在第三次观测运行中, 约20%的引力波信号和glitch信号重叠在一起^[31]. 随着探测器灵敏度的提高以及更多的引力波信号和glitch信号被识别, 将来引力波信号和glitch信号的重叠概率必将增加, 如何处理此类情况也为我们提出了新挑战.

噪声数据对引力波事件探测的影响还体现在信号的误识别和数据不可靠上. 误识别可能导致大量的人力和计算资源的浪费, 而不可靠的数据则直接影响到科学研究的结果和结论. 因此, 噪声数据的存在对引力波事件的探测与分析构成了重大挑战, 探测器噪声的有效表征和识别、分类以及最终去除, 对引力波搜索都至关重要^[32].

2.2 常见的地面噪声数据处理方法

早在20世纪90年代, 随着LIGO和Virgo等探测器的初步建设, 科学家们就已经开始面对噪声的挑战了^[33]. 常见的噪声数据处理方法有阈值检测、利用辅助通道进行否决、特征工程方法、时频域分析法、滤波法、贝叶斯推断等, 接下来我们对这些方法进行简单概述.

阈值检测需要设置一个固定的信号幅度阈值, 当观测数据的幅度超过该阈值时即认为存在噪声. 这种方法实现简单、计算快捷, 适用于早期计算能力有限的情况, 并且具有良好的实时性. 然而, 阈值检测对不同类型的噪声和噪声背景不敏感, 尤其是当噪声的形




图 1 (网络版彩图) GW170817事件^[8]发生时LIGO Livingston探测器输出数据的时频图, 黄色是glitch信号, 绿色是真实引力波信号

Figure 1 (Color online) The time-frequency plot of the output data from the LIGO Livingston detector during the GW170817 event ^[8] shows the glitch signal in yellow and the real gravitational wave signal in green.

态复杂或与引力波信号有相似特征时^[11,34], 容易产生误报和漏报, 缺乏适应性, 难以处理复杂多变的噪声环境. 随着探测器灵敏度的提高和数据采集量的增加^[35], 简单的阈值方法已无法满足分析的需求.

文献^[11]通过监测多个辅助通道(这些辅助通道对引力波信号不敏感, 而是给探测器提供有关环境和其他自由度的重要信息), 对出现大量噪声的时段给出数据质量标记, 进而“否决”并删除探测器该时段的对应数据, 以进行引力波数据的搜索. 数据质量标记方法在最初的探测器科学运行中被证明在提高搜索灵敏度方面是非常有效的. 在第六次科学运行中使用数据质量标记后, 探测器对致密双星波源的敏感度提高了约30%, 探测范围增加了约5 Mpc. 然而, 过度使用数据质量标记会降低仪器的占空比, 使仪器的可用数据大大减少.

噪声分类通常依靠专家通过特征工程手工处理关键参数, 如归一化幅度、持续时间和频率范围, 并采用传统分类器(例如决策树、支持向量机、k近邻等)进行分类^[11,16]. 尽管这种方法利用专家知识提高了分类性能且计算资源需求较低, 但它依赖于主观经验, 可能无法识别所有的噪声类型, 并且在新数据或不同环境下鲁棒性较差, 处理大数据集时也面临挑战.

时频域分析法也被应用于噪声分类^[17]. 这些方法通过将时间序列数据经过傅里叶变换或小波变换, 以便在频域或时频域中检测和分类信号. 这种处理能够有效地区分不同的频率成分, 有助于识别特定频率范围内的噪声. 然而, 傅里叶变换和小波变换的计算复杂度较高, 需要精心选择参数(例如小波基函数), 因为不同的参数选择可能导致结果大相径庭. 另外, 维纳滤波和自适应噪声消除方法也被证明在降低引力波数据中的平稳高斯噪声方面是有效的^[36]. 当数据中存在特征明显的固定噪声源(如热噪声和粒子噪声)时, 这些技术能够迅速抑制特定频率范围内的噪声, 从而提高探测器的灵敏度^[37]. 然而, 选择不恰当的滤波器频率可能会造成有用信号成分的丢失或扭曲^[38].

匹配滤波技术是探测致密双星信号的首选方法^[39]. 它在识别与预测波形模板(引力波信号的理论模型通常称为波形模板)相匹配的信号方面表现突出, 例如在分析首次直接探测到的致密双星合并事件GW150914中就发挥了关键作用^[1]. 不过, 匹配滤波法在处理glitch信号时效果欠佳, 原因如下: 首先, 引力

波数据中glitch的出现频率相对较高(大约每分钟1次), 并且数据量庞大, 这使得匹配滤波需要进行频繁的计算, 消耗大量的计算资源和时间. 其次, 匹配滤波的效果依赖于与信号匹配良好的波形模板, 但glitch的形态多变, 很难用单一的理论模型来准确描述, 这大大降低了检测的准确率. 最后, 匹配滤波是基于线性高斯噪声假设的, 而实际的glitch信号常常是非高斯和非平稳的, 这使得该方法在处理glitch信号时能力有限.

统计方法如贝叶斯推断^[40,41]也被应用于引力波探测器中的噪声表征和监测^[42]. 这些技术在识别和追踪如仪器故障和环境干扰的噪声源方面取得了成效, 对诊断和减轻噪声影响起到了关键作用^[43]. 然而, 这些方法计算量较大, 在需要快速检测和表征噪声信号的场合——比如多信使天文学和低延迟警报系统中, 可能无法及时提供所需结果^[44,45]. 至于其他降噪技术, 如小波去噪和自适应滤波, 它们在处理低信噪比信号时可能难以有效去除噪声^[46]. 特别是在强噪声和弱信号并存的情况下, 这些方法可能无法在不引入伪影的前提下实现有效的噪声抑制^[47].

为了克服这些困难, 研究人员正在探索和发展更先进的噪声数据处理方法, 包括机器学习算法、自适应信号处理技术以及量子增强方法^[48,49]. 这些新兴技术的设计目标是优化和加强传统的噪声处理手段, 在复杂噪声环境和具有挑战性的信号场景中提供改进的降噪、信号检测和参数估计能力.

3 机器学习方法在地面噪声数据处理中的应用

LIGO和Virgo探测器收集了众多辅助通道数据流, 这些数据来自诸如光电探测器和地震仪等不同仪器和环境传感器. 这些传感器监测和控制仪器状态, 记录干涉仪中噪声源的数据, 为诊断和减轻非天文因素引起的噪声提供依据. 由于仪器和环境监测传感器的数量庞大, 完全依赖手动分析这些辅助通道数据通常是不现实的. 利用机器学习在处理大规模数据集方面的强大能力来分析这些数据, 已被证明是非常有效的.

LIGO和Virgo合作组织内部已经广泛研究了基于辅助通道数据的噪声处理方法^[11,17,46,47,50–52], 并在多个文献中报告了研究成果. 在这些方法中, 引力波通道数据通常用于确定训练样本的标签, 而识别噪声的过

程仅依赖于辅助通道的信息. 一旦模型经过训练, 它能够完全独立于引力波通道数据进行操作.

文献[46]报道了一个研究案例, 首次将LIGO探测器内的辅助通道数据与三种机器学习算法(随机森林、神经网络和支持向量机)相结合. 该分类器成功识别并去除了两个不同数据集(LIGO第四次科学运行四周和第六次科学运行一周)中存在的大部分glitch, 且三种算法对哪些事件是glitch的判断一致, 误差在10%以内. 此后, 多位研究人员探索了如何通过辅助通道中的特征来推断引力波数据中是否存在非高斯噪声. 例如, 文献[45]开发了一个名为iDQ (推断数据质量)的稳健辅助通道数据统计框架, 该框架利用辅助传感器来识别和表征引力波探测器中的非高斯噪声, 几乎能够即时识别非高斯噪声, 这对于及时追踪引力波事件至关重要. iDQ的有序否决列表[53]算法, 在GW170817事件首次报告后8 s内, 就自主识别出了在LIGO Livingston探测器[8]和多个辅助通道中与引力波信号同时出现的glitch信号. 这一快速的识别过程极大地加快了GW170817事件的通报速度. 此外, 文献[54]通过使用神经网络等机器学习方法处理时间序列数据, 根据历史地震数据开发了一个地震噪声水平的预测模型. 研究表明, 将基于机器学习的预测方法整合到引力波探测操作的框架中, 能显著提升其科学产出.

总的来说, 运用机器学习处理大规模数据集的能力来分析辅助通道数据, 进而消除噪声, 已被证实是非常有效的. 接下来, 本文将详细探讨如何应用机器学习方法进行噪声的分析、表征、识别、分类, 并最终消除或抑制.

3.1 用机器学习对噪声进行分析、表征与识别

引力波探测中的噪声对信号的识别和分析产生了严重影响, 因此准确识别这些噪声是数据处理的一个关键步骤. 探测器噪声表征的第一步是区分噪声和潜在的天体物理信号, 然后将它们分类为不同的类别. 这个任务可以通过从每个时间序列中提取噪声特征, 并将这些特征映射到目标噪声类型来解决. 然而, 由于噪声通常表现出复杂的时间和频率演变特性, 这使得用固定数量的特征来表征它们变得非常困难. 此外, 探测器灵敏度的提高可能会导致更多前所未有的噪声形态

出现.

进入21世纪, 随着计算机技术的飞速发展和机器学习理论的日趋成熟, 机器学习方法逐渐被引入噪声的处理中[1,27,46]. 机器学习方法, 如主成分分析和独立成分分析, 已被用于识别主要噪声源, 并将其与引力波信号分离[17,47], 这些技术可以学习噪声数据的底层结构, 并提供相关特征的紧凑表示. 支持向量机也被用于噪声识别, 它能够构造一个最优超平面, 将噪声数据和正常信号分离开来[55]. 这种方法适用于复杂数据, 并能有效处理少量标签数据, 结果具有一定的可解释性. 然而, 支持向量机对大规模数据集训练时间较长, 计算资源需求大, 且需要调节多个超参数, 对于多分类问题需要扩展[26].

随后, 深度学习方法如卷积神经网络和自动编码器等在识别和分类引力波数据中的glitch方面展现出了巨大优势[56,57]. 这些模型能够从标记或未标记的glitch大型数据集中学习复杂的模式和特征, 从而自动检测和分类不同类型的glitch[58]. 例如, George等人[14]开发了一个名为Gravity Spy的深度学习框架, 该框架可以根据glitch的形态和特征将其分类为不同的类别. 在高级LIGO和高级Virgo探测器的数据应用中, 此框架已证明了其对glith信号分类的高精度和低误报率[28]. 不过, 卷积神经网络的训练需要大量计算资源和时间, 且模型复杂度高, 难以解释其内部机制.

总体而言, 将机器学习技术应用于引力波噪声数据的识别和特征提取, 在提高引力波探测器的性能方面显示出了巨大潜力. 通过自动识别噪声、提取相关特征和预测噪声行为, 机器学习算法可以大幅提高引力波数据分析的灵敏度、稳健性和效率.

3.2 用机器学习方法对噪声进行分类

在引力波探测中, 噪声的分类不仅是关键的数据处理步骤, 也是提升探测器灵敏度的基础. 不同的噪声类型可能源自不同的噪声源, 反映出不同的物理过程或技术问题. 因此, 对这些噪声进行正确的分类有助于深入理解噪声的本质, 提供关键信息, 从而有助于改进仪器的设计, 提高其性能.

在噪声数据处理领域, 无监督的机器学习方法被广泛应用于glitch分类[14,29,59]. 这类方法能够在没有预先标记数据的情况下, 自主识别出glitch的内在结构

和模式. 相反, 有监督的机器学习方法, 如决策树和随机森林, 则在已标记的数据集上进行训练, 以预测新观测到的glitch所属的类别^[17,18]. 也有将无监督和有监督方法组合用于短时噪声分类的^[19]. 最近, 循环神经网络和长短期记忆网络等深度学习架构因其出色的时间序列数据处理能力而被应用于glitch分类任务中. 这些网络结构能捕捉数据中的时序特征, 显著提高glitch分类的准确性和鲁棒性^[60].

处理glitch的一种特别有效的方法是构建其时间频率图(简称时频图), 并将它们输入到卷积神经网络中进行训练. 文献^[61]表明, 将时间频率变换、Omega扫描^[62]和Q变换^[63]输入深度卷积神经网络是进行glitch分类的有效方法. 与其他机器学习方法相比, 卷积神经网络通常在区分具有相似形态的glitch方面具有更高的准确性.

监督学习方法的一个关键步骤是有足够的已标记的glitch样本可用, 公民科学家项目Gravity Spy^[28]就是为了解决这一问题而提出的. 基于Zooniverse平台, Gravity Spy利用公民科学家和机器学习的共同优势, 设计了一个计算系统来分析和表征引力波数据中的噪声信号. 公民科学家首先对如图2所示的glitch图像进行手动分类. 这个手动分类过程产生的glitch类别被用作有监督机器学习方法的标签^[64], 此后, 随着公民科学家识别出新的glitch类别, 机器学习算法会纳入这些新类别以重新进行训练.

值得注意的是, 融合迁移学习技术已成为一项关键技术, 它具有缩短训练时间和提高分类精确率的双重优势. 这一领域的一项显著成果是文献^[14]在Gravity Spy数据集上实现了98.8%的最高分类精确度. 此外, 深度学习方法在glitch分类中的有效性也得到了越来越多的认可. 目前已经采用了诸如Inception, ResNets和VGG等著名架构, 并通常与迁移学习技术结合使用以提高性能. 值得注意的是, 文献^[64]提出的体系结构配置已被证明能够在短短10个训练周期内实现超过98%的分类准确率, 这突出展示了在glitch分类背景下应用迁移学习的成效. 这些进步将进一步提升引力波探测结果的可信度.

3.3 用机器学习方法对噪声进行去除

LIGO和Virgo探测器的输出信号是噪声和引力波信号的总和, 这些信号一般是非线性的. 因此, 即使在

维纳滤波之后(如文献^[36,37]中所述, 维纳滤波只能滤除线性噪声), 输出信号中仍然存在大量污染的非线性耦合噪声数据. 机器学习技术可用于识别、建模并消除以非平稳或非线性方式耦合的技术噪声^[65]. 利用机器学习推断非线性函数的能力, 可以使用环境和控制数据流作为神经网络的输入, 以找到在探测器输出中产生非线性噪声的系统传递函数. 然后, 用训练有素的神经网络从输出数据中减去这些非线性耦合, 从而降低总噪声. 机器学习算法的处理速度也远快于维纳滤波, 能够实时应用于数据处理. 例如, Saleem等人^[66]使用深度学习开发了一种名为“DeepClean”的实时噪声回归和减噪方法. 该方法可以从引力波应变数据中估计并减去非线性和非平稳噪声, 显著提高了引力波信号的信噪比, 降低了误报率. 深度学习模型如长短期记忆网络, 已经在历史噪声数据上进行了训练, 用于预测未来的噪声行为, 并将其从探测器输出中去除^[67]. 这种方法有助于降低引力波检测的延迟, 并能够及时跟进潜在的引力波事件^[68]. 最近, Wang等人^[69]创新性地开发了一个名为“WaveFormer”的工作流, 该工作流巧妙地融合了迁移学习技术与卷积神经网络的强大功能, 专门针对LIGO观测数据设计, 能够在宽频谱范围内进行精细的分层特征提取, 旨在实现对引力波数据中噪声的有效抑制以及GW信号幅度和相位的精准恢复. 实践证明, 通过应用“WaveFormer”, LIGO的整体噪声水平及glitch得到了显著降低, 降幅超过一个数量级. 同时, 在信号恢复方面, 相位误差控制在约1%以内, 而幅度误差也仅为7%左右, 这些数据充分展示了“WaveFormer”在引力波噪声消除和GW信号精确恢复方面的卓越性能, 为未来引力波天文学领域的数据处理和信号分析提供了一种强有力的新方法.

一个特别有趣的情况是, 当噪声源由一个或多个可用的快速信号监控时, 其耦合在短时间尺度上可以描述为线性, 但耦合传递函数在更长的时间尺度上表现为非线性变化. 在NonSENS^[70]系统中, 为了使干涉仪保持在最灵敏的工作状态, 系统需要使用反馈控制回路将所有的谐振腔保持在工作点上. 然而, 反馈控制回路的传感或制动可能会在辅助传感器中引入噪声, 该噪声(频率大约在20–300 Hz之间)会非线性耦合到引力波应变信号中. 文献^[70]开发出了稳定、参数化的模型来描述污染探测器应变的噪声. 这个模型可以用

来执行时域减噪, 实践证明该方法可以去除探测器中的 60 Hz 主频处的非平稳电源线性耦合, 以及 60 Hz 附近 4 Hz 宽的由耦合调制产生的边带噪声 [70]. 这种非平稳噪声减除方案已成功应用于 LIGO 第三次观测运行的前半段(O3a), 其性能优于线性和平稳方案.

引力波数据中的其他噪声去除算法还有全变分方法 [71,72]、字典学习方法 [73]、使用 WaveNet 实现的深度学习 [74] 等.

总体而言, 机器学习提供了一种更为精细的去噪声手段, 如自编码器可用于学习数据的低维表示, 并去除噪声 [75]; 生成对抗网络则通过对抗训练, 一方面生成器尝试创建逼真的引力波信号, 另一方面判别器努力区分生成的噪声信号和引力波信号, 从而达到去除噪声的目的 [26]. Powell 等人 [17,18] 将机器学习算法应用于高级 LIGO 探测器的数据, 以识别和消除非天体物理噪声. 他们使用主成分分析来提取噪声数据的主要成分, 然后使用随机森林分类器来识别和消除瞬态噪声. 该方法显著减少了噪声, 并提高了探测器的灵敏度 [76]. 此外, 机器学习技术已被用于实时分析引力波数据并从中去除噪声 [45].

4 噪声数据处理应用案例——Gravity Spy

Gravity Spy [28] 是一个主要由 LIGO 科学合作组织和 Zooniverse 平台共同创建的开创性的公民科学家项目. Gravity Spy 的目标是通过公民科学家参与, 利用人类智慧和机器智能相结合的方式, 对 LIGO 数据中的 glitch 进行标记、分类和去除, 以帮助改进引力波数据分析自动化效率, 从而提高引力波探测器, 特别是 LIGO 的灵敏度和准确性.

自 2016 年启动以来, Gravity Spy 项目已经记录了超过 2 百万个 glitch, 并吸引了超过 270 万名志愿者参与, 贡献了超过 8 亿 2 千万次的分类. Gravity Spy 已被广泛应用于 glitch 形态的研究 [23,77,78], 在评估典型 glitch 样本对数据分析的影响方面, 该项目也发挥了关键作用 [79–82]. 同时, Gravity Spy 还将 glitch 与环境噪声或辅助通道测量值进行交叉引用, 以增强数据解读的准确性 [51,83,84], 并且作为 glitch 分类算法训练的一部分 [29,47,59,61,85]. 此外, 通过 Gravity Spy 识别出的新类别 glitch 不仅有助于发现新的噪声源, 还可为后续的探测器调试工作提供指导 [86].

接下来对 Gravity Spy 数据集的组成和样本类别、基于该数据集的机器学习应用示例及其对机器学习研究的贡献和局限性进行简单介绍.

4.1 Gravity Spy 数据集的组成和样本类别介绍

在 Gravity Spy 项目中, 数据集的收集过程涉及 LIGO 科学家和公民科学家的合作. 起初, LIGO 科学家们识别并标记一组在 LIGO 数据中观察到的常见噪声类型图像. 这些标记的示例图像作为公民科学家在 Zooniverse 平台上分类新噪声的训练数据. 公民科学家通过人为地帮助识别和分类噪声图像, 提供更加准确的机器学习训练数据集标签, 从而改善机器学习算法的性能. 随着时间的推移, 这种众人的努力显著扩展了数据集, 允许系统识别新的噪声类别, 并提升对现有的类别的识别速率和准确率.

Gravity Spy 的原始数据集中包含了 22 类 glitch 信号, 共约 8000 张时间-频率-能量图(简称时频图). 时频图给出了 glitch 信号的频率和振幅随时间的变化, 每类 glitch 的时频图都具有不同的形态. 文献 [64] 详细介绍了最初的由 Omicron 算法 [87] 生成的 glitch 数据集以及相应的机器学习方法. Omicron 算法是基于常数 Q 变换, 采用正弦高斯函数来检测数据中的过剩噪声, 并利用聚类来提取该过剩噪声的数据特征的方法. Q 变换 [88] 是标准短时傅里叶变换的变形, 信号 X 以复数正弦高斯函数为基底, 其形状和面积由所需的常数 Q 和高斯窗口 w 决定, 公式为

$$X(\tau, \phi, Q) = \int_{-\infty}^{\infty} x(t)w(t - \tau, \phi, Q)e^{-2i\pi\phi t} dt. \quad (1)$$

变换系数 X 测量时频区域(称为 tile)内的平均信号幅值和相位, 该时频区域以时间 τ 和频率 ϕ 为中心. 分析窗口持续时间 σt 与频率 ϕ 成反比, 并由常数 Q (也称为品质因子)参数化: $\sigma t = Q / \sqrt{8\pi\phi}$. 参数空间 (τ, ϕ, Q) 按照文献 [63] 中开发的策略进行平铺. 这种平铺技术提供了一种多分辨率时频分析方法, 计算得到的值正比于时间、常数 Q 的对数和频率的对数. 然后通过 Omega Scans [62] 算法, 使用不同的 Q 值在时间频率平铺上进行搜索, 识别出最大信噪比值对应的模板, 并进行可视化, 生成与该 Q 值对应的时频图图像. 该图像的颜色轴是归一化以后的能量(值大致为信噪比的平方), 定义为给定频区域的 Q 变换幅值的平方除以稳态白噪声

的均方幅值. 只有信噪比高于7.5且在LIGO敏感频率范围(10–2048 Hz)内的处于“观测模式”期间检测到的噪声才会被glitch触发器触发. 每个glitch都用4个不同时长(0.5, 1.0, 2.0和4.0 s)窗口显示(如图2所示), 以捕捉同一glitch的不同持续时长特征, 生成的图像给公民科学家和机器学习算法进行分类. Gravity Spy图像数据集中的样本类别包括多种glitch类型, 每种类型都有不同的特征, 具体类别及其特征见文献[64, 86].

典型的Gravity Spy的神经网络^[64]如图3所示, 它首先做四组卷积组操作. 每组卷积组依次包括卷积、ReLU激活、最大池化和Dropout四个操作步骤, 旨在从输入图像中分层提取特征. 卷积组操作的四个操作步骤具体过程为(初始图像大小为280×340像素):

第一步: 使用5×5大小的卷积核做 n 次(从第1个到第4个卷积组的卷积操作, 其次数 n 分别为16, 32, 64和64)卷积操作来提取图像的特征;

第二步: 每个卷积操作后面都接了一个ReLU激活操作, 目的是引入非线性以增强网络对复杂函数的拟合能力;

第三步: 最大池化操作, 采用2×2的窗口对特征图进行下采样, 以缩小特征图的大小、减少计算量、防止过拟, 同时保留关键信息;

第四步: 为了进一步防止过拟合, 每个卷积组的最后还需要做一个Dropout操作模拟神经元的失活, 即以一定的概率随机丢弃特征图的一些元素.

四组卷积组操作完成后是一个flatten层, 将之前的多维数据拉成一维向量. 接着是一个全连接层, 将一维向量映射成256个隐变量(神经元). 最后Softmax层将隐变量映射成每一个分类类别的概率值, 将每个样本分类到概率最大的类别以完成神经网络的分类过程.

在文献[64]中, 通过使用机器学习方法, 用GravitySpy神经网络对20个类别(去除了“No glitch”和“None of the Above”两类)的7718张glitch图像数据进行了分类, 其平均准确率达到了97.1%.

4.2 Gravity Spy项目中的机器学习方法应用概述

已有多个科研小组将多种机器学习方法应用于分析LIGO数据中由Gravity Spy项目得到的glitch数据集.




图2 (网络版彩图) Zooniverse¹⁾ 平台公布的第四轮观测运行的前半段时间(O4a)的“Blip”图像, 上图时长0.5 s, 下图时长2.0 s

Figure 2 (Color online) The “Blip” image of the first half of the fourth observation run (O4a) released by the Zooniverse platform has a duration of 0.5 s for the upper image and 2.0 s for the lower image.




图3 (网络版彩图) Gravity Spy神经网络结构图

Figure 3 (Color online) Neural network architecture of Gravity Spy.

1) <https://www.zooniverse.org/projects/zooniverse/gravity-spy/classify/workflow/1610>.

这些方法涵盖了从传统的机器学习方法到先进的深度学习架构方法、自注意力机制和自编码技术等多种机器学习方法. 在Gravity Spy项目中, 机器学习方法的应用取得了令人鼓舞的结果, 展示了这些方法在提升glitch分类和引力波探测领域的潜力^[20,28,64,86,89]. 下面对一些代表性的机器学习方法及其研究中的具体实验结果和性能进行概述.

首先文献^[28]对Gravity Spy这一创新项目进行了详细描述, 阐明了该项目的目的和任务. 随后, 文献^[64]介绍了Gravity Spy数据集中的22类glitch完整形态, 对Gravity Spy数据集类别用t-SNE进行可视化, 分析glitch的整体形态分布特点, 通过开发基于神经网络、支持向量机和集成学习的分类器来确定数据集的基线分类精确度, 该数据对于未来测试算法性能起到参考作用. 该研究团队开发了一个集成框架, 证明组合各种分类器可以提高分类模型的准确性, 用标准训练集训练的集成分类器在标准测试集上达到了98.21%的分类准确率.

识别新的噪声类别对于提升LIGO探测器的性能具有重要意义. 文献^[86]展示了Gravity Spy如何通过两种互补的方法独立识别出高级LIGO探测器第三次观测运行数据中的两种新的glitch类别: Fast Scattering(也叫crown)和Low-frequency Blips. Fast Scattering与探测器位置的地面运动相关, 在LIGO Livingston的所有glitch类别中占比为27%, Low-frequency Blips占比为8%, 这两类分别是LIGO Livingston中最常见和第四常见的glitch源. 移除“None of the Above”类别后(人们认为卷积神经网络用低置信度标记“None of the Above”比试图构建一类具有许多形态的glitch更有效), 将原有的21个类别加上新的两个类别后, 训练数据集包含了第三次观测运行的23个类别, 共9631个glitch样本, 由此得到的训练和验证准确率分别为99.9%和98.8%.

文献^[20]用Gravity Spy的卷积神经网络将LIGO Hanford O3期间的233981个glitch和LIGO Livingston的379805个glitch按照形态进行分类, 发现两个LIGO站点之间的glitch分布不同. 在O3期间, Livingston探测器中由Gravity Spy机器学习方法得到的置信度大于90%的最常见的glitch类别包括: Fast Scattering 占比27%, Scattered Light (在2020年1月引入反应链跟踪后出现概率大大降低)占比23%, Tomte占比19%.

在Hanford探测器中, Scattered Light, Low-frequency Bursts和Extremely Loud是最常见的glitch类别, 其占比分别为: 47%, 16%和9%. Extremely Loud glitches对探测器的干扰最大, 通常会导致探测器可以检测到的引力波源的距离大幅下降. 总之, Livingston探测器更多地受地面干扰(如与探测器附近人为和地面运动的微震动增加密切相关的Fast Scattering glitch, 其出现频率为每小时9.05次, 而在Hanford探测器中, 该频率为每小时0.22次), 这表明人们可能需要针对每个引力波探测器进行单独定制的数据质量研究工作.

集成方法是一种可以结合多种机器学习模型的优势以提高整体性能的机器学习方法. Bagging, Boosting和Stacking等技术可以应用于增加模型的鲁棒性和准确性. 在Gravity Spy项目中, 集成方法可以结合不同模型的优点, 在噪声分类中表现出更高的鲁棒性和准确性. 文献^[90]分析了14种机器学习模型, 9个深度学习模型, 以及两种集成模型(ShallowWaves集成模型和DeepWaves集成模型). 实验通过交叉验证评估集成方法, 结果显示, 集成方法由于利用了每个单独模型的优势, 表现优于任何单个模型. DeepWaves集成模型获得了最佳的整体分类准确率, 其次是ShallowWaves集成模型.

不少迁移学习的结果表明, 在有限的有标签数据集情况下就能达到不错的噪声分类效果. 迁移学习方法一般先在大型图像数据集(如ImageNet)上进行预训练, 然后用适合Gravity Spy噪声类别的新层替换最终分类层, 最后在Gravity Spy数据集上微调模型^[14,91,92]. 这种方法利用了从通用图像分类任务中学到的知识, 并将其运用于特定的噪声分类任务. 流行的预训练模型包括VGG, ResNet和Inception. 文献^[14]用预训练的ResNet50模型在Gravity Spy数据集上微调后达到了95%的分类准确率. 最新的文献^[92]使用了更简单的ResNet18模型从头训练. 结果显示, 该模型最好的基线模型和迁移学习监督模型的准确率高于文献^[64]中报告的融合视图卷积神经网络. 此外, 基线模型的性能也优于文献^[64]的卷积神经网络硬融合集成, 分类速度更快, 略次于文献^[14]中微调的ResNet50的分类结果.

虽然现有的Gravity Spy神经网络在glitch分类方面效果不错, 但最近的文献^[89]指出, 其神经网络架构过于简单, 泛化能力有限, 无法处理多时间窗口图像数

据,且面临过拟合的问题.因此,该文献提出基于注意力机制的改进glitch分类器,该分类器全面比较了以多时间窗口为输入的3种融合(早期、中期和晚期融合)策略的结果,应用标签平滑技术来减轻训练标签对结果的影响,首次尝试在分类器中引入注意力机制,通过识别主要影响glitch分类决策的特定窗口时间来提高glitch决策过程的透明度和可解释性.在第四次观测运行数据集上的分类结果显示,中期融合策略分类器的效果最好,准确率为94.1%,精度为95%,F1得分为93.1%,AUC为0.965,优于现有的Gravity Spy神经网络分类器.这些进步不仅有望提高glitch分类的速度,而且有望提高正在进行的引力波检测工作的准确性.

总之,通过对不同机器学习方法在Gravity Spy数据集上的性能进行比较,结果表明,深度学习模型通常优于传统机器学习方法.最新的机器学习技术,如集成方法、迁移学习和注意力机制,通过结合多个模型的优势,利用预训练知识和擅长处理多时间窗口图像数据等,显著提高了glitch的分类效果.

4.3 Gravity Spy数据集对机器学习研究的贡献和局限性

Gravity Spy数据集在时间序列分析和glitch分类检测领域对机器学习作出了重大贡献.它通过提供一个大型且标记良好的glitch数据集,使得各种机器学习算法的开发和测试成为可能,从而改进了引力波中glitch信号的检测和分类. Gravity Spy数据集对机器学习研究的贡献体现在以下几方面.

(1) Gravity Spy作为一个基准数据集,可以用于评估不同机器学习模型在噪声分类方面的性能.研究人员可以将他们的方法与已建立的基准模型进行比较,评估改进情况.

(2) 特征表示: Gravity Spy数据集促进了对各种特征表示技术的探索,如时频图、梅尔频率倒谱系数和小波变换,这些技术对于捕捉噪声特征至关重要.

(3) 算法开发: 数据集的多样性和不平衡性推动了具有处理这些挑战能力的鲁棒算法的开发.卷积神经网络、深度学习、注意力机制和集成方法等技术在此数据集中得到了广泛测试和改进.

(4) 迁移学习: 数据集使得迁移学习实验成为可能,通过在大型通用数据集上预训练的模型进一步

在Gravity Spy数据集上进行微调,以提高性能.这种方法在有标签数据有限的情况下显示出很高的准确性.

当然, Gravity Spy数据集也存在一定的局限性.

(1) 类不平衡: Gravity Spy数据集的主要局限性之一是glitch类别分布极其不平衡,一些glitch类型的数量比其他类型多得多,这使得模型难以准确学习并识别罕见的glitch.

(2) 错误标签glitch: 由于数据集是由公民科学家标记的,因此可能存在glitch标签错误或不一致的情况,这将影响机器学习模型的性能.

(3) glitch的动态性: LIGO探测器中的glitch可能会由于环境、设备或操作条件的变化而随时间变化,这种动态性意味着数据集需要不断更新以保持相关性.

(4) 有限的上下文信息: 虽然数据集提供了glitch的时频图,但通常缺乏glitch发生时的上下文信息,且时频图会丢失glitch的相位信息.

尽管存在这些局限性, Gravity Spy数据集仍然是机器学习社区的宝贵资源,推动了glitch分类的进步,并为引力波探测的更广泛目标作出了显著贡献.未来可从以下几个方面展开研究.

(1) 数据增强: 通过生成合成噪声或对现有数据进行变换来人工增加数据集的多样性.

(2) 主动学习: 迭代选择最具信息量的样本进行标记,减少人工标注的负担.

(3) 领域适应: 适应模型以应对数据分布随时间的变化,确保持续的相关性和准确性.

(4) 可解释性: 开发可解释的机器学习模型决策方法,提高用户的信任和理解.

总之, Gravity Spy项目结合了公民科学家与机器学习的优势来解决复杂科学问题.这种协同合作显著提升了glitch分类技术,有力推动了引力波探测领域的发展,并为未来更多重要发现奠定了坚实基础.

5 总结

自2015年LIGO首次成功探测到GW150914事件以来,极大地推动了天文学和物理学的前沿研究.然而,随着探测灵敏度的提高,地面探测器中同时也出现了大量来自仪器和环境的噪声信号,尤其是glitch信号,这对引力波数据的处理和分析构成了重大挑战.

机器学习,特别是深度学习技术,已经在地面引力波噪声数据处理中展示出巨大潜力.通过自动化地识别和分类glitch信号,机器学习方法能够有效提高信号检测的精度,减少误报率,并显著提升数据处理的效率.本文回顾了一般的噪声数据处理方法的优缺点,并概述了各种机器学习方法在地面噪声数据处理中的应用,特别是Gravity Spy项目的成功案例,展示了机器学习与公民科学家相结合在改进LIGO等探测器数据质量中的重要作用.

Gravity Spy项目成功地分类和识别了多种glitch信号.该项目不仅为引力波探测的数据处理提供了强有

力的工具,也为机器学习在复杂科学问题中的应用提供了宝贵经验.随着数据集的不断扩展和模型的优化,Gravity Spy项目极大地提升了地面引力波信号的探测灵敏度和数据分析的可靠性.

尽管取得了显著进展,但当前的机器学习模型仍面临着一些挑战,如数据集不平衡、噪声标签不准确以及glitch信号的动态变化等.这些问题需要通过进一步的研究和技术改进来解决.未来,随着更先进的机器学习技术的发展和跨学科合作的深入开展,预计这些挑战将逐步得到克服,从而推动引力波天文学的发展.

参考文献

- Abbott B P, Abbott R, Abbott T D, et al. Observation of gravitational waves from a binary black hole merger. *Phys Rev Lett*, 2016, 116: 061102
- Aso Y, Michimura Y, Somiya K, et al. Interferometer design of the KAGRA gravitational wave detector. *Phys Rev D*, 2013, 88: 043007
- Amaro-Seoane P, Audley H, Babak S, et al. Laser interferometer space antenna. arXiv: 1702.00786
- Hu W R, Wu Y L. The Taiji Program in Space for gravitational wave physics and the nature of gravity. *Natl Sci Rev*, 2017, 4: 685–686
- Luo J, Chen L S, Duan H Z, et al. TianQin: A space-borne gravitational wave detector. *Class Quantum Grav*, 2016, 33: 035010
- Chen H Y, Lyu X Y, Li E K, et al. Near real-time gravitational wave data analysis of the massive black hole binary with TianQin. *Sci China-Phys Mech Astron*, 2024, 67: 279512
- Abbott R, Abbott T D, Acernese F, et al. GWTC-3: Compact binary coalescences observed by LIGO and Virgo during the second part of the third observing run. *Phys Rev X*, 2023, 13: 041039
- Abbott B P, Abbott R, Abbott T D, et al. GW170817: Observation of gravitational waves from a binary neutron star inspiral. *Phys Rev Lett*, 2017, 119: 161101
- Torres-Orjuela A, Huang S J, Liang Z C, et al. Detection of astrophysical gravitational wave sources by TianQin and LISA. *Sci China-Phys Mech Astron*, 2024, 67: 259511
- Abbott B P, Abbott R, Abbott T D, et al. Characterization of transient noise in Advanced LIGO relevant to gravitational wave signal GW150914. *Class Quantum Grav*, 2016, 33: 134001
- Aasi J, Abadie J, Abbott B P, et al. Characterization of the LIGO detectors during their sixth science run. *Class Quantum Grav*, 2015, 32: 115012
- Armano M, Audley H, Baird J, et al. Transient acceleration events in LISA Pathfinder data: Properties and possible physical origin. *Phys Rev D*, 2022, 106: 062001
- Wang H, Du M, Xu P, et al. Challenges in space-based gravitational wave data analysis and applications of artificial intelligence. *Sci Sin-Phys Mech Astron*, 2024, 54: 270403
- George D, Shen H, Huerta E A. Classification and unsupervised clustering of LIGO data with deep transfer learning. *Phys Rev D*, 2018, 97: 101501
- Mukherjee S, Obaid R, Matkarimov B. Classification of glitch waveforms in gravitational wave detector characterization. *J Phys-Conf Ser*, 2010, 243: 012006
- Rampone S, Pierro V, Troiano L, et al. Neural network aided glitch-burst discrimination and glitch classification. *Int J Mod Phys C*, 2013, 24: 1350084
- Powell J, Trifirò D, Cuoco E, et al. Classification methods for noise transients in advanced gravitational-wave detectors. *Class Quantum Grav*, 2015, 32: 215012
- Powell J, Torres-Forné A, Lynch R, et al. Classification methods for noise transients in advanced gravitational-wave detectors II: Performance tests on Advanced LIGO data. *Class Quantum Grav*, 2017, 34: 034002
- Mukund N, Abraham S, Kandhasamy S, et al. Transient classification in LIGO data using difference boosting neural network. *Phys Rev D*, 2017, 95: 104059

- 20 Glanzer J, Banagiri S, Coughlin S B, et al. Data quality up to the third observing run of advanced LIGO: Gravity Spy glitch classifications. *Class Quantum Grav*, 2023, 40: 065004
- 21 Bini S, Vedovato G, Drago M, et al. An autoencoder neural network integrated into gravitational-wave burst searches to improve the rejection of noise transients. *Class Quantum Grav*, 2023, 40: 135008
- 22 Ormiston R, Nguyen T, Coughlin M, et al. Noise reduction in gravitational-wave data *via* deep learning. *Phys Rev Res*, 2020, 2: 033066
- 23 Merritt J D, Farr B, Hur R, et al. Transient glitch mitigation in Advanced LIGO data. *Phys Rev D*, 2021, 104: 102004
- 24 Houba N, Ferraioli L, Giardini D. Detection and mitigation of glitches in LISA data: A machine learning approach. *Phys Rev D*, 2024, 109: 083027
- 25 Boudart V. Convolutional neural network to distinguish glitches from minute-long gravitational wave transients. *Phys Rev D*, 2023, 107: 024007
- 26 George D, Huerta E A. Deep learning for real-time gravitational wave detection and parameter estimation: Results with Advanced LIGO data. *Phys Lett B*, 2018, 778: 64–70
- 27 Cuoco E, Powell J, Cavaglià M, et al. Enhancing gravitational-wave science with machine learning. *Mach Learn-Sci Technol*, 2021, 2: 011002
- 28 Zevin M, Coughlin S, Bahaadini S, et al. Gravity Spy: Integrating advanced LIGO detector characterization, machine learning, and citizen science. *Class Quantum Grav*, 2017, 34: 064003
- 29 Sakai Y, Itoh Y, Jung P, et al. Unsupervised learning architecture for classifying the transient noise of interferometric gravitational-wave detectors. *Sci Rep*, 2022, 12: 9935
- 30 Mohanty S D, Chowdhury M A T. Glitch subtraction from gravitational wave data using adaptive spline fitting. *Class Quantum Grav*, 2023, 40: 125001
- 31 Davis D, Littenberg T B, Romero-Shaw I M, et al. Subtracting glitches from gravitational-wave detector data during the third LIGO-Virgo observing run. *Class Quantum Grav*, 2022, 39: 245013
- 32 Abbott B P, Abbott R, Abbott T D, et al. GWTC-1: A gravitational-wave transient catalog of compact binary mergers observed by LIGO and Virgo during the first and second observing runs. *Phys Rev X*, 2019, 9: 031040
- 33 Abbott B P, Abbott R, Adhikari R, et al. LIGO: The laser interferometer gravitational-wave observatory. *Rep Prog Phys*, 2009, 72: 076901
- 34 Adams T. Detector Characterisation and Searches for Gravitational Waves using GEO 600. Dissertation for Doctoral Degree. Cardiff: Cardiff University, 2014
- 35 Buonanno A, Chen Y. Quantum noise in second generation, signal-recycled laser interferometric gravitational-wave detectors. *Phys Rev D*, 2001, 64: 042006
- 36 Driggers J C, Vitale S, Lundgren A P, et al. Improving astrophysical parameter estimation *via* offline noise subtraction for Advanced LIGO. *Phys Rev D*, 2019, 99: 042001
- 37 Davis D, Massinger T, Lundgren A, et al. Improving the sensitivity of Advanced LIGO using noise subtraction. *Class Quantum Grav*, 2019, 36: 055011
- 38 Pawlowski R S, Hansen R O. Gravity anomaly separation by Wiener filtering. *Geophysics*, 1990, 55: 539–548
- 39 Abbott B P, Abbott R, Abbott T D, et al. GW150914: The Advanced LIGO detectors in the era of first discoveries. *Phys Rev Lett*, 2016, 116: 131103
- 40 Littenberg T B, Cornish N J. Bayesian inference for spectral estimation of gravitational wave detector noise. *Phys Rev D*, 2015, 91: 084034
- 41 Cornish N J, Littenberg T B. Bayeswave: Bayesian inference for gravitational wave bursts and instrument glitches. *Class Quantum Grav*, 2015, 32: 135012
- 42 Walker M, Agnew A F, Bidler J, et al. Identifying correlations between LIGO's astronomical range and auxiliary sensors using lasso regression. *Class Quantum Grav*, 2018, 35: 225002
- 43 Nuttall L K, Massinger T J, Areeda J, et al. Improving the data quality of Advanced LIGO based on early engineering run results. *Class Quantum Grav*, 2015, 32: 245005
- 44 Powell J. Parameter estimation and model selection of gravitational wave signals contaminated by transient detector noise glitches. *Class Quantum Grav*, 2018, 35: 155017
- 45 Essick R, Godwin P, Hanna C, et al. iDQ: Statistical inference of non-gaussian noise with auxiliary degrees of freedom in gravitational-wave detectors. *Mach Learn-Sci Technol*, 2021, 2: 015004
- 46 Biswas R, Blackburn L, Cao J, et al. Application of machine learning algorithms to the study of noise artifacts in gravitational-wave data. *Phys Rev D*, 2013, 88: 062003
- 47 Cavaglia M, Staats K, Gill T. Finding the origin of noise transients in LIGO data with machine learning. *Commun Comput Phys*, 2019, 25: 963–987

- 48 Gabbard H, Williams M, Hayes F, et al. Matching matched filtering with deep networks for gravitational-wave astronomy. *Phys Rev Lett*, 2018, 120: 141103
- 49 Nitz A H, Dal Canton T, Davis D, et al. Rapid detection of gravitational waves from compact binary mergers with PyCBC Live. *Phys Rev D*, 2018, 98: 024050
- 50 Isogai T (LIGO Scientific Collaboration and the Virgo Collaboration). Used percentage veto for LIGO and Virgo binary inspiral searches. *J Phys-Conf Ser*, 2010, 243: 012005
- 51 Colgan R E, Márka Z, Yan J, et al. Detecting and diagnosing terrestrial gravitational-wave mimics through feature learning. *Phys Rev D*, 2023, 107: 062006
- 52 Colgan R E, Corley K R, Lau Y, et al. Efficient gravitational-wave glitch identification from environmental data through machine learning. *Phys Rev D*, 2020, 101: 102003
- 53 Essick R, Blackburn L, Katsavounidis E. Optimizing vetoes for gravitational-wave transient searches. *Class Quantum Grav*, 2013, 30: 155010
- 54 Mukund N, Coughlin M, Harms J, et al. Ground motion prediction at gravitational wave observatories using archival seismic data. *Class Quantum Grav*, 2019, 36: 085005
- 55 Abbott B P, Abbott R, Abbott T D, et al. Exploring the sensitivity of next generation gravitational wave detectors. *Class Quantum Grav*, 2017, 34: 044001
- 56 Razzano M, Cuoco E. Image-based deep learning for classification of noise transients in gravitational wave detectors. *Class Quantum Grav*, 2018, 35: 095016
- 57 George D, Huerta E A. Deep neural networks to enable real-time multimessenger astrophysics. *Phys Rev D*, 2018, 97: 044039
- 58 Coughlin S, Bahaadini S, Rohani N, et al. Classifying the unknown: Discovering novel gravitational-wave detector glitches using similarity learning. *Phys Rev D*, 2019, 99: 082002
- 59 Sakai Y, Itoh Y, Jung P, et al. Training process of unsupervised learning architecture for Gravity Spy dataset. *Annalen der Physik*, 2024, 536: 2200140
- 60 Houba N, Ferraioli L, Giardini D. Detection and mitigation of glitches in LISA data: A machine learning approach. *Phys Rev D*, 2024, 109: 083027
- 61 George D, Shen H, Huerta E A. Deep transfer learning: A new deep learning glitch classification method for advanced LIGO. arXiv: 1706.07446
- 62 Rollins J G. Multimessenger Astronomy with Low-Latency Searches for Transient Gravitational Waves. Dissertation for Doctoral Degree. New York: Columbia University, 2011
- 63 Chatterji S, Blackburn L, Martin G, et al. Multiresolution techniques for the detection of gravitational-wave bursts. *Class Quantum Grav*, 2004, 21: S1809–S1818
- 64 Bahaadini S, Noroozi V, Rohani N, et al. Machine learning for Gravity Spy: Glitch classification and dataset. *Inf Sci*, 2018, 444: 172–186
- 65 Davis D, Walker M. Detector characterization and mitigation of noise in ground-based gravitational-wave interferometers. *Galaxies*, 2022, 10: 12
- 66 Saleem M, Gunny A, Chou C J, et al. Demonstration of machine learning-assisted real-time noise regression in gravitational wave detectors. arXiv: 2306.11366
- 67 Gabbard H, Messenger C, Heng I S, et al. Bayesian parameter estimation using conditional variational autoencoders for gravitational-wave astronomy. *Nat Phys*, 2022, 18: 112–117
- 68 Wei W, Huerta E A. Deep learning for gravitational wave forecasting of neutron star mergers. *Phys Lett B*, 2021, 816: 136185
- 69 Wang H, Zhou Y, Cao Z, et al. WaveFormer: Transformer-based denoising method for gravitational-wave data. *Mach Learn-Sci Technol*, 2024, 5: 015046
- 70 Vajente G, Huang Y, Isi M, et al. Machine-learning nonstationary noise out of gravitational-wave detectors. *Phys Rev D*, 2020, 101: 042003
- 71 Torres A, Marquina A, Font J A, et al. Total-variation-based methods for gravitational wave denoising. *Phys Rev D*, 2014, 90: 084029
- 72 Torres-Forné A, Cuoco E, Marquina A, et al. Total-variation methods for gravitational-wave denoising: Performance tests on Advanced LIGO data. *Phys Rev D*, 2018, 98: 084013
- 73 Torres-Forné A, Marquina A, Font J A, et al. Denoising of gravitational wave signals via dictionary learning algorithms. *Phys Rev D*, 2016, 94: 124040
- 74 Wei W, Huerta E A. Gravitational wave denoising of binary black hole mergers with deep learning. *Phys Lett B*, 2020, 800: 135081
- 75 Shen H, George D, Huerta E A, et al. Denoising gravitational waves with enhanced deep recurrent denoising auto-encoders. In: Proceedings of the 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Brighton: IEEE, 2019. 3237–3241
- 76 Pankow C, Chatziioannou K, Chase E A, et al. Mitigation of the instrumental noise transient in gravitational-wave data surrounding GW170817. *Phys Rev D*, 2018, 98: 084016

- 77 Lopez M, Boudart V, Buijsman K, et al. Simulating transient noise bursts in LIGO with generative adversarial networks. [Phys Rev D](#), 2022, 106: 023027
- 78 Powell J, Sun L, Gereb K, et al. Generating transient noise artefacts in gravitational-wave detector data with generative adversarial networks. [Class Quantum Grav](#), 2023, 40: 035006
- 79 Davis D, White L V, Saulson P R. Utilizing aLIGO glitch classifications to validate gravitational-wave candidates. [Class Quantum Grav](#), 2020, 37: 145001
- 80 Ashton G, Thiele S, Lecoecue Y, et al. Parameterised population models of transient non-Gaussian noise in the LIGO gravitational-wave detectors. [Class Quantum Grav](#), 2022, 39: 175004
- 81 Macas R, Pooley J, Nuttall L K, et al. Impact of noise transients on low latency gravitational-wave event localization. [Phys Rev D](#), 2022, 105: 103021
- 82 Hourihane S, Chatziioannou K, Wijngaarden M, et al. Accurate modeling and mitigation of overlapping signals and glitches in gravitational-wave data. [Phys Rev D](#), 2022, 106: 042006
- 83 Soni S, Austin C, Effler A, et al. Reducing scattered light in LIGO's third observing run. [Class Quantum Grav](#), 2020, 38: 025016
- 84 Longo A, Bianchi S, Valdes G, et al. Daily monitoring of scattered light noise due to microseismic variability at the Virgo interferometer. [Class Quantum Grav](#), 2021, 39: 035001
- 85 Yan J, Leung A P, Hui C Y. On improving the performance of glitch classification for gravitational wave detection by using generative adversarial networks. [Mon Not R Astron Soc](#), 2022, 515: 4606–4621
- 86 Soni S, Berry C P L, Coughlin S B, et al. Discovering features in gravitational-wave data through detector characterization, citizen science and machine learning. [Class Quantum Grav](#), 2021, 38: 195016
- 87 Robinet F, Arnaud N, Leroy N, et al. Omicron: A tool to characterize transient noise in gravitational-wave detectors. [SoftwareX](#), 2020, 12: 100620
- 88 Brown J C. Calculation of a constant Q spectral transform. [J Acoust Soc Am](#), 1991, 89: 425–434
- 89 Wu Y, Zevin M, Berry C P L, et al. Advancing glitch classification in Gravity Spy: Multi-view fusion with attention-based machine learning for Advanced LIGO's fourth observing run. arXiv: [2401.12913](#)
- 90 Apostol E S, Truică C O. Efficient machine learning ensemble methods for detecting gravitational wave glitches in LIGO time series. In: Proceedings of the 2023 IEEE 19th International Conference on Intelligent Computer Communication and Processing (ICCP). Cluj-Napoca: IEEE, 2023. 79–86
- 91 Mesuga R, Bayanay B J. A deep transfer learning approach on identifying glitch wave-form in gravitational wave data. arXiv: [2107.01863](#)
- 92 Fernandes T, Vieira S, Onofre A, et al. Convolutional neural networks for the classification of glitches in gravitational-wave data streams. [Class Quantum Grav](#), 2023, 40: 195018

Application of machine learning in ground-based gravitational wave transient noise data processing

XIE QunYing^{1*}, KANG RuiChun¹, LI JiaTong¹, GUO YiYang^{2,3}, ZHAO ShaoDong^{2,3},
ZHANG XueHao^{2,3} & ZOU XiaoBo^{2,3}

¹*School of Information Science & Engineering, Lanzhou University, Lanzhou 730000, China;*

²*Lanzhou Center for Theoretical Physics and Key Laboratory of Quantum Theory and Application of MOE, Lanzhou 730000, China;*

³*School of Physical Science and Technology, Lanzhou University, Lanzhou 730000, China*

**Corresponding author (email: xieqy@lzu.edu.cn)*

In 2015, LIGO first detected the binary black hole merger event GW150914, marking a new era in gravitational wave astronomy. Ground-based laser interferometric gravitational wave detectors possess extremely high sensitivity, making them susceptible to transient noise (glitches) from both the instrument and the environment. Despite the development of various methods and tools in gravitational wave signal processing to enhance the characterization, identification, and removal of these glitches, LIGO's continuous data output can overwhelm any research team. Therefore, developing robust methods to manage glitches is crucial for improving the reliability and scientific value of gravitational wave detection. This article first reviews the advantages and disadvantages of general noise data processing methods, then outlines the applications of various machine learning techniques in this area. Finally, it introduces the latest application of machine learning in glitch data processing through the Gravity Spy project. The goal is to present recent advancements in machine learning for the recognition, modeling, and removal of glitches, providing a reference for researchers handling transient noise in ground-based gravitational wave data.

gravitational wave, data analysis, noise, artificial intelligence

PACS: 04.30.-w, 07.05.Kf, 85.40.Qx, 07.05.Mh

doi: [10.1360/SSPMA-2024-0369](https://doi.org/10.1360/SSPMA-2024-0369)