将长短期记忆网络和卷积神经网络应用于引力波真实数据中的核心坍缩超新星搜索

Alberto Iess[1], Elena Cuoco[1,2], Filip Morawski[3,4], Constantina Nicolaou[5], 和 Ofer Lahav 5

[1] 比萨高等师范学校，骑士广场7号，意大利比萨 I-56126，电子邮件：alberto.iess@sns.it [2] 欧洲引力天文台（EGO），意大利比萨卡西纳 I-56021 [3] 尼古拉·哥白尼天文中心，波兰科学院，Bartycka 18，00-716，波兰华沙 [4] 苏格兰大学物理联盟，格拉斯哥大学物理与天文学学院，英国格拉斯哥 G12 8QQ [5] 伦敦大学学院物理与天文学系，Gower Street，英国伦敦 WC1E 6BT

2023年1月24日

arXiv:2301.09387v1 [astro-ph.IM] 23 Jan 2023

摘要

背景。 预计核心坍缩超新星（CCSNe）会产生引力波信号，在银河系及邻近星系内，这些信号有望被当前和未来一代干涉仪探测到。核心坍缩超新星产生的信号具有随机性，因此需要采用匹配滤波以外的检测方法。

目的。 我们旨在展示机器学习（ML）在使用真实数据对不同核心坍缩超新星模拟信号和噪声瞬变进行多标签分类方面的潜力。我们比较了一维和二维卷积神经网络（CNN）在单个及多个探测器数据上的表现。我们首次使用长短期记忆网络（LSTM）测试了多标签分类。

方法。 我们采用事件触发生成器小波检测滤波器（WDF），结合机器学习，对核心坍缩超新星信号进行搜索和分类。我们将数据的时间序列和时频表示作为机器学习模型的输入。为计算分类准确率，我们将中微子驱动核心坍缩的最新流体动力学模拟所得核心坍缩超新星波形，同时注入来自 LIGO 和 Virgo O2 科学运行的干涉仪噪声中；注入距离为可探测的 1 千秒差距。

结果。 我们比较了三个模型在单个探测器数据上的表现。随后，我们合并了各模型对单个探测器数据中的噪声和天体物理瞬变进行分类的输出，得到了 LIGO 的总体准确率（~ 99%）和 Virgo 的总体准确率（~ 80%）。我们进一步使用三个干涉仪之间的符合触发事件分析了多探测器情形，准确率达到 ~ 98%。

1。引言

S自双黑洞（BBH）并合
GW150914（Abbott 等，2016b）被 LIGO 和 Virgo 科
e学合作组织发现以来，引力波（GW）天文学
g在科学界逐渐受到关注，为其带来了新的发展动力
n天体物理学中的一种新观测渠道。这促成了首次
j电磁（EM）与引力波（GW）多信使观测
t双中子星（BNS）并合 GW170817（Ab-
bott 等人，2017年），发生于 Advanced
LIGO（Harry（2010年）和 Aasi 等人（2015年））及 Advanced Virgo
（（Acernese 等人，2015年）干涉仪探测器，以及一
l在首个引力波暂
s态星表 GWTC-1 中收录了大量双黑洞并合（Abbott等人，2019）。2020年，激光干涉引力波天文台和
VVirgo完成了第三次科学运行 O3；首
p阶段 O3a 的结果揭示了39个候选事件，这
b些候选致密并合事件来自26周的数据，相关结果发表于
G GWTC-2星表（Abbott等人，2021a）。目前，激光干涉引力波天文台和Virgo干涉仪正按计划进行升级，以提高灵敏度，迎接将于2023年开始的O4科学运行。KAGRA探测器（So
мuya，2012）在O3接近尾声时开始了首次观测运行（Akutsu
等人，2020），也将提高灵敏度，从而有效构建一个由四台干涉仪组成、探测能力更强的网络，以服务未来的科学运行。

在引力波的天体物理源中，核心坍缩超新星（CCSNe）尚未被观测到。由于它们会发射电磁辐射和中微子，因此是多信使分析的有趣候选对象。然而，核心坍缩超新星发出的引力波信号无法被由于坍缩动力学具有随机性，且依赖于许多参数（如前身星质量、旋转状态和金属丰度），因此无法对其进行精确建模。因此，人们采用不同于常规匹配滤波方法的替代检测方法，这些方法对信号波形的假设尽可能少，例如基于小波的相干WaveBurst流水线（Klimenko与Mitselmakher（2004）和Klimenko等人（2016））。机器学习（ML）技术已用于解决引力波天文学中的诸多问题，包括不同类型源的信号检测（Baker等人（2015）、Gabbard等人（2018）、Kim等人（2020）和Morawski等人（2020））、参数估计（Varma等人（2019）、Haegel与Husa（2020）、Green等人（2020）、Chua与Vallisneri（2020）和Williams等人（2021））、噪声分类（Zevin等人（2017）、Mukund等人（2017）和Razzano与Cuoco（2018））以及噪声扣除（Torres-Forné等人（2020）和Wei与Huerta（2020））；Cuoco等人（2020）的综述对此进行了全面介绍。在此前的工作中（Iess等人，2020），我们展示了一维和二维卷积神经网络（CNN）在区分噪声瞬变（即毛刺）与核心坍缩超新星爆发信号波形方面的有效性。这些信号由三维流体动力学模拟生成，并叠加在背景噪声上；我们使用白化时间序列和频谱图作为输入特征。背景噪声为模拟的高斯噪声，根据Virgo在O3科学运行期间以及未来爱因斯坦望远镜（ET）探测器的理论灵敏度曲线生成（Punturo等人（2010）和Hild等人（2011））。在同一项工作中，我们还展示了模型能够正确区分不同核心坍缩超新星引力波辐射模型。卷积神经网络

Astone等人（2018）也使用唯象模型，在多个引力波探测器中搜索核心坍缩超新星信号的g模发射。Cavaglià等人（2020）使用遗传编程算法，将计算得到的一组参数（如中心频率、带宽和持续时间）作为输入特征，在单个干涉仪数据中实现同一目标。Chan等人（2020）训练了一种一维卷积神经网络模型，利用引力波探测器网络的白化引力波时间序列搜索核心坍缩超新星。

在本分析中，我们通过使用 O2 科学观测运行期间的真实探测器噪声，而非模拟噪声，扩展了此前关于这一主题的研究（Iess等人，2020）。我们通过加入两个能量更高的模型，增加了超新星波形的数量。此外，我们还探索了循环神经网络（RNN），并将其性能与卷积神经网络进行了比较。循环神经网络是一类专门用于处理序列数据的神经网络，其反馈回路机制使网络能够将先前的输入保留在记忆中，并将其与当前输入一并考虑（Hüsken & Stagge 2003）。循环神经网络模型常用于自然语言处理领域（Nicolaou et al. 2019）以及时间序列数据处理。在本研究中，我们使用了一种特殊的循环神经网络，即长短期记忆单元（长短期记忆网络）（Hochreiter & Schmidhuber 1997）。这种网络能够解决梯度消失问题，并具备处理长期依赖关系的能力，因此最适合分析引力波数据。我们首先使用来自单个探测器的一段数据进行训练和测试，随后将研究方法扩展到三干涉仪网络。本文结构如下：第 2 节和第 3 节介绍真实探测器数据，并简要概述本研究所用的波形。第 4 节介绍分析中涉及的各类机器学习算法。第 5 节详述结果，第 6 节则讨论并总结研究结论。

2. 数据集

本研究分析的数据通过将经三维数值模拟获得的部分核心坍缩超新星波形添加到真实的干涉仪噪声中生成。与 Iess 等人（2020）、Astone 等人（2018）和 Chan 等人（2020）使用的模拟高斯噪声相比，引力波探测器中的真实噪声存在一定程度的变化，因为它受环境条件影响；这些条件可以监测，但无法控制。当噪声伪迹持续时间较长时，会影响探测器的灵敏度；在频域中，这对应于非平稳噪声功率谱密度（PSD）。此外，数据中还存在许多类别的短暂非天体物理瞬变，它们可能通过触发否决或虚警而妨碍引力波搜索流程。考虑到这一点，为了比较结果，我们从 O2公开科学运行（Abbott 等人 2021b）中选取了 44 个片段，要求每个探测器至少 97% 的时间通过 Abbott 等人（2016a）所述的数据质量标志。每个文件都包含一段时长为 4096 秒、采样率为 4096 Hz 的时间序列，并以其起始 GPS时间标识。这些片段涵盖了从t_{GPS} = 1185669120 到t_{GPS} = 1186070528的时段。在本分析中，我们使用了此前已在模拟数据上测试的五种核心坍缩超新星模型（s11、s13、he3.5、s18p、s25）。此外，为增加分类问题的复杂性，我们还加入了两种振幅较高、以前身星为沃尔夫–拉叶星的模型（m39、y20），以及一种前身星质量与 s18p 相同、但对流氧壳层中没有初始密度扰动的波形（s18np）（Powell 与 Müller 2020）。波形经过低通滤波以抑制混叠，并降采样至 4096 Hz。我们将所有信号模拟为位于固定 1 千秒差距处，并在天空中均匀分布。为满足后一条件，我们从赤经 α 和赤纬余弦 δ的均匀分布中进行采样。波框架中的偏振角固定为 $\psi = 0$。每个片段中最初的 300 秒不含注入信号，并用于估算功率谱密度（PSD）（Cuoco 等人 2001）和计算白化参数。随后，每隔十秒注入一次信号，同时考虑各个历元中不同探测器对两种引力波偏振h_+、$h_\times$ 的天线方向图函数F_+、$F_\times$，以及相对于地心参考系为各干涉仪计算的时间偏移（Schutz 2011）。完整的依赖关系由下式描述：

$$h(t) = F_+(\alpha,\delta,\lambda,\beta,\chi,\eta)\,h_+(t) + F_\times(\alpha,\delta,\lambda,\beta,\chi,\eta)\,h_\times(t), \quad (1)$$

其中，λ、β 分别是探测器的经度和纬度，χ 定义了探测器臂角平分线的方向，η 则是两条探测器臂之间的夹角。设$s(t) = n(t) + h(t)$为探测器时间序列，其中$n(t)$为干涉仪噪声，$h(t)$为可能存在的信号。那么，时刻t_0 的匹配滤波信噪比（S/N）时间序列按 Allen 等人（2012）的方法计算：

$$\left(\frac{S}{N}\right)^2 = 4\int_0^{f_{max}} \frac{\tilde{s}(f)\left[\tilde{h}(f)^*\right]_{t_0=0}}{S_n(f)}\, e^{2\pi i f t_0}\, df, \quad (2)$$

其中，f_{max}为最高频率截断值，$S_n(f)$为单边噪声功率谱密度。将信号注入探测器应变数据后，使用小波检测滤波器（WDF）库在时域进行白化处理，以去除噪声功率谱密度中的平稳分量。该库见 Cuoco 等人（2001）和 Cuoco 等人（2018）的文献。白化参数通过使用自回归（AR）模型拟合噪声功率谱密度计算得出。每个数据段注入的核心坍缩超新星总数为 376 个，即八个模型各 47 个。注入数据集的 16544 个核心坍缩超新星信号中，有一部分会因对小波变换系数平方和设置固定阈值而触发 WDF 流水线。WDF 检测到的事件并非只有这些，因为噪声瞬变也会产生额外的触发事件。图 1 展示了这两类仪器和天体物理爆发信号实例的白化时频图。

3. 波形

3.1. s11 模型

s11 模型是由 Andresen 等（2017）使用 PROMETHEUS-VERTEX 代码（Rampp 和 Janka 2002）模拟的 11$M_\odot$ 零龄主序模型，该代码采用牛顿引力。模拟在核心反弹时刻后0.35秒结束。该模型不会发生爆炸，其引力波振幅在本研究所考虑的所有引力波信号中最小。其峰值频率较低，为~ 600Hz。

3.2. s13 模型

s13 模型是一个质量为 13$M_\odot$ 的零龄主序模型，由 Radice 等人（2019年）使用欧拉辐射流体力学代码 FOR- NAX（Skinner 等人 2019年）进行模拟。该模型不会发生爆炸，并显示出与 g模相关的引力波辐射。该模型在核心反弹后 0.78s 结束。由于缺乏激波复兴，该模型的引力波振幅较低，峰值频率为~ 800Hz。该模型呈现出较弱的驻立吸积激波不稳定性（SASI）成分。

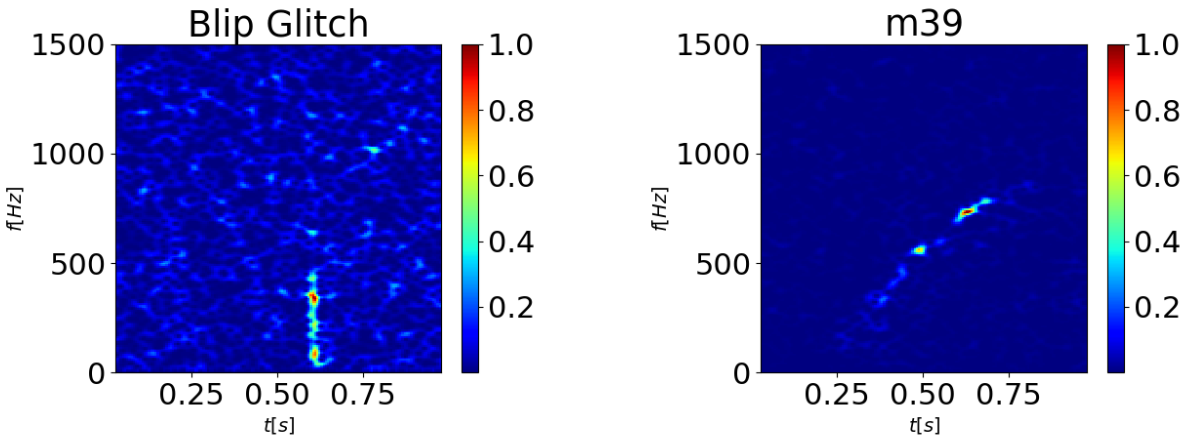

图 1. 本分析所用噪声和信号类别的白化时频图示例：短促毛刺噪声（左）和 m39（右），后者是一种快速旋转核心坍缩超新星爆炸模型。图中所示的 m39 引力波对应于极向辐射。为供二维卷积神经网络分类器使用，频谱图已重新缩放至 $[0, 1]$ 范围。

3.3. 模型 *s25*

s25 模型是一个质量为 $25M_\odot$ 的零龄主序模型，由 Radice 等人（2019年）使用欧拉辐射流体力学代码 FOR- NAX 进行模拟。该模型在核心反弹后 0.5s 发生爆炸，模拟于核心反弹时刻后 0.62s 结束，此时引力波辐射仍然很强。该模型在低频处呈现出明显的驻立吸积激波不稳定性（SASI）特征，同时还具有高频 g模，其引力波辐射峰值为 ~ 1000Hz。

3.4. 模型 *s18p*

模型 s18p 是来自 Powell 与 Müller（2019）的 $18M_\odot$ ZAMS 前身星，使用广义相对论中微子流体力学代码 CoCoNuT-FMT（Müller 等，2010年）进行模拟。模拟结束时间为 0.9 秒，此时引力波辐射的振幅已降至极低水平。该模型的频谱图中显示出清晰的 g 模信号。该模型在核心反弹后 ~ 300 毫秒发生爆炸。引力波频率峰值为 ~ 850 赫兹。

*3.5. s18np*模型

Powell & Müller（2020）的 s18np模型与 s18 的不同之处在于，模拟中未包含来自对流氧壳层的扰动。因此，该模型会产生强烈的坍缩后旋转激波不稳定性。

*3.6. he3.5*模型

模型 he3.5 是来自 Powell 与 Müller（2019）的 3.5 $M_\odot$ 极度剥离氦星，使用广义相对论中微子流体力学代码 CoCoNuT-FMT 进行模拟。极度剥离星是指在双星系统中，因向双星伴星转移质量而失去外层的恒星（Tauris 等，2015年）。模拟在核心反弹后 0.7 秒结束，此时早已过了引力波辐射峰值阶段。该模型的频谱图中呈现出清晰的 g 模。引力波信号的振幅在 ~ 900Hz 处最强。该模型在核心反弹后 ~ 0.4 秒发生爆炸。

*3.7. y20*模型

模型 y20 由 Powell 与 Müller（2020）使用中微子流体动力学代码 CoCoNuT-FMT 进行模拟，是一颗非旋转、质量为 20 个太阳质量且具有太阳金属丰度的沃尔夫-拉叶星。该模型的模拟在核心反弹后 1.2 秒停止。其波形的特征是核心反弹后出现早期对流，频率低于 200Hz。激波在反弹后 ~ 200ms 复兴，随后出现强烈的基模辐射。

3.8. 模型 *m39*

Powell & Müller（2020）模拟的 m39模型是一颗快速自转的沃尔夫-拉叶星，其初始氦星质量为 39 个太阳质量。该模拟采用中微子流体动力学代码 CoCoNuT-FMT 执行。由于快速自转（600km s^{-1}），强烈的中微子驱动爆炸产生了较大的信号振幅，且无需强磁场的帮助。模拟在核心反弹后 0.98 s 结束，并在反弹后 ~ 200ms 实现激波复兴。其主要特征是强烈的基模辐射，峰值频率可达 ~ 800Hz。该模型的赤道辐射在与快速自转恒星核心反弹相关的所有频率上都具有较高振幅。然而，我们的分析仅使用了极向辐射，如图 1 所示。

4. 深度学习算法

在本分析中，我们使用了不同类型的机器学习算法进行多标签分类。提供了两种类型的输入：供一维卷积神经网络和长短期记忆网络使用的白化时间序列，以及供二维卷积神经网络使用的白化时频图像。

4.1. 一维卷积神经网络

一维卷积神经网络以白化时间序列作为输入。它由 4 个卷积层组成，卷积核大小为 3。卷积滤波器的数量分别为 (120,80,80,40)。每个卷积层之后均应用大小为 (2,2) 的最大池化，并对 40% 的节点进行空间丢弃。卷积神经网络架构的输出被输入到两个全连接层中，其大小分别为 200 和 100。这些层使用的激活函数是修正线性

表1. 各干涉仪分别在所有分析时段内产生的触发事件累计数，以及三个探测器的所有符合触发事件数。

	触发事件		
探测器	信号	噪声	总计
Virgo V1	9273	47901	57174
LIGO L1	10480	3810	14290
LIGO H1	10984	4103	15087
L1, H1, V1	5647	675	6322

单元 (ReLU)。最后一层为全连接层，节点数由类别标签的数量决定，并采用 softmax 激活函数来得出每个类别的概率。使用的优化器为 Adam，学习率为 $\alpha = 0.001$，损失函数为类别交叉熵。我们选择的批次大小为 32。

4.2. 二维卷积神经网络

二维卷积神经网络以白化时频图作为输入。以样本为中心的频谱图使用凯泽窗（$\beta = 5.6$）生成，采用多个长度为 0.125s、带有重叠的快速傅里叶变换。网络由 3 个卷积层组成，卷积核大小分别为 (4,4)、(3,3) 和 (2,2)。每个卷积层之后均应用 (2,2) 最大池化。卷积神经网络架构的输出馈入一个大小为 200 的全连接层，随后进入一个输出概率的全连接输出层。我们使用了与一维情形相同的激活函数。采用的优化器为 Adam，学习率为 $\alpha = 0.001$，损失函数为分类交叉熵。批量大小为 32。

4.3. 长短期记忆网络

循环模型以白化时间序列为输入。它由 2 个双向长短期记忆层组成，维度分别为 64 和 32。第一个循环层有 10% 的输出节点应用空间丢弃。输出随后传入 4 个全连接层，大小分别为 1024、256、64、32，使用*tanh* 激活函数；最后传入一个全连接输出层，通过 softmax 激活函数输出每个类别的概率。所用优化器为 Adam，学习率为 $\alpha = 0.001$，损失函数为分类交叉熵损失函数。批量大小为 256。

5. 搜索和分类结果

我们在相同的训练集上分别训练了每个网络。完整数据集按以下比例划分：60% 用于训练，10% 用于验证，30% 用于测试。图 2 展示了全部 44 个文件中注入信号的匹配滤波信噪比分布。信号的信噪比会因波形模型以及模拟源相对于干涉仪的位置而异。正如预期，由于 Virgo 的灵敏度较低，相同信号在 Virgo 产生的信噪比较低。我们观察到匹配滤波器的信

Virgo 中振幅较低的模型的信噪比集中在 4 附近，之后分布急剧下降。这与我们将信噪比取为每个触发事件附近数秒时间序列上匹配滤波器响应的最大值这一事实相符。在没有信号的情况下，我们在 3 到 4 之间的区域计算该值，因此弱信号几乎不会具有更低的信噪比。此外，噪声突发是 WDF 产生部分触发事件的原因。表1报告了所有数据段中产生的触发事件累计数量

分别针对每个探测器列出，同时还列出了三个探测器中同时发生的触发事件数量。尽管运行 WDF 时采用了相同的白化参数，Virgo数据集中的噪声触发数量仍大幅超出。

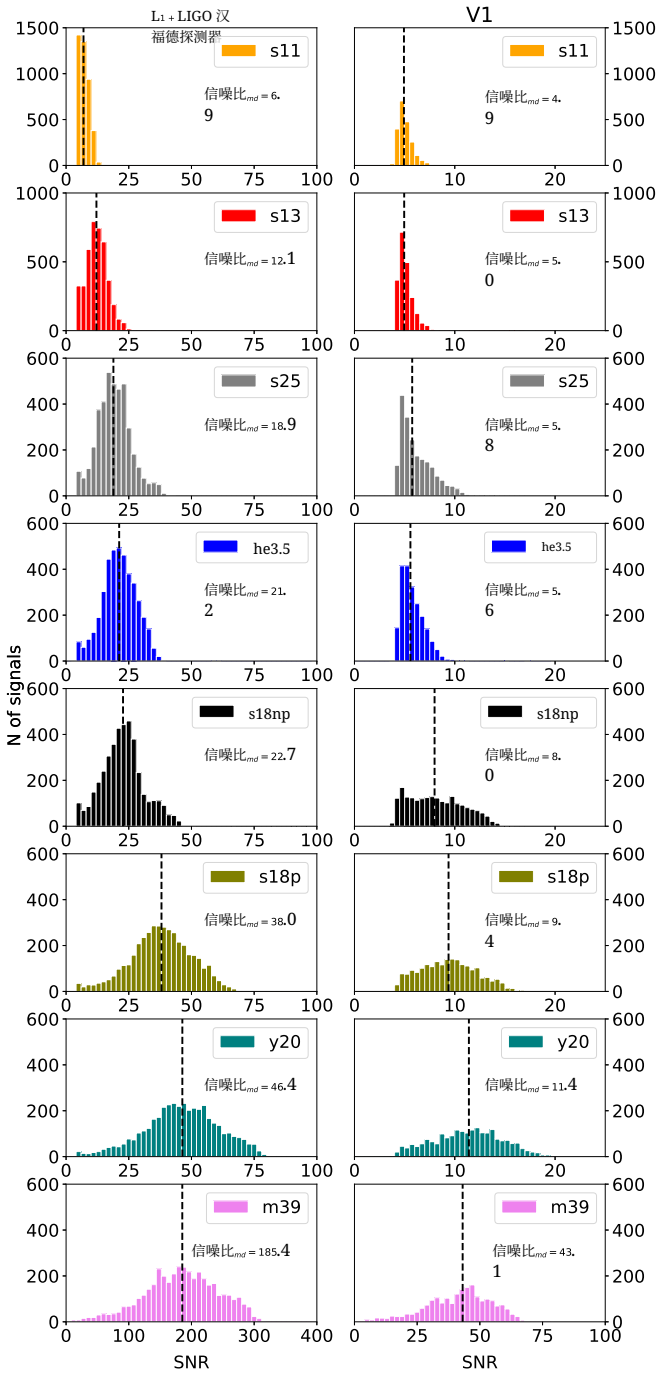

图2. 注入干涉仪中的信号的匹配滤波器信噪比分布：Virgo（右侧）以及 LIGO 利文斯顿和汉福德（左侧）。由于灵敏度和信号信噪比相似，LIGO 探测器被归为一组。每种波形模型的信噪比中位数处均绘有一条虚线。

这可以解释为探测器噪声功率谱密度的非平稳特性，以及其在各个独立片段中的较大变化，这使白化过程的效果有所降低。未来可以通过采用自适应白化，实时跟踪功率谱密度的演变来解决这一问题。对于每个干涉仪，当触发时间戳落在注入波形所覆盖的片段内时，我们便将该触发定义为由核心坍缩超新星信

号引起。当同一信号产生多个触发时，我们通过对触发时间取平均进行聚类。由于 V1 数据中的大量背景触发可能会使训练过程产生偏差，因此在训练这一特定数据集时，我们只使用了与 LIGO 利文斯顿探测器和 LIGO 汉福德探测器时间上重合的触发。选择重合时间窗时，我们考虑了波形的长度以及干涉仪之间的最大传播时间。需要强调的是，同一核心坍缩超新星模型的不同部分都可能触发 WDF。从事件时间戳出发，我们围绕触发选取了一个对称时间窗，其长度设为 Radice s25 模型的长度；它是波形中第二短的。这样便避免使用因计算时间有限而停止模拟后产生的波形尾部。我们注意到，Andersen s11 波形触发 WDF 流水线的次数不足，无法在训练和测试中有效使用。在整个数据集中，与 s11 时间重合的触发事件，在 LIGO H1 和 LIGO L1 数据集中分别只有 16 个和 12 个，且没有任何触发事件同时与三个探测器重合。因此，我们没有将样本的时间窗设为 s11 的长度；为保持完整性，仍在训练和测试过程中保留了该模型及其标签。

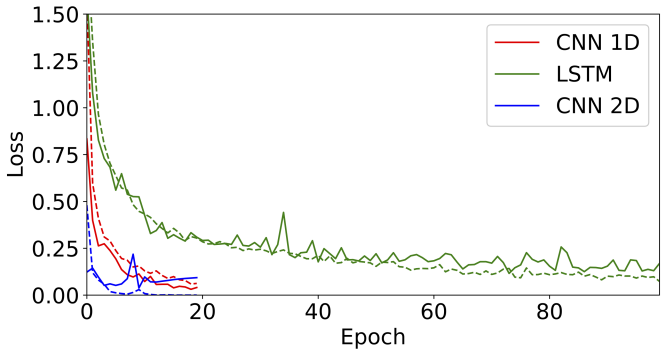

图 3. 所考虑模型的分类交叉熵损失函数随训练轮次的变化。虚线表示训练损失，实线表示在验证集上计算的损失。

训练前，我们对样本进行了随机打乱，以使数据集均匀分布。每个模型所需的训练时间各不相同，因为这取决于其架构中需要优化的权重数量。此外，训练时间还与各数据集中的样本数量有关，因此由于采用了三重符合，Virgo 的训练时间较短。为了避免过拟合，我们为每种算法分别选择了训练轮数。我们在 Tesla k40 GPU 上对一维卷积神经网络进行了 10 轮训练，在 L1 上每轮平均耗时约 ~ 15 秒。我们在 Tesla k40 GPU 上对二维卷积神经网络进行了 10 轮训练，在 L1 上每轮平均耗时约 ~ 20 秒。长短期记忆网络在 Tesla k80 GPU 上进行了 100 轮训练，如图 3 所示，在 L1 上每轮平均耗时约 ~ 60 秒。表 2 展示了各模型在每个探测器上对所有类别的完整灵敏度，这些数值对应于混淆矩阵对角线上的值。我们回顾一下，某一类别 c 的灵敏度（亦称真正率，TPR）定义为真正例与真正例和假负例之和的比值：

$$TPR_c = \frac{TP_c}{TP_c + FN_c}. \quad (3)$$

在以下各小节中，我们将分别分析每个数据集，并详细介绍各个独立模型及合并模型的结果。合并模型的预测结果通过对一维卷积神经网络、二维卷积神经网络和长短期记忆网络计算出的输出概率取平均得到。图4展示了三个干涉仪的多标签分类混淆矩阵，以及所有错误分类样本的信噪比分布。图5展示了合并模型根据信噪比对 LIGO 和 Virgo 数据集中的不同核心坍缩超新星模型进行分类的情况。该图突出表明，核心坍缩超新星信号在 LIGO 数据集中的信噪比较高，只有较弱的信号会被错误分类。另一方面，注入 Virgo 数据的模型中，只有能量最高的模型被正确分类。s25 是一个例外，它表现出低频 SASI辐射。

5.1. LIGO L1

经 WDF 触发器提取后，LIGO L1 数据集由以下样本组成：3810 个噪声触发、12 个 s11、1438 个 s18p、1782 个 s18np、704 个 he 3.5、2052 个 m39、1969 个 y20、476 个 s13、2047 个 s25。如前所述，Andresen s11 样本数量过少，任何算法都无法通过训练识别其特征。所有机器学习模型对高能量核心坍缩超新星信号的分类准确率都较高；而 he3.5 和 s13 的灵敏度最低，因为与其他信号相比，它们在训练集和测试集中的代表性都不足。具体而言，与其他算法相比，一维卷积神经网络对 s13 和 s18p 信号的分类准确率低 ~ 10%。长短期记忆网络有轻微倾向，会将噪声误分类为低信噪比信号类别，这可能是因为它会记住数据中的小噪声峰。我们对三个模型的概率取平均值进行合并，得到总体灵敏度 ~ 99.3%，与最佳模型（二维卷积神经网络）的结果相当。分类错误的信号的信噪比低于 20。

5.2. LIGO H1

与预期一致，LIGO H1 数据集与 LIGO L1 的数据集相当相似。其构成为：4103 个噪声触发事件、25 个 s11、1534 个 s18p、1803 个 s18np、881 个 he3.5、2059 个 m39、1991年个 y20、637 个 s13、2054 个 s25。对于所使用的所有机器学习模型，高振幅模型都取得了最佳分类真正率。与 L1 一样，s13 和 he3.5 在所有机器学习算法中的准确率最低。不过，在这个数据集中，长短期记忆网络架构对这些信号的分类准确率最低。尽管其表现仍不如卷积神经网络，但与 L1 场景相比，同一模型在噪声类别上的准确率更高。这可能是因为纳入的噪声样本数量更多。合并三个模型的输出并未提升灵敏度，未超过表现最佳的二维卷积神经网络模型，但取得了相近的数值（真正率 ~ 99.1%）。与 L1 一样，信噪比低于 20 的样本占大多数错误分类样本。

5.3. Virgo V1

V1、L1 和 H1 之间的三重符合触发用于识别 Virgo V1 数据集中的样本，其分布如下：675 个噪声、0 个 s11、329 个 s18p、491 个 s18np、115 个 he3.5、1940 个 m39、1139 个 y20、76 个 s13、1557 个 s25。振幅较低的核心坍缩超新星模型要么完全没有出现（s11），要么只出现在少量样本中，且主要处于较低信噪比。所考察的机器学习算法均无法有效分类 s13、he3.5 和 s18p 信号。长短期记忆网络的表现

表 2. 在 O2科学运行的真实数据上，计算了三个探测器 Virgo 探测器、LIGO 利文斯顿探测器和 LIGO 汉福德探测器的噪声类别与核心坍缩超新星信号类别的真阳性率，以及总灵敏度。星号表示相应数据集中不存在该模型。

		波形									
ITF	**模型**	噪声	*s11*	*s18p*	*s18np*	*he3.5*	*m39*	*y20*	*s13*	*s25*	**总计**
V1	LSTM	49.2	*	3.6	58.4	0.0	89.5	69.9	0.0	89.8	73.7
	一维卷积神经网络	44.6	*	8.4	10.9	0.0	84.3	73.1	0.0	87.4	68.3
	二维卷积神经网络	48.6	*	9.6	39.4	3.6	92.3	72.5	0.0	94.6	75.2
L1	LSTM	90.1	0.0	98.2	92.8	85.4	98.7	96.0	87.1	94.8	93.6
	一维卷积神经网络	99.4	0.0	89.5	95.3	82.2	99.2	98.2	75.5	98.8	95.9
	二维卷积神经网络	99.8	0.0	99.1	99.3	97.4	100.0	99.7	91.6	99.8	99.3
H1	LSTM	96.2	0.0	95.5	96.8	89.1	99.7	95.9	75.1	97.6	95.4
	一维卷积神经网络	99.0	0.0	90.1	99.3	91.6	98.4	100.0	80.6	97.4	96.5
	二维卷积神经网络	99.7	0.0	99.6	99.8	96.8	99.7	99.8	96.8	99.2	99.1

优于卷积神经网络，能够识别具有低频 SASI辐射的中等振幅 s18np模型。一种可能的解释是，长短期记忆网络能够在较低信噪比下识别低频辐射。在 y20测试样本上，长短期记忆网络的表现略逊于一维卷积神经网络和二维卷积神经网络。所有模型在 m39 和 s25模型上均取得了良好的灵敏度（真正率 > 84%）。最常见的误识别是在低信噪比下将信号误识别为噪声触发，以及误识别为 y20模型。对于 V1数据，与二维卷积神经网络相比，合并输出提高了整体灵敏度，真 正率 ~ 79.8%，而后者为 ~ 75.3%。如图4所示，较低信噪比<20 导致了大多数分类错误的样本，尽管较弱的 m39信号仍会被误识别至信/噪比 ~ 30。信号的信噪比分布在信/噪比 = 18 – 30 区间存在间隙：这是由于分析中使用的核心坍缩超新星模型具有不同的固有引力波振幅，因此导致大多数信号在相应的信噪比区间内被分类错误。

5.4. 三干涉仪分析

尽管对于信噪比较高的信号，我们成功地在激光干涉引力波天文台干涉仪上取得了较高的单探测器分类准确率，但更稳健且更贴近实际的方法是利用所有可用探测器的数据，以期提高对较弱信号的准确率。可以通过将各探测器的时间序列或图像堆叠起来，使用三个探测器的数据训练网络来实现这一点，从而使输入维度增加一维。核心坍缩超新星信号由地心参考系中的时间和赤道坐标定义。随后，考虑天线方向图以及探测器之间的时间延迟，将信号投影到每个干涉仪的数据中。我们使用此前为 Virgo V1 数据集计算的 coincident 触发事件，获得三台干涉仪的样本，并据此训练和测试模型。各类别所用信号的细分情况参见该数据集。由于样本量远小于单个激光干涉引力波天文台探测器的情况，这对分类器的性能产生了负面影响。尽管存在这一局限，图6所示合并模型对各个核心坍缩超新星模型的灵敏度仍然很高，与单个激光干涉引力波天文台探测器所得结果相当。具体而言，我们观察到一种熟悉的模式：代表性不足的类别和信噪比较低的模型（he3.5、s13）准确率较低。另一方面，对于所有类别，其分类灵敏度都显著高于 Virgo 数据集。与单探测器的情况一样，合并模型在正确分类噪声样本方面更为稳健，噪声类别的 真正率 ~ 97.7%；尽管噪声类别在整个数据集中所占比例小得多（表1对此有所体现），这一结论仍然成立。合并模型的总体真正率 为 ~ 97.8%。所有类别的真正率

计算结果证实了各个模型的单探测器结果，分别为：一维卷积神经网络的真正率 ~ 89.5%、长短期记忆网络的真正率 ~ 86.7%，以及二维卷积神经网络的真正率 ~ 98.4%。由于三重 coincident 样本数量减少，训练过程受到阻碍，因此提高分类准确率的一种可行方案是利用生成对抗网络（GAN）（Goodfellow 等，2014）扩充数据集。生成对抗网络已成功用于生成逼真的合成数据集，例如各类人物图像（Gulrajani 等，2017），甚至指尖图像（Yu 等，2019）。原则上，同样的方法可以改善所研究频谱图表示数据集中各类核心坍缩超新星模型之间的平衡。不过，这种方法需要另行开展专门的研究项目。

6. 讨论

在尚未观测到的引力波辐射源中，核心坍缩超新星尤为值得关注，因为它们具有多个辐射通道，能够传递有关当前坍缩机制的不同信息。由于辐射信号具有高度随机性，目前的匹配滤波技术无法应用于核心坍缩超新星的引力波搜索。机器学习算法对数据基本不作预设，也不对信号形态作出假设。不过，它们非常适合检测时间序列和时频数据中的模式。我们先前已证明，在假设存在高斯噪声背景的情况下，一维和二维卷积神经网络能够根据信号在这两个域中的形态对其进行分类。在这项后续研究中，我们证明了卷积神经网络架构和循环长短期记忆网络在涉及真实探测器噪声的分类任务中也能取得较高的准确率。与 Iess 等人（2020）相比，本分析存在几项重要差异。首先，我们新增了三种中微子驱动爆炸模型，以提高多标签分类问题的复杂度。其次，在训练过程中，我们将真实噪声瞬变归为单独一类。此外，我们将所有信号的距离固定为 1 千秒差距，并针对三个干涉仪中的每一个，使用相同的源进行单探测器分析，以比较信噪比分布和分类准确率。因此，信号信噪比仅取决于注入时刻探测器的灵敏度，以及信号相对于探测器平面的天球方向，这两者通过天线方向图函数体现。三个网络在激光干涉引力波天文台数据集上的准确率均超过 90%，且对于灵敏度和朝向相近的两个探测器，预测结果一致。与模拟噪声背景的情况一样，二维卷积神经网络在三种网络中表现最佳，并且在不同训练轮次中的预测非常稳定。对于激光干涉引力波天文台数据集，一维卷积神经网络的表现略优于长短期记忆网络，但

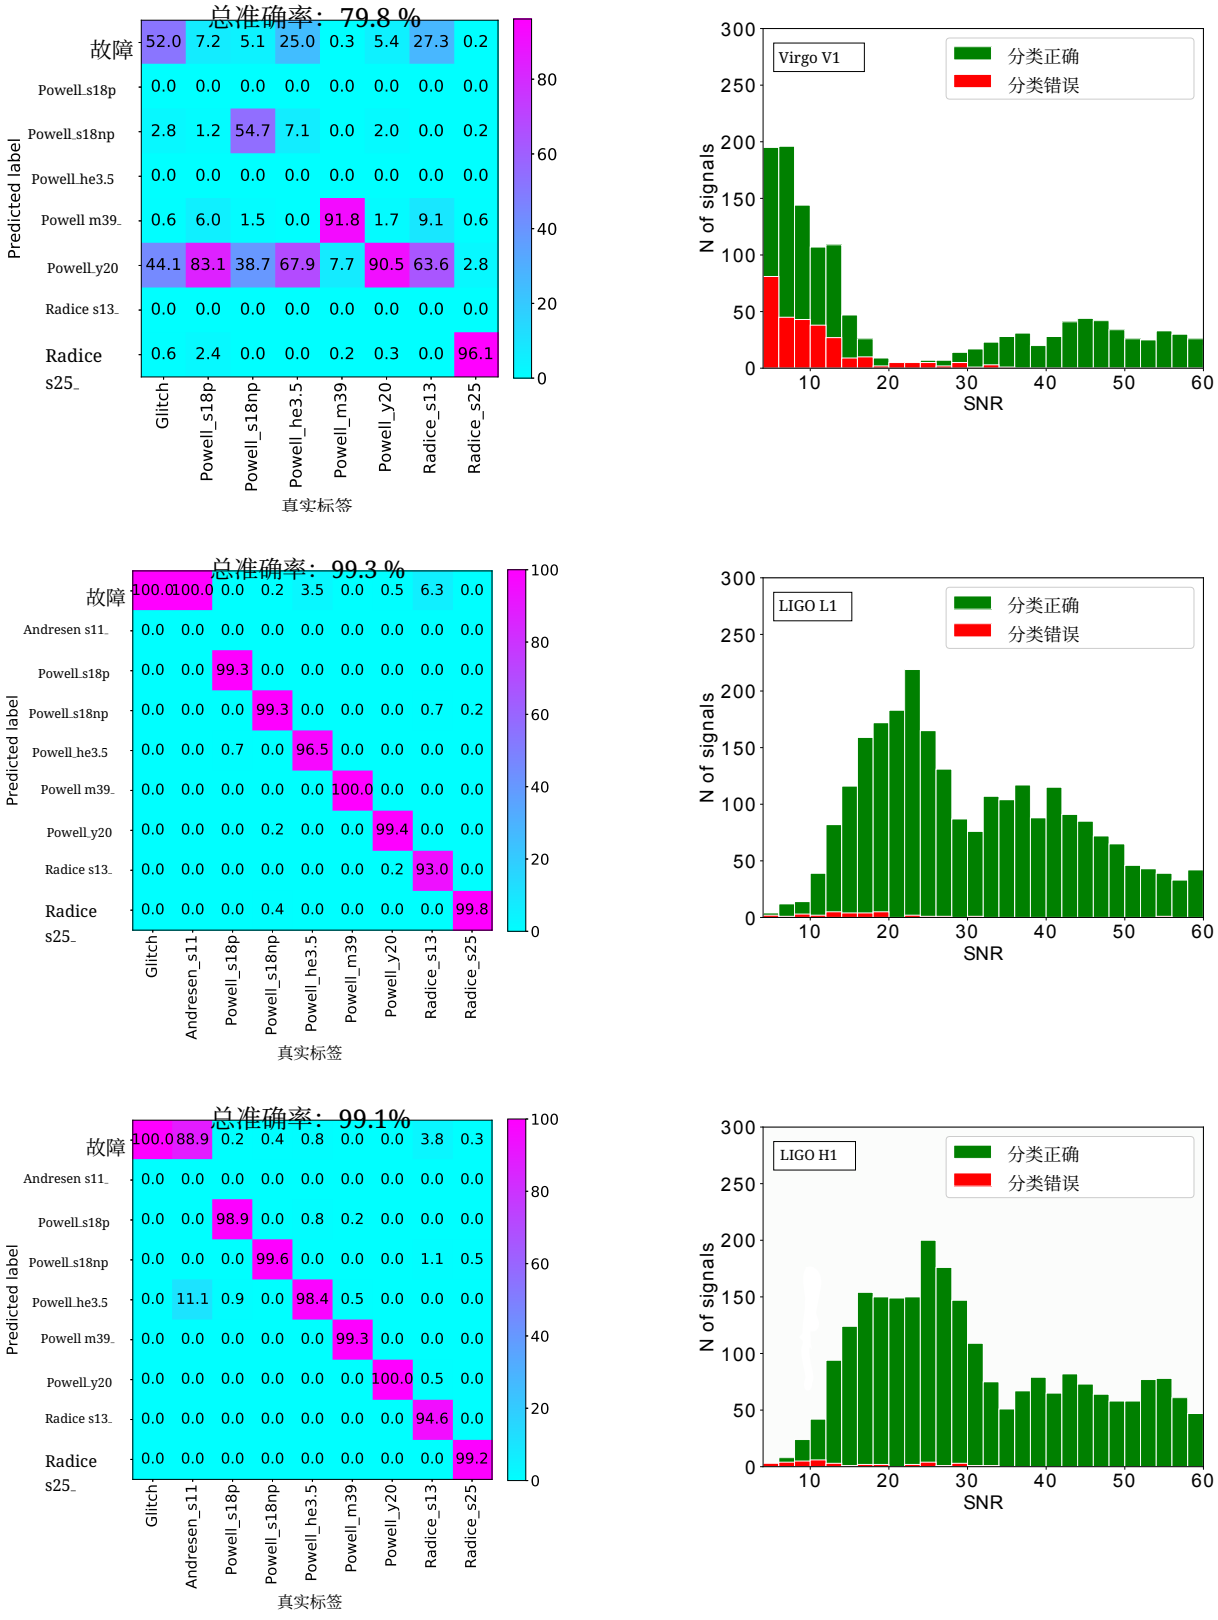

图4。 使用长短期记忆网络、一维卷积神经网络和二维卷积神经网络的合并输出，对 V1（顶部）、L1（中部）和 H1（底部）数据集进行多标签分类所得的混淆矩阵，以及分类正确和分类错误样本的信噪比分布。我们仅展示低于 S/N=60 的信噪比范围，因为分类错误发生在该范围内。

在 Virgo 数据集上的表现则较差，这主要是因为它无法对 s18np 模型进行分类；该模型具有 SASI特征。合并模型的表现与二维卷积神经网络相当，

在输入大量样本时，能够以非常高的准确率区分噪声实例。对于 Virgo 数据集，由于样本量较小，且探测器处的核心坍缩超新星信号信噪比较低，预期其准确率会较差

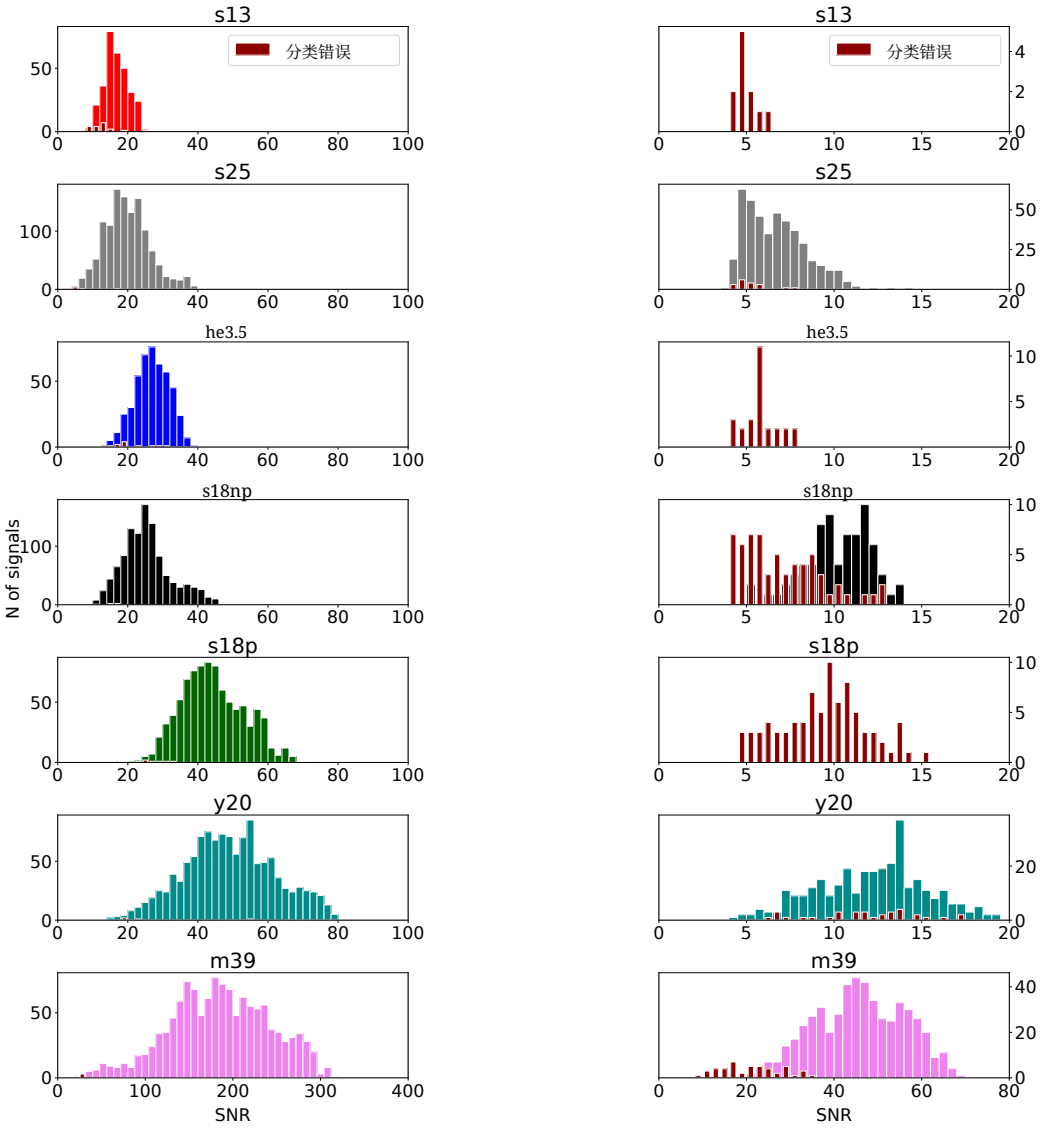

图 5。激光干涉引力波天文台 LIGO L1、LIGO 汉福德探测器（左）和 Virgo Virgo V1（右）测试集的匹配滤波器信噪比分布直方图。深红色的较窄柱表示在每个信噪比区间内，合并后的长短期记忆网络和卷积神经网络模型分类错误的信号数量。L1 和 LIGO 汉福德探测器的组距为 2，Virgo Virgo V1 的组距为 0.5，但 m39 的信噪比范围更大。对于后一个模型，L1 和 LIGO 汉福德探测器的分箱宽度为 8，Virgo Virgo V1 的分箱宽度为 2。

。尽管如此，振幅较高的信号通常仍能达到中等偏好的准确率。另一方面，对于同一数据集，信噪比为< 15时的结果会受到样本量的显著影响。为全面评估这一低信噪比区域，可以构建一个针对性数据集，为每种波形提供更多样本，以探查模型在此类信噪比下的表现。在本研究中，我们还将先前的分析（Iess等人，2020）扩展至多探测器框架，方法与 Astone 等人（2018）和 Chan 等人（2020）相同：将来自每台干涉仪、对应同一信号的样本进行堆叠，并要求 WDF 触发事件在时间上相互符合。这使我们能够在现实场景下开展分析：与 Virgo 干涉仪相比，激光干涉引力波天文台数据集包含信噪比较高的核心坍缩超新星样本。由于要求触发事件相互符合，数据集规模有所缩小，因此我们的准确率略低于单台激光干涉引力波天文台干涉仪的情况。不过，我们预计，随着数据集中的样本量增加，两种情况之间的差距最终将会缩小。从计算角度来看，我们受到数据集规模和 GPU 内存的限制。虽然我们使用长短期记忆网络取得了相近的准确率以及一维卷积神经网络架构，相比之下，循环模型的超参数调优更为困难，训练所需时间也显著更长。此外，长短期记忆网络在学习较长序列时性能会下降，这限制了它们分析由数千个时间步组成的数据集的能力。对于一些具有低频发射分量的模型，在较低信噪比区域中，长短期记忆网络的表现优于一维卷积神经网络；这一结果还需要通过更大的数据集进一步分析。也可以采用下采样来提升循环模型的计算性能，并缩短需要学习的序列长度。总体而言，上述分析表明，卷积神经网络和循环神经网络架构可用于引力波探测流程，以探测中微子驱动的核心坍缩超新星暴发信号；此外，还有可能区分来自银河系附近区域的源所产生的不同信号形态。所得结果与此前针对模拟探测器噪声（Iess等人，2020）和真实探测器噪声（López等人，2021）中的中微子驱动核心坍缩超新星模型的应用结果一致，且距离范围与本研究所考虑的范围相同。以往及当前的估计已将

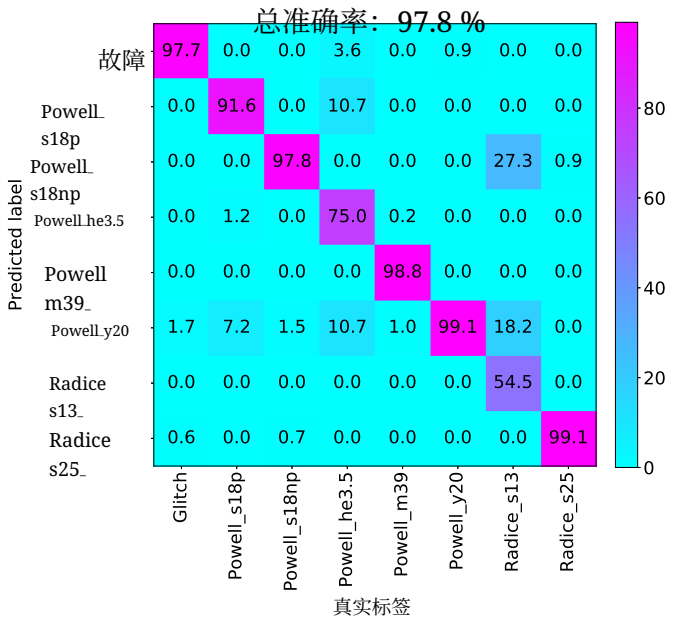

图 6. 将使用来自激光干涉引力波天文台（LIGO 利文斯顿探测器、LIGO 汉福德探测器）和 Virgo（Virgo 探测器）数据的三台干涉仪网络样本训练得到的长短期记忆网络、一维卷积神经网络和二维卷积神经网络模型的输出合并后，得到的测试集分类混淆矩阵。

银河系核心坍缩超新星的发生率估计为每世纪1至2次（van den Bergh与Tammann（1991年）、Cappellaro等人（1993年）以及Rozwadowska等人（2021年））。考虑到Virgo、激光干涉引力波天文台和神冈引力波探测器干涉仪灵敏度的计划提升，如果发生的事件具有与当前模拟相似的某些引力波特征（g模发射、提示对流、驻立吸积激波不稳定性），那么利用深度学习方法探测银河系核心坍缩超新星似乎是可行的。

致谢

本文/出版物基于欧洲科学与技术合作组织（COST）支持的COST行动CA17137相关工作。FM获得了波兰国家科学中心项目资助，项目编号为2016/22/E/ST9/00037、2017/26/M/ST9/00978和2020/37/N/ST9/02151，同时还获得了波兰国家学术交流局项目PPN/IWA/2019/1/00157的资助。OL和CN获得了STFC伦敦大学学院数据密集型科学博士培训中心项目ST/P006736/1以及英国科学技术设施委员会综合项目ST/R000476/1的资助。部分计算工作在PL-GRID Prometheus集群基础设施上完成。本研究使用了引力波开放科学中心（https://www.gw-openscience.org/）提供的数据、软件和/或网络工具。该中心由LIGO实验室、LIGO科学合作组织和Virgo合作组织运营。LIGO实验室和Advanced LIGO由美国国家科学基金会（NSF）、英国科学技术设施委员会（STFC）、马克斯·普朗克学会（MPS）以及德国下萨克森州资助，以支持Advanced LIGO的建设，以及GEO600探测器的建设和运行。此外，澳大利亚研究理事会也为Advanced LIGO提供了额外支持。Virgo则通过欧洲引力天文台（EGO）获得资助，资助机构包括法国国家科学研究中心（CNRS）、意大利国家核物理研究所（INFN）和荷兰国家亚原子物理研究所；此外，比利时、德国、希腊、匈牙利、爱尔兰、日本、摩纳哥、波兰、葡萄牙和西班牙的机构也提供了资助。合理要求下，可向通讯作者获取支持本研究结果的数据。

参考文献

Aasi, J., Abbott, B. P., Abbott, R., 等. 2015年, 《经典与量子引力》, 32, 074001 Abbott, B. P., Abbott, R., Abbott, T. D., 等. 2016a, 《经典与量子引力》, 33, 134001 Abbott, B. P., Abbott, R., Abbott, T. D., 等. 2016b, 《物理评论快报》, 116, 061102 Abbott, B. P., Abbott, R., Abbott, T. D., 等. 2017年, 《物理评论快报》, 119, 161101 Abbott, B. P., Abbott, R., Abbott, T. D., 等 . 2019 年 , Phys. Rev. X, 9, 031040 Abbott, R., Abbott, T. D., Abraham, S., 等 . 2021a [arXiv:2010.14527] Abbott, R., Abbott, T. D., Abraham, S., 等 . 2021b, SoftwareX, 13, 100658 Acernese, F., Agathos, M., Agatsuma, K., 等. 2015年, 《经典与量子引力》, 32, 024001 Akutsu, T., Ando, M., Arai, K., 等. 2020年, 理论与实验物理进展, 2021 Allen, B., Anderson, W. G., Brady, P. R., Brown, D. A., & Creighton, J. D. E. 2012, 《物理评论D》, 85, 122006 Andresen, H., Müller, B., Müller, E., & Janka, H. T. 2017年, 《皇家天文学会月报》, 468, 2032 Astone, P., Cerdá-Durán, P., Di Palma, I., 等. 2018, 《物理评论D》, 98, 122002 Baker, P. T., Caudill, S., Hodge, K. A., 等. 2015年, 《物理评论D》, 91, 062004 Cappellaro, E., Turatto, M., Benetti, S., 等. 1993年, 《天文学与天体物理学》, 273, 383 Cavaglià, M., Gaudio, S., Hansen, T., 等. 2020年, Mach. Learn.: Sci. Technol., 1, 015005 Chan, M. L., Heng, I. S., & Messenger, C. 2020年, 《物理评论D》, 102, 043022 Chua, A. J. & Vallisneri, M. 2020, 《物理评论快报》, 124 Cuoco, E., Calamai, G., Fabbroni, L., 等. 2001, 《经典与量子引力》, 18, 1727 Cuoco, E., Powell, J., Cavaglià, M., 等. 2020年, 机器学习：科学与技术 Cuoco, E., Razzano, M., & Utina, A. 2018, 收录于第26届欧洲信号处理会议（欧洲信号处理会议）, 2018年, 2648–2652 Gabbard, H., Williams, M., Hayes, F., & Messenger, C. 2018, 《物理评论快报》, 120, 141103 Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., 等. 2014, 生成对抗网络 Green, S. R., Simpson, C., & Gair, J. 2020年, 《物理评论D》, 102 Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A. 2017年, 改进的Wasserstein生成对抗网络训练 Haegel, L. & Husa, S. 2020, 《经典与量子引力》, 37, 135005 Harry, G. M. 2010年, 《经典与量子引力》, 27, 084006 Hild, S., Abernathy, M., Acernese, F., 等. 2011年, 《经典与量子引力》, 28, 094013 Hochreiter, S. & Schmidhuber, J. 1997, Neural Comput., 9, 1735–1780 Hüsken, M. & Stagge, P. 2003, Neurocomputing, 50, 223 Iess, A., Cuoco, E., Morawski, F., & Powell, J. 2020年, 机器学习：科学与技术, 1, 025014 Kim, K., Li, T. G. F., Lo, R. K. L., Sachdev, S., & Yuen, R. S. H. 2020年, 《物理评论D》, 101, 083006 Klimenko, S. & Mitselmakher, G. 2004, 《经典与量子引力》, 21, S1819 Klimenko, S., Vedovato, G., Drago, M., 等. 2016, 《物理评论D》, 93, 042004 López, M., Di Palma, I., Drago, M., Cerdá-Durán, P., & Ricci, F. 2021年, 《物理评论D》, 103, 063011 Morawski, F., Bejger, M., & Ciecieląg, P. 2020年, 机器学习：科学与技术, 1, 025016 Mukund, N., Abraham, S., Kandhasamy, S., Mitra, S., & Philip, N. S. 2017, 《物理评论 D 》, 95, 104059 Müller, B., Janka, H.-T., & Dimmelmeier, H. 2010年, 《天体物理学杂志增刊》, 189, 104 Nicolaou, C., Vaidya, A., Dzogang, F., Wardrope, D., & Konstantinidis, N. 2019, 收录于2019年第六届社交网络分析、管理与安全国际会议（社交网络分析、管理与安全国际会议）, 351–356 Powell, J. & Müller, B. 2019年, 《皇家天文学会月报》, 487, 1178 Powell, J. & Müller, B. 2020年, 《皇家天文学会月报》, 494, 4665 Punturo, M., Abernathy, M., Acernese, F., 等. 2010年, 《经典与量子引力》, 27, 194002

Radice, D., Morozova, V., Burrows, A., Vartanyan, D., & Nagakura, H. 2019年, 《天体物理学杂志快报》, 876, L9 Rampp, M. & Janka, H. T. 2002, 《天文学与天体物理学》, 396, 361 Razzano, M. & Cuoco, E. 2018, 《经典与量子引力》, 35, 095016 Rozwadowska, K., Vissani, F., & Cappellaro, E. 2021年, 《新天文学》, 83, 101498 Schutz, B. F. 2011, 《经典与量子引力》, 28, 125023 Skinner, M. A., Dolence, J. C., Burrows, A., Radice, D., & Vartanyan, D. 2019年, 《天体物理学杂志增刊》, 241, 7 Somiya, K. 2012, 《经典与量子引力》, 29, 124007 Tauris, T. M., Langer, N., & Podsiadlowski, P. 2015年, 《皇家天文学会月报》, 451, 2123 Torres-Forné, A., Cuoco, E., Font, J. A., & Marquina, A. 2020年, 《物理评论D》, 102, 023011 van den Bergh, S. & Tammann, G. A. 1991年, 《天文学与天体物理学年评》, 29, 363 Varma, V., Gerosa, D., Stein, L. C., Hébert, F., & Zhang, H. 2019年, 《物理评论快报》, 122, 011101 Wei, W. & Huerta, E. 2020年, 《物理快报B》, 800, 135081 Williams, M. J., Veitch, J., & Messenger, C. 2021年, 《物理评论D》, 103 Yu, N., Davis, L., & Fritz, M. 2019年, 将伪造图像归因于生成对抗网络：生成对抗网络指纹的学习与分析 Zevin, M., Coughlin, S., Bahaadini, S., 等. 2017年, 《经典与量子引力》, 34, 064003