

深度学习在引力波数据处理中的应用初探

曹周键^a, 王赫^b, 朱建阳^b

(北京师范大学 a.天文系;b.物理系,北京 100875)

摘要:截至 2018-01-16, LIGO 已成功探测引力波事件 6 次.可以预期,引力波探测事件会越来越多,引力波天文学会很快进入到大数据阶段.深度学习在大数据处理方面近年来得到迅速发展.它在数据处理速度,准确度等方面都表现出极大的优势.深度学习在引力波数据处理中的应用讨论还不多.本文引入此问题,并对其初步研究.引力波数据最大的特点是强噪声、弱信号.现行的数据处理方法是利用匹配滤波的方式把引力波信号从强噪声中挖掘出来.同时,匹配滤波方法还可以确定引力波源的性质,定量确定其参数.匹配滤波方法的弱点是计算量巨大.这导致数据处理速度很慢.对于将来的大数据引力波天文学,这更将是一个巨大的隐患.匹配滤波方法的另一个潜在问题是,完备准确的理论波形模板是其工作的前提条件.这个潜在问题的后果是很难找到理论预期之外的引力波信号.深度学习的数据处理方法有可能在这些问题上提供出路.同时,深度学习也会遇到其自身的若干困难和问题.本文将从网络结构、训练数据制备、训练优化、对信号识别的泛化能力、对数据的特征图表示以及对特征数据遮挡的响应等方面来展开讨论.

关键词:引力波天文学;匹配滤波法;深度学习;数值相对论;引力波模板

中图分类号:P142.8;TP183

文献标志码:A

引力波是广义相对论最重要的理论预言之一.引力波探测是史无前例地在强场、强动态时空区对广义相对论的实验检验.更重要地,它将开创全新的宇宙观测窗口——引力波天文学.但引力波探测极其困难.2015 年 9 月 14 日, LIGO 实现了人类的第一次引力波直接探测.该实验结果在 2016 年 2 月公布,并被命名为 GW150914.随后引力波探测的进展非常迅速.到目前为止已确认双黑洞并合引力波探测结果 5 例,分别包括 GW150914^[1], GW151226^[2], GW170608^[3], GW170104^[4]和 GW170814^[5].以及确认的双中子星并合引力波探测结果 1 例, GW170817^[6].另外还有疑似双黑洞并合引力波探测结果 1 例 LVT151012^[7].引力波的成功探测还获得了 2017 年度的诺贝尔物理学奖.受引力波探测的驱动,关于引力波的物理学和天文学研究在 2016 年以来发展也异常迅速.现在,除了比较成熟的 LIGO 型地面引力波探测器外,脉冲星计时观测计划(比如 FAST 的其中一部分科学任务, SKA 计划等)蓬勃发展.空间引力波探测器 eLISA 被列为欧空局的 L3 计划, 检验 eLISA 实验技术的卫星 LISA Pathfinder 运行非常成功^[8].中国也在积极探讨太极^[9-10]、天琴^[11]等引力波探测计划.

影响引力波探测能力的因素包括硬件灵敏度和波源的理论模型.在既定硬件灵敏度的基础上,辅助以好的理论模型可以通过匹配滤波技术(matched filtering)把埋在噪声下的引力波信号挖出来.引力波的成功探测是实验技术进步和理论研究突破结合的产物. GW150914 实验的数据处理中,有效单体数值相对论(EOB-NR)模型挖出噪声下的引力波信号,达到 5.1σ 的置信度,同时还反演出其引力波源是并合双黑洞,给出了该双黑洞的质量、自旋等信息,实现了对引力波源的天文观测^[12-14].

虽然匹配滤波技术在引力波弱信号提取和波源信息反演方面都工作得非常成功,但它具有一个很大的弱点以及一个潜在的隐患.匹配滤波方法的巨大计算量导致数据处理速度很慢.以 LIGO 的数据处理为例,匹配滤波方法对一例引力波事件的数据处理时间在月的量级,所以它完全不能用来做引力波后续观测的天

收稿日期:2018-01-17.

基金项目:国家自然科学基金(11622546;11690023)

作者简介(通信作者):曹周键(1978-),男,重庆人,北京师范大学教授,博士生导师,国家优青,主要研究数值相对论与引力波天文学, E-mail: zjcao@amt.ac.cn.

文预警.目前的引力波后续观测预警使用的是高误报率、低信息量方式.这大大地增加了后续观测的难度.从这个意义上讲,GW170817 完备的引力波及各波段电磁波联合观测是一个非常了不起的成果^[6].

匹配滤波方法的潜在问题是,完备准确的理论波形模板是其工作的前提条件.为了构建理论波形模板,首先需要对可能的引力波源有比较充分的了解;再则需要有较为可靠的理论去描述这些波源;然后需要有快速准确的方式去求解相关方程得到所需理论波形模板^[12-14].致密双星系统是很好的引力波源,别的天文系统如何呢?利用引力波还能观测别的什么天文系统吗?广义相对论已经被无数的实验所验证.它是很好的描述引力波源的基本理论.但时空奇点已经预示了广义相对论在某个时空失效.广义相对论在描述引力波源时什么地方会不适用?它不适用时应该用什么替代理论来描述引力波源?使用广义相对论描述引力波源,需要求解爱因斯坦方程.爱因斯坦方程是自然科学中最为复杂的偏微分方程之一.为建立引力波波形模板,数值相对论是最为可行和可靠的方法^[15-21].数值相对论本身是一个非常困难的研究课题.匹配滤波方法这个潜在问题的后果是很难找到理论预期外的引力波信号^[22].

相反,如果能够观测到理论预期之外的引力波信号.这样的实验结果将极大地促进天文学的发展,同时还将为量子引力、极端物理条件下的物态等重大的基本物理学问题提供重要的实验依据.可以相信,到时引力波探测将不只是排除某些引力理论^[23-26],而是将人们导向正确的超越广义相对论的引力理论.无疑这将对引力波数据处理的一个极大挑战.

深度学习(deep learning)的概念源于人工神经网络(artificial neural networks).含多隐层的多层感知器就是一种深度学习网络结构.深度学习通过组合低层特征形成更加抽象的高层表示属性类别或特征,以发现数据的分布式特征表示.2006年前,尝试训练深度架构因各种原因都失败了.Hinton等人于2016年提出的深度置信网络(DBN)改变了局面,并由此引出了深度学习的概念.基于深度置信网络提出的非监督贪心逐层训练算法,为解决深层结构相关的优化难题带来希望,随后提出多层自动编码器深层结构,为数据的自动降噪提供了可能性^[27].此外Lecun等人提出的卷积神经网络是第一个真正多层结构学习算法^[28].它利用空间相对关系减少参数数目以提高训练性能.自2006年以来,深度学习得到了极大发展.特别是2016年AlphaGo的成功更是大力地加深了深度学习的广泛影响^[29].深度学习在数据处理,特别是大数据处理中在近年来也得到飞速的发展.是否有可能把深度学习的优势发挥到引力波的数据处理中,这是一个非常有趣而且重要的科学问题.目前已有少量的几篇论文涉及这个问题^[30-36].它们的结果是令人鼓舞的.这几篇论文的作者们发现,深度学习方法在引力波数据处理速度和准确度两个方面都是可以传统的匹配滤波方法相比拟的.但哪些因素会影响深度学习方法的引力波数据处理效果,该方法处理引力波数据的置信度如何,如何用深度学习方法寻找理论预期之外的引力波等重要的问题仍需要系统研究.

本文以高斯白噪声和无自旋双黑洞并合引力波^[37]为例子,使用模拟数据对深度学习方法在引力波数据处理问题应用中相关的网络结构、训练数据制备、训练优化、对信号识别的泛化能力、对数据的特征图表示以及对特征数据遮挡的响应等方面展开了讨论.以下的各小结将分别介绍这些方面的初步研究结果.

1 深度学习神经网络的结构

深度学习数据处理是基于一个神经网络工作的.神经网络由网络结构和连接系数等参数两部分构成^[38].网络的结构通常被称为超参数,因为它是在学习或者说数据训练前预先给定的.网络结构的好坏会在很大程度上决定深度学习数据处理的成败.连接系数等参数是通过数据训练、学习确定下来的.

在本工作中只考察卷积神经网络(Convolutional Neural Network, CNN).与深度学习中图像分类问题不同的是,构造CNN的模型的输入数据样本是一维的时序信号,并不是二维的图像像素点阵数据^[36].通过修改神经网络模型内部的构造等以适应对象数据集.输入模型中的训练样本都已经经过了规整的采样,其中每个数据样本中8192个采样点信息看作是图像中单一通道中的特征样本信息,对应于长和宽分别为1和8192个像素点的灰度图像.

CNN通常分为两部分:卷积特征提取部分和全连接的多层感知器(Multilayer Perceptron, MLP).特征提取部分通常是一个多隐藏层结构.每个隐藏层由卷积计算层、非线性激活层和池化层3部分构成.每个特征

提取经隐藏层后输出的数据信息称为该层的特征图^[39].越深的隐藏层经过学习提取到的特征图就会越抽象,描绘着潜藏在数据样本中的深层信息.多层感知器是一种前馈人工神经网络模型,其将输入的多个数据集映射到单一的输出的数据集上.MLP 部分中的神经元层会对学习到的特征图进行分类评估,通过损失函数将给出的判断与样本数据的真实标签之间进行误差比较.本文只简明扼要的概述 CNN 的组成结构,更多关于 CNN 模型的细节可参阅文献[39-41].

CNN 中有很多超参数是需要在训练模型之前确定的.神经网络模型的深度(隐藏层的层数)越深,广度(每个隐藏层的神经元个数)越大,理论上讲这样的网络可以分辨或拟合越复杂抽象的特征信息.现代 CNN 构架中已经出现不少深度超百层的深度神经网络^[42-44].但需要注意到深度越深、广度越大,对网络的训练或者说学习就越困难.使用包含有 3 个卷积隐藏层和 2 个全连接层的 CNN 模型(图 1).图 1 中标注的第 1 个 16 指的是 16 个卷积核,后面的指每个卷积核的大小.设定卷积步长为 1.由于没有额外的数据填充,所以每个卷积核把 8 192 个数据变为 $(8\ 192 - 16) / 1 + 1 = 8\ 177$ 个数据.然后经过 16 个核大小为 16、步长为 2 的池化层,由于没有额外数据填充,8 177 个数据变为 $(8\ 177 - 16) / 2 + 1 = 4\ 081$.第 2 层和第 3 层的卷积和池化类似.在第 3 卷积、池化层后,把数据展平.继而,用全连接层变 64 256 个数据为 64 个数据,再变为 2 个数据.把所得深度神经网络

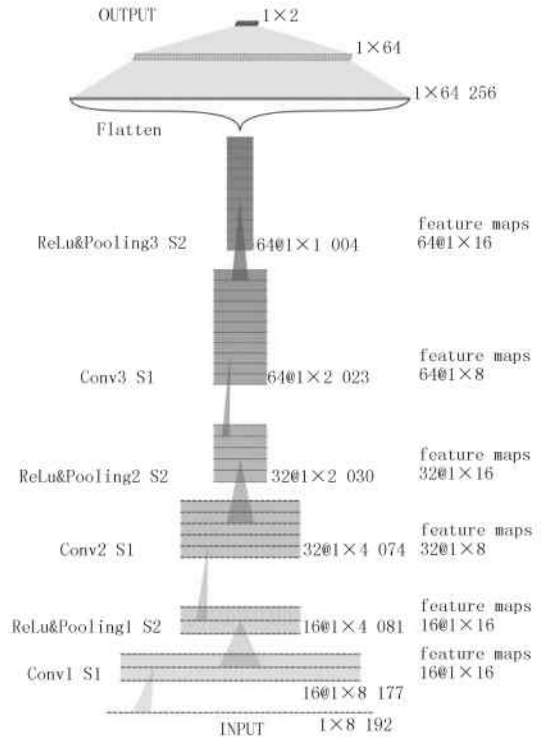


图1 网络结构示意图

网络作为分类器,来判断所关心数据中是否包含引力波信号.经过数据训练学习后,把确定下来的网络用于训练数据集和测试数据集来检验深度神经网络模型的准确率和泛化能力.

卷积计算层是 CNN 模型最核心的线性计算结构,其有着局部相关性、平移不变性、缩放不变性和降维等诸多特性^[45].在图像分类识别中,样本图片的局部特征经过缩放和平移等变换,都可以实现良好的特征提取和识别.因此,在数据集制备和整理的过程中,只考虑物理上关心的引力波范围在 1 s 内的波形.

卷积计算层中也含有需要手动调节的超参数.选定 3 个卷积计算层中的卷积核的个数分别为 16、32 和 64,其表示每层对应输出特征图的数目.再取每层的一维卷积核大小分别为 16、8 和 8.以图像处理为例,卷积的对象是给定的输入图像.在输出图像中每个像素是输入图像中一个小区域中像素的加权平均,其中权值由一个函数定义.这个函数称为卷积核.在卷积计算层中并不使用零填充这个超参数,因为信号采样率足够大,忽略时序信号边缘的采样点并不影响模型对数据样本特征的学习和提取.步长是卷积核滑动时必须指定的另一个超参数.在卷积计算层中步长都取为 1.

神经网络模型的非线性特性是由非线性激活层来体现的,使用非常常用的斜面函数(Ramp),也叫修正线性单元(Rectified Linear Units, ReLU)函数

$$f(x) = \begin{cases} 0, & x < 0, \\ x, & x > 0. \end{cases} \quad (1)$$

它有训练速度快^[46]和在非预训练下性能远优于其他激活函数^[47-48]等诸多优点.

池化层中的下采样操作在 CNN 中是非常重要的^[49].它可以有效降低经过非线性操作后特征表示的维度,同时不同于信号处理中降低信号采样率做法的是,其仍可以保持大部分重要的信息,具有一定程度上的

平移和失真不变性^[50].通常,池化操作有最大化、平均化和随机性等方式.在图像处理领域,最大化池化对纹理提取更好,平均化池化对背景保留更好,随机池化会有更强的泛化能力.由于原始数据的低信噪比特点,会使得引力波波形特征显著地淹没在噪声中,所以为了保证信息最大限度的不损失同时又能提高训练学习的效率,神经网络模型整体采用平均池化操作.通过不同池化方式下模型性能的对比,发现在平均池化下隐藏层对于已学到特征的微小变化具有更优秀的抗噪性,对特征也更加敏感^[50].此外,池化层的滑动核窗口大小会比通常的图像分类问题中稍大一些.因此,选取的池化层核大小为 16,步长为 2.

感受野(Receptive Field)是卷积神经网络中最重要的概念之一.感受野表示输入数据特征空间中某一特定 CNN 层特征图的范围区域.对于一个步长为 1 的卷积计算层而言,其每个特征图在输入数据上的感受范围等于卷积核的覆盖范围.更一般地,假设卷积核大小为 k ,填充大小为 p ,步长大小为 s ,输入层的数据维度为 n_{in} ,跳步为 j_{in} ,感受野为 r_{in} ,记输出层的数据维度为 n_{out} ,跳步为 j_{out} ,感受野为 r_{out} 则有

$$\begin{aligned} n_{out} &= \frac{n_{in} + 2p - k}{s} + 1, \\ j_{out} &= sj_{in}, \\ r_{out} &= r_{in} + (k - 1)j_{in}. \end{aligned} \quad (2)$$

对于整个网络的输入层,自然有 n 等于整个输入数据个数,跳步 j 等于 1,感受野 r 等于 1.由上述递推关系可知,随着神经网络层数的深入,其相应特征图在输入数据上的感受野范围逐渐扩大,可以很快地覆盖整个输入数据.这一点对于 CNN 设计架构的性能提升非常重要.在 CNN 构架的特征提取中,输入模型数据通过 3 层卷积计算、非线性和池化操作后,可以计算得到最后特征图在输入原始数据上的感受野大小是 150.虽然特征提取部分的特征感受野并没有覆盖全部输入时序信号,但是它已足够覆盖引力波波形的最小特征周期.

多层感知器部分的全连接隐藏层是由线性层和非线性激活层两部分构成,其超参数只由线性层的神经元数目这一个维度所决定,选取其为 64 个.值得注意的是,数据在最后的输出层会经过 Softmax 激活函数(s_m ,它把向量映射成向量)

$$y_i = s_m(x_i) = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (3)$$

使得最终输出的是两个类别的概率似然值.

为了研究最简化的卷积神经网络模型结构对引力波波形时序数据的特征提取,模型在构建中并没有使用最近普遍流行的批量归一化(Batch Normalization)层^[51]和丢弃(Dropout)层^[52].它可以显著优化对模型的训练和提升模型的性能.同时,也没有使用空洞卷积(Dilated Convolutions)技术^[53-54].该技术可以做到在不池化损失信息的情况下,使得感受野呈指数级的增加.

2 训练数据集和测试数据集的制备

训练数据集是用来让神经网络进行学习用的数据集.显然,训练数据集将直接影响深度学习方法工作的效果.

为了简化研究,下面将对讨论的问题做出一些假设.首先,取引力波参数空间范围足够小以符合研究的需要.因而考虑不带自旋的双黑洞并合系统所辐射的引力波.引力波探测器探测到的引力波信号

$$h(t) = F^+ h_+(t) + F^\times h_\times(t), \quad (4)$$

其中, $h_{+,\times}$ 是引力波的两个偏振模式, $F^{+\times}$ 是探测器对这两个偏振模式分别的响应函数.假定探测器是理想摆放的,于是有 $F^+ = 1, F^\times = 0$. 即,只考虑“+”偏振模式的引力波波形.使用了有效单体数值相对论(EOB-NR)模型^[37]来模拟引力波信号.

对于一个双黑洞系统而言,其作为引力波波源产生的引力波波形涉及若干个系统参数.除了双星系统中各自的黑洞质量外,每个黑洞都会有 3 个自旋自由度,此外,还有一个描述运动状态的独立自由度是双星系统的轨道偏心率^[12-13,37].为了简化问题的讨论,取双黑洞系统的自旋和轨道偏心率都为零,即此时双黑洞系统的参数只有两个,它们分别代表两个黑洞各自的质量.同时,针对 LIGO 型引力波探测器进一步要求讨论

的双黑洞系统是由对应于质量为 $4M_{\text{sun}} \sim 75M_{\text{sun}}$ (M_{sun} , 太阳质量) 的两个黑洞形成的. 引力波波形也将统一的处理为 LIGO 探测相关的从旋进后期到铃震基本结束的 1 s 时间范围内. 图 2 就是以采样率为 8 192 Hz 的引力波波形实例. 其中纵轴已经被做了某种归一化. 因为只关心 1 s 持续时间的引力波信号, 所以对数据量为 8 192 个数据点.

把特定双黑洞系统的引力波波形与模拟的高斯白噪声叠加, 经过整理成为有监督标签的数据集. 在构造训练集数据的过程中, 取双黑洞系统中的一个黑洞质量为 $m_1 = 5M_{\text{sun}}, 7M_{\text{sun}}, 9M_{\text{sun}}, \dots, 75M_{\text{sun}}$; 另一个系统参数根据双黑洞系统的质量比 $q = \frac{m_2}{m_1}$ 从 1 到 10 间隔 0.1 采样, 并在 $5M_{\text{sun}} \sim 75M_{\text{sun}}$ 之间取值得到另一个黑洞质量 m_2 . 共计产生 704 个引力波形. 类似地, 为了构造测试数据集取 $m_1 = 4M_{\text{sun}}, 6M_{\text{sun}}, 8M_{\text{sun}}, \dots, 74M_{\text{sun}}$, 也共计产生 748 个引力波形. 这 1 440 个引力波形所对应的双黑洞质量参数分布如图 3 所示. 然后, 保持由此分别生成的 704 和 748 个引力波波形的相对振幅, 在其中每一个波形上分别加入 10 组模拟高斯白噪声得到 7 040 个训练数据和 7 480 个测试数据. 为了保证训练数据集在训练过程中可以平衡的学习到样本的标识信息, 再分别模拟了 7 040 和 7 480 个不含引力波信号的纯高斯白噪声数据加入到训练集中. 这样一共得到 14 080 个训练样本和 14 960 个测试样本. 最后, 将训练数据的 14 080 个样本的顺序随机打乱. 这样就完成了制备输入到神经网络模型的训练数据集和测试数据集. 图 4 就是训练数据集中信噪比 S_{NR} 为 0.316 的一个样本数据. 注意这里信噪比的定义不同于引力波数据处理中匹配滤波信噪比的定义^[13]. 本文的信噪比定义

$$S_{\text{NR}} = \sqrt{\frac{\sigma_{\text{signal}}}{\sigma_{\text{noise}}}},$$

$$\sigma = \frac{1}{N} \sum_i (x_i - \bar{x})^2, \quad (5)$$

$$\bar{x} = \frac{1}{N} \sum_i x_i.$$

注意这里定义的信噪比与目前引力波数据处理中用的匹配滤波信噪比 (matched signal to noise ratio) 是不同的^[1, 12-13, 37]. 训练数据集和测试数据集包含引力波信号部分信噪比的分布如图 5 所示.




图2 $5M_{\text{sun}} + 5M_{\text{sun}}$ 双黑洞系统合并所辐射引力波的波形图




图3 704个训练数据引力波信号与748个测试数据引力波信号所对应的双黑洞质量分布

3 对神经网络的训练、学习和优化

在深度学习中, 神经网络的训练学习过程就是对大量带标签数据 (监督学习) 通过反向传播算法学习网络结构中的参数. 输入数据在已初始化模型参数 (通常使用高斯分布来随机初始化网络结构中待学习参数) 的卷积神经网络中前向传播, 最后会得到一个期望输出. 这个期望输出与数据真实类别标签的误差是由损失函数来描述. 比如损失函数经常用均方误差来定义:

$$C_e = \sum_i \frac{1}{2} (y_i - \hat{y}_i)^2, \quad (6)$$

其中, \hat{y} 是期望输出, 对应于样本的真实标签, y 是实际输出, 对应于最后输出层的激活值. 损失函数关于模型参数的负梯度方向对应于模型误差的降低. 在优化过程中, 误差会在网络中逐层地反向传播到各层的待学习参数, 每层的神经元会根据该误差对网络结构中的参数进行更新, 使得模型在每次迭代学习时都使用新的模型参数来让误差逐渐收敛于最小. 对于卷积神经网络而言, 待学习的参数包括卷积核权重参数、全连接层间的连接权重参数以及各层的偏置等. 训练好的模型只需要将所关心数据样本输入模型正向传播一次, 就能够计算出输入数据所对应的预测类别, 从而完成 CNN 的分类识别任务.




图4 蓝线为训练数据集中一个信噪比为0.316的样本, 橙线为该样本所包含的引力波信号




图5 训练数据集和测试数据集包含引力波信号部分信噪比的分布

训练一个模型的主要目的是让模型通过学习得到合适的参数, 即实现输入数据到给出最终预测之间的最优映射. 为了优化模型训练的效率, 将 64 个数据样本整合在一起, 小批量地输入给网络. 以此批量方式迭代更新模型参数. 在模型的分训练过程中, 使用交叉熵损失函数 (cross entropy loss function)

$$C = \frac{1}{N} \sum_i [\hat{y}_i \ln y_i + (1 - \hat{y}_i) \ln(1 - y_i)] \tag{7}$$

来衡量模型预测样本的标签与真实标签之间的误差, 然后, 利用反向传播算法^[55] 和小批量随机梯度下降 (SGD) 算法^[56], 通过模型反复迭代学习并更新卷积神经网络模型中的参数, 使损失函数的值逐渐逼近最小值. 在 SGD 优化算法中, 学习率是模型调参过程中非常重要的超参数. 在本文使用的模型版本中, 把学习率设置为 0.000 1.

在开源的 MXNet^[57] 深度学习框架中训练卷积神经网络模型, 并在 FloydHub 提供的云 GPU 平台^[58] 上完成了所有的训练和调参过程. 如图 6 所示, 在每一次小批量输入数据到模型中学习后, 损失函数会向着逐渐减小的方向变化. 图 6 中损失函数的震荡波动是由于训练数据是小批量的方式送入网络模型中学习的. 如果每次更新学习时都用全部训练数据集样本, 一次性地交给模型训练, 损失值的震荡就会变小, 因为每个梯度更新都是单调地优化整个训练集对应的损失函数 (除非学习率设置得过高) 而不是小批量集对应的损失函数. 所以, 跟踪当前模型的损失函数可以直观理解不同超参数设置下的效果, 从而知道如何修改超参数以获得更高效的学习过程.

在训练模型的过程中, 对比模型在训练数据集和测试数据集上准确率表现可以知道模型过拟合的程度. 把训练数据集小批量一小批量地送入网络, 直到把所有训练数据集送完, 称之为一个周期. 接下来将重复地把训练数据集小批量一小批量地送入网络学习. 如图 7 所示, 横轴对应的每个点衡量了在训练中每个样本数据都被观察过一次后的期望 (一个周期意味着每个样本数据都被观察过了一次). 从图 7 可以知在训练周期约 45 次以后, 模型在训练集和测试集上的准确率都逐渐收敛于 0.9 以上, 说明模型表现出不错的泛化能力. 值得一提的是, 初始化的模型参数会对每次训练过程中的收敛表现有很大的影响. 这里显示出来的结果是在尝试的若干随机初始参数中找出表现最好的一个. 虽然目前还没有一个好的方法来直接确定初始参数, 但是可以通过迁移学习 (Transfer Learning), 将更容易收敛的高信噪比信号下分类训练的模型参数迁移到低信噪比的深度学习中, 作为其模型训练的初始参数.




图6 在每一次小批量输入数据后的损失函数




图7 模型分别对训练数据集和测试数据集预测引力波信号的准确率随着学习过程的演化行为

4 深度学习对信号识别的泛化能力

卷积神经网络所具有的强大泛化能力,体现为神经网络识别训练样本以外的样本集合的能力,由此实现引力波探测模板以外的引力波信号.在上一节中,通过有别于训练样本引力波波形的测试样本数据来验证模型的泛化能力.目前,神经网络模型泛化能力的成因还没有在理论上达成一致性的认识,影响网络泛化能力的因素包括模型结构复杂性、样本复杂性、样本质量、初始参数权值和学习时间等方面.为了进一步研究模型的泛化能力,制备了不同信噪比的测试数据集,考察已训练好模型对于不同信噪比的数据样本的准确率.这里的信噪比指的是图5所示的最可几信噪比.通过增大减小噪声信号幅度的方式来改变信噪比,所以信噪比的分布样子不会变,只是沿图5的横轴左右平移.同样地,还是把最可几信噪比记为 S_{NRM} .模型预测准确性随着信噪比的变化如图8所示.




图8 不同信噪比预测数据的卷积神经网络模型分类准确率

5 深度学习对数据的特征图 (Feature Map) 表示

匹配滤波方法识别强噪声下的弱引力波信号靠的是寻找数据中与理论模板一致的部分数据特征.如果想在没有理论模板的情况下也辨别出弱信号来,那么就需要数据处理方法能分辨噪声部分数据与信号数据部分不同的特征.针对这个问题,理解神经网络对数据特征的分辨能力是有趣和重要的问题.

在卷积神经网络中,特征的提取和分类识别都是自动学习的.深度神经网络工作原理的可解释性问题至今仍是未解决^[59].对卷积神经网络可解释性研究^[60]不仅会对神经网络效率的保证,以及模型性能的提升是有必要的,也可以对训练数据中与标签相关的潜在特征有更加深入的理解.

可视化是最常用也是最直接的一种理解卷积神经网络的手段.例如在计算机视觉领域中,第一卷积计算层的权重可视化是很有帮助的,从中可以查看权重特征图像是否清晰平滑等来分析网络是否已经收敛.然而,在卷积网络模型中,首层的权重参数都是单通道长度为16的一维序列数据,所以很难从中分析给出有参考价值的信息.


在卷积神经网络里,中间卷积层特征图的可视化有助于更好地理解深度网络内部机理,进一步了解一个

训练好的神经网络究竟在各个卷积层中学习到了怎样的特征.此外,特征图的讨论会对原始数据有更好的理解.文献[61]提出了联系特征图与原图像之间关系的可视化方法.由于数据在卷积神经网络前向传播的过程中会保持数据的空间结构,即每层的特征图与原始时序信号数据具有在空间上的对应关系,其中具体对应的位置及大小可以通过卷积计算层的感受野来度量.而神经网络每次迭代更新是通过后向传播来训练的.所以,关于特征图的可视化可以有两种途径:1)正向可视化方法.前向计算,即直接把每一层的特征图显示出来.每个特征图都对应隐藏层上的一个有序节点,对应于原时序信号数据中的某一位置处激活了该节点特征.随着网络深度的增加,特征图会变得越来越稀疏,这相当于是对原数据降噪和深度提取.但是经过逐层卷积计算和池化后,特征图会越来越抽象,其维度也会逐渐降低.这将会导致很难从中理解相应特征图在对应的节点处从原始数据中学习到了怎样的特征.但尽管如此,激活后最显著的特征图通常与样本的识别特征是强相关的.2)逆向可视化方法.根据神经网络的最后一层中最显著的激活特征图进行反向计算,再利用卷积层的感受野得到原始输入数据中的区域,由此得到输入数据时间坐标下的特征可视化图像,从中可以进一步看出输入时序信号数据的哪些特征区域激活了神经网络,从而理解该特征图从原数据中学习了何种特征.在图像识别领域中,该种途径可以对图像做物体定位等^[62-64].

5.1 正向可视化方法


与传统的特征可视化相区别的是,待训练的低信噪比时序信号数据是通过模拟生成的.如图 4 所示,用理论模型 EOBNR^[37]生成的纯引力波特征信号作为训练数据中的完备特征信息作为指导,通过对比纯白噪声背景数据以及引力波信号与噪声的混合模拟时序数据(信噪比大约为 0.5),分别观察卷积神经网络是如何经过特征提取给出正确的分类的,同时查看它们在各个隐藏层下的特征图表现.

将纯引力波信号、纯白噪声以及将其二者混合后的时序数据作为对照样本,送入已训练好的 CNN 卷积神经网络中,可以得到 3 个卷积层的特征图.第 1 卷积层的特征图对比如图 9~11 所示.第 2 卷积层的特征图对比如图 12~14 所示.第 3 卷积层的特征图对比如图 15~17 所示.




横轴为神经元编号, 纵轴为神经元输出信号

图9 纯引力波信号在卷积神经网络第1层的16个特征图



横轴为神经元编号, 纵轴为神经元输出信号

图10 纯噪声在卷积神经网络第1层的16个特征图



横轴为神经元编号, 纵轴为神经元输出信号

图11 引力波信号和噪声的叠加数据在卷积神经网络第1层的16个特征图

第 1 卷积层的特征图是直接原数据样本中映射而来.从纯引力波信号的特征图(图 9)中可以明显发现特征是非常规律且平滑的,空间方向上的特点与原引力波波形的特点接近.但是,通过观察低信噪比(信噪比大约为 0.5)的混合数据可见噪声的影响对特征图(图 11)的影响非常大,与纯噪声情况的特征图(图 10)几乎看不出差别,很难从第 1 卷积层的特征图 10 中区分出是否含有引力波.

随着网络深度的递增,每层特征图的表达越来越抽象,各层经过激活的特征图表现也越来越稀疏,差异也越来越大.虽然低信噪比数据的特征使得混合数据的特征图表达非常不平滑,但是通过对比纯引力波信号、纯噪声数据和混合数据对应的特征图可知:在较深的卷积隐藏层中,部分特征图可以用来区分输入数据是否包含有引力波信号,比如在第 3 层的 64 个特征图(图 15~17)中,第 2 行左起第 9 个特征图在有引力波

信号情况下(图 15)激活强度比较强,但是在纯噪声情况下(图 16)表现较弱.在全连接感知层之前,将第 3 卷积隐藏层的 64 个特征图平展开,可以分别绘制得到 3 种不同输入数据在尺度大小和对应节点之间的对比关系(图 18).不同输入模型数据在特征提取的最后层中,其所对应的特征图在各节点的稀疏程度基本一致.




图12 纯引力波信号在卷积神经网络第2层的32个特征图




图13 纯噪声数据在卷积神经网络第2层的32个特征图




图14 引力波信号和噪声的叠加数据在卷积神经网络第2层的32个特征图

在卷积神经网络模型中,训练过的全连接感知层会根据输入的特征数据信息,给出分类预测的得分(见表 1).在最后,该得分会经过 Softmax 激活函数处理为具有一定“概率”意义的结果.神经网络对纯引力波特征信号的分类给出了最肯定的得分,分差超过 20.判断纯噪声数据中不含有引力波信息也非常的肯定(Softmax 函数的概率超过了 99.9%认为其中不存在引力波).含引力波信息的混合模拟信号输入卷积神经网络模型后,对错误分类类别直接给出了负分的得分判断,最终模型预测此低信噪比的时序信号中存在引力波.

表 1 纯引力波、纯噪声以及混合数据 3 种不同时序输入数据下,神经网络最后给出的得分表达 (Softmax 概率)

输入数据	存在引力波		不存在引力波	
	得分	Softmax 概率	得分	Softmax 概率
纯引力波	12	1	-12	0
纯噪声	-5	0.000 1	5	0.999 9
混合数据	1	0.92	-1	0.08

5.2 逆向可视化方法

在特征图的可视化研究中,除了直接观察各个卷积隐藏层的特征图外,还可以对激活最显著的节点特征进行反向传播.通过反池化和转置卷积操作并且利用已训练好的模型参数,将特征图映射回到输入数据空间的时序坐标中,进而可以帮助理解卷积神经网络究竟是根据哪些特征给出分类判断.对第 3 层最显著特征节点(图 15~17 中第 2 行左起第 9 个特征图)进行了转置卷积操作,结果如图 19 所示.从图 19 中可以看到,在不同的数据样本下,该特征节点反向可视化上的表现差异很大.在纯引力波输入情况下,该特征节点可以描

述引力波的特征信息,二者在时间坐标上表现出了相同的波形震荡周期规律.在纯噪声和混合数据情况下,反向可视化的结果显示出噪声的特点来.




图15 纯引力波信号在卷积神经网络第3层的64个特征图




图16 纯噪声数据在卷积神经网络第3层的64个特征图




图17 引力波信号和噪声的叠加数据在卷积神经网络第3层的64个特征图

6 深度学习对特征数据遮挡的响应

面对输入的数据,一个有趣的问题是卷积神经网络是主要根据数据样本中的哪一部分数据实现的分类判断呢?在考虑的引力波波形中,是旋进部分重要,还是双黑洞合并和铃震的部分重要?通过数据样本的部分遮挡来考察这个问题.被遮挡的部分将会替换为原一维时序数据平均值,并在整个时间坐标范围内平滑移动,考察不同遮挡位置下的卷积神经网络对测试数据的分类能力.经过对数据采样点的不同遮挡尝试之后,发现遮挡区域在整个时间坐标上不同位置处的大小越小,模型会表现趋于平滑.把测试结果画在了图 20 中.

遮罩宽度取 600 个采样点,当遮罩处于第 7 200~7 800 采样点处时,神经网络对混合数据(图 20 中蓝色曲线所示)给出了明显不同的判断结果,说明这部分数据对模型的分辨能力影响最大.此处被遮挡的部分对应于引力波双黑洞旋进后期部分的波形.神经网络对数据识别的这个特点有一个潜在的用处.在未来的引力波探测实验中,由于探测精度的提高,很可能一段数据中包含着不止一个引力波信号.可以用这种遮挡的方式来判断信号的个数.如果随着遮挡的移动判断概率没什么变化,那说明数据中一定包含着不止一个引力波信号;反之则说明只有一个信号.

7 小结和展望

引力波的成功探测不但完成了广义相对论实验检验的最后一块拼图,而且还打开了引力波天文学这扇观测天体和宇宙的全新窗户^[14].同时它还将可能改变引力物理学研究的格局.在引力波实验以前,由于其他的引力实验只能涉及较为弱引力场和低速的物理情形,以后牛顿参数衡量,相应参数小于甚至更小.而引力波探测对应的引力波源相应的参数在 1 的量级,是典型的强引力场强动态时空区域.引力物理学研究探讨的是广义相对论适用边界何在,失效后应该变成什么理论的问题.量子引力是该研究领域典型的科学问题.在引力波探测之前,由于没有实验可供参考,人们只能利用理论推理的方式工作.随着引力波探测数据的增多,人们有可能会像对待别的物理问题一样,由实验结果指引人们思考问题的方向.可以想象,那样的话引力物理的研究方式将被极大地改变^[65].

在目前的引力波数据处理中,匹配率波方法占据了绝对的位置.不论是引力波信号的辨认还是波源参数的反演,都离不开

匹配率波方法.而匹配滤波方法工作的前提是准确完备的理论模板.粗略地说,这样的情况使得引力波探测只能测到完全在理论预言范围内的引力波.这限制了利用引力波探测发现完全未知事物的能力和可能.

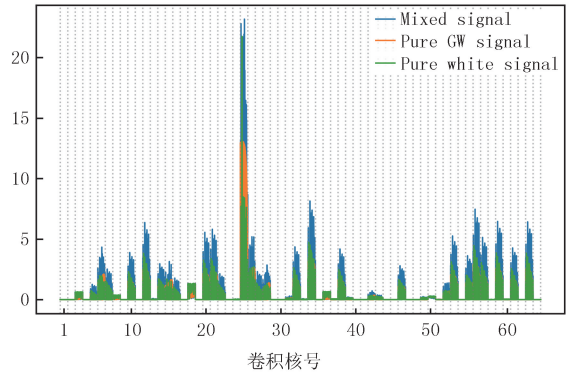


图18 纯引力波、纯噪声以及混合数据分别在卷积神经网络第三层平展开的特征图




图19 蓝色曲线表示的是最显著节点特征经过反向计算返回到时间坐标上的可视化数据.紫色曲线绘制的是相应输入数据.从上到下分别对应输入数据是纯引力波、纯噪声和混合数据的情况




图20 紫色线表示的是宽度为600个采样点的遮罩处于不同位置处时,混合数据在卷积神经网络中判断信号含有引力波波形的概率

近年来深度学习数据处理方法得到极大发展,在数据处理的高效性和高迁移性方面表现突出.深度学习数据处理方法的高效性有希望进一步提高引力波的探测能力,把传统匹配滤波方法辨认不出的或者置信度不够的引力波信号(如 LVT151012)识别出来.其高迁移性有可能让人们使用广义相对论构造的理论模板训练的神经网络发现超越广义相对论理论描述的引力波信号.这样引力波探测将实实在在地把引力物理变成实验主导的学科.

当然,深度学习方法在引力波数据处理中的应用研究目前还很少,更谈不上系统研究.本文作为这个问题的尝试性探索,引入了这个问题,并且在相关的网络结构、训练数据制备、训练优化、对信号识别的泛化能力、对数据的特征图表示以及对特征数据遮挡的响应等方面给出了粗略讨论.以后的工作将继续围绕这些问题进行深入、系统地研究.

参 考 文 献

- [1] Abbott B P, Abbott R, Abbott T D, et al. Observation of Gravitational Waves from a Binary Black Hole Merger[J]. *Phys Rev Lett*, 2016, 116(6):061102.
- [2] Abbott B P, Abbott R, Abbott T D, et al. GW151226: Observation of Gravitational Waves from a 22-Solar-Mass Binary Black Hole Coalescence[J]. *Phys Rev Lett*, 2016, 116(24):241103.
- [3] Abbott B P, Abbott R, Abbott T D, et al. GW170608: Observation of a 19 Solar-mass Binary Black Hole Coalescence[J]. *Ap J*, 2017, 851: L35.
- [4] Abbott B P, Abbott R, Abbott T D, et al. GW170104: Observation of a 50-Solar-Mass Binary Black Hole Coalescence at Redshift 0.2[J]. *Phys Rev Lett*, 2017, 118(22):221101.
- [5] Abbott B P, Abbott R, Abbott T D, et al. GW170814: A Three-Detector Observation of Gravitational Waves from a Binary Black Hole Coalescence[J]. *Phys Rev Lett*, 2017, 119(14):141101.
- [6] Collaboration V. GW170817: Observation of Gravitational Waves from a Binary Neutron Star Inspiral[J]. *Phys Rev Lett*, 2017, 119(16): 161101.
- [7] Collaboration V. GW150914: First results from the search for binary black hole coalescence with Advanced LIGO[J]. *Phys Rev D*, 2016, 93:122003.
- [8] Gibney E. Successful test drive for space-based gravitational-wave detector[J]. *Nature*, 2016, 531(7592):20.
- [9] Gong X, Xu S, Bai S, et al. A scientific case study of an advanced LISA mission[J]. *Classical & Quantum Gravity*, 2011, 28(9):192-198.
- [10] David B, Li J U, Zhao C N, et al. Gravitational wave astronomy: the current status[J]. *Science China Physics Mechanics & Astronomy*, 2015, 58(12):120402.
- [11] Luo J, Chen L S, Duan H Z, et al. TianQin: a space-borne gravitational wave detector[J]. *Classical & Quantum Gravity*, 2015, 33(3): 035010.
- [12] 蔡荣根, 曹周键, 韩文标. 合并双星系统的引力波理论模型[J]. *科学通报*, 2016, 61(14):1525-1535.
- [13] 曹周键, 都志辉. 数值相对论与引力波天文学[J]. *中国科学:物理学 力学 天文学*, 2017, 47(1):60-77.
- [14] CAI Ronggen, CAO Zhoujian, GUO Zongkuan, et al. The gravitational-wave physics[J]. *National Science Review*, 2017, 4(5):687-706.
- [15] PRETORIUS F. Evolution of binary black-hole spacetimes.[J]. *Phys Rev Lett*, 2005, 95(12):121101.
- [16] BAKER J G, CENTRELLA J, CHOI D I, et al. Gravitational-wave extraction from an inspiraling configuration of merging black holes[J]. *Phys Rev Lett*, 2006, 96(11):111102.
- [17] CAMPANELLI M, LOUSTO C O, MARRONETTI P, et al. Accurate evolutions of orbiting black-hole binaries without excision[J]. *Phys Rev Lett*, 2006, 96(11):111101.
- [18] BRUEGMANN B, GONZALEZ J A, HANNAM M, et al. Calibration of moving puncture simulations[J]. *Phys Rev D*, 2008, 77:024027.
- [19] YAMAMOTO T, SHIBATA M, TANIGUCHI K. Simulating coalescing compact binaries by a new code *sacra*[J]. *Phys Rev D*, 78: 064054.
- [20] CAO Z J, YO H J, YU J P. Reinvestigation of moving punctured black holes with a new code[J]. *Phys Rev D*, 2008, 78:124011.
- [21] 曹周键. 基于爱因斯坦方程的相对论性天体模拟软件: 2015SR047789[P]. 2015-03-18.
- [22] 曹周键. 从引力波探测到包含引力波的多信使天文学[Z]. *大学物理*, 2018(出版中).
- [23] Ezquiaga J M, Zumalacárregui M. Dark Energy After GW170817: Dead Ends and the Road Ahead[J]. *Phys Rev Lett*, 2017, 119:251304.
- [24] Sakstein J, Jain B. Implications of the Neutron Star Merger GW170817 for Cosmological Scalar-Tensor Theories[J]. *Phys Rev Lett*, 2017, 119(25): 251303.
- [25] Creminelli P, Vernizzi F. Dark energy after GW170817 and GRB170817A[J]. *Phys Rev Lett*, 2017, 119(25):251302.
- [26] Baker T, Bellini E, Ferreira P, et al. Strong Constraints on Cosmological Gravity from GW170817 and GRB 170817A[J]. *Phys Rev Lett*,

- 2017,119(25): 251301.
- [27] Vincent P, Larochelle H, Bengio Y, et al. Extracting and composing robust features with denoising autoencoders[C]//International Conference on Machine Learning. [S.l.]: ACM, 2008: 1096-1103.
- [28] Arbib M A. The Handbook of Brain Theory and Neural Networks[M]. Cambridge: MIT Press, 1998: 255-258.
- [29] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search.[J]. Nature, 2016, 529(7587): 484.
- [30] George D, Huerta E A. Deep Neural Networks to Enable Real-time Multimessenger Astrophysics[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1701.00008>.
- [31] George D, Shen H, Huerta E A. Deep Transfer Learning: A new deep learning glitch classification method for advanced LIGO[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1706.07446>.
- [32] George D, Huerta E A. Deep Learning for Real-time Gravitational Wave Detection and Parameter Estimation: Results with Advanced LIGO Data[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1711.03121>.
- [33] George D, Shen H, Huerta E A. Glitch Classification and Clustering for LIGO with Deep Transfer Learning[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1711.07468>.
- [34] George D, Huerta E A. Deep Learning for Real-time Gravitational Wave Detection and Parameter Estimation: Results with Advanced LIGO Data[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1711.07966>.
- [35] Shen H, George D, Huerta E A, et al. Denoising Gravitational Waves using Deep Learning with Recurrent Denoising Autoencoders[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1711.09919>.
- [36] Li X, Yu W, Fan X. A Method Of Detecting Gravitational Wave Based On Time-frequency Analysis And Convolutional Neural Networks[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1712.00356>.
- [37] Cao Z, Han W B. Waveform model for an eccentric binary black hole based on the effective-one-body-numerical-relativity formalism[J]. Phys Rev D, 2017; 96: 044028.
- [38] Chen Y, Cao Z, Wang S, et al. Self-organized correlations lead to explosive synchronization[J]. Physical Review E Statistical Nonlinear & Soft Matter Physics, 2015, 91(2): 022810.
- [39] Dahl J V, Koch K C, Kleinhans E, et al. Convolutional networks and applications in vision[C]//IEEE International Symposium on Circuits and Systems. Piscataway: IEEE Press, 2010: 253-256.
- [40] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [41] Dumoulin V, Visin F. A guide to convolution arithmetic for deep learning[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1603.07285>.
- [42] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//IEEE Conference on Computer Vision and Pattern Recognition. Washington DC: IEEE Computer Society, 2015: 1-9.
- [43] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1409.1556>.
- [44] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1512.03385>.
- [45] Goodfellow I, Bengio Y, Courville A. Deep Learning[M]. Cambridge: MIT Press, 2016.
- [46] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[C]//International Conference on Neural Information Processing Systems. [S.l.]: Curran Associates Inc, 2012: 1097-1105.
- [47] Glorot X, Bordes A, Bengio Y. Deep Sparse Rectifier Neural Networks[J]. Jmlr W & Cp, 2011, 15: 315-323.
- [48] Jarrett K, Kavukcuoglu K, Ranzato M, et al. What is the best multi-stage architecture for object recognition? [C]//International Conference on Computer Vision. Piscataway: IEEE Press, 2010: 2146-2153.
- [49] Baldi P, Sadowski P, Whiteson D. Searching for exotic particles in high-energy physics with deep learning[J]. Nature Communications, 2014, 5(5): 4308.
- [50] Lecun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [51] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//International Conference on International Conference on Machine Learning. [S.l.]: JMLR, 2015: 448-456.
- [52] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: a simple way to prevent neural networks from overfitting[J]. Journal of Machine Learning Research, 2014, 15(1): 1929-1958.
- [53] Yu F, Koltun V. Multi-Scale Context Aggregation by Dilated Convolutions[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1511.07122>.
- [54] Yu F, Koltun V, Funkhouser T. Dilated Residual Networks[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1705.09914>.
- [55] Schmidhuber J. Deep Learning in neural networks; An overview[J]. Neural Networks, 2015, 61: 85.
- [56] Ruder S. An overview of gradient descent optimization algorithms[EB/OL]. [2018-01-16]. <https://arxiv.org/abs/1609.04747>.
- [57] Chen T, Li M, Li Y, et al. MXNet: A Flexible and Efficient Machine Learning Library for Heterogeneous Distributed Systems[EB/OL].

- [2018-01-16].<https://arxiv.org/abs/1512.01274>.
- [58] 云 GPU 平台[EB/OL].[2018-01-16].<https://www.floydhub.com>.
- [59] Vidal R, Bruna J, Giryes R, et al. Mathematics of Deep Learning[EB/OL].[2018-01-16].<https://arxiv.org/abs/1712.04741>.
- [60] Bau D, Zhou B, Khosla A, et al. Network Dissection: Quantifying Interpretability of Deep Visual Representations[EB/OL].[2018-01-16].<https://arxiv.org/abs/1704.05796>.
- [61] Zeiler M D, Fergus R. Visualizing and Understanding Convolutional Networks[EB/OL].[2018-01-16].<https://arxiv.org/abs/1311.2901>.
- [62] Ren S, He K, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[C]//International Conference on Neural Information Processing Systems. Cambridge: MIT Press, 2015: 91-99.
- [63] Dai J, Li Y, He K, et al. R-FCN: Object Detection via Region-based Fully Convolutional Networks[EB/OL].[2018-01-16].<https://arxiv.org/abs/1605.06409>.
- [64] Liu W, Anguelov D, Erhan D, et al. SSD: Single Shot MultiBox Detector[M]//Computer Vision - ECCV 2016. Springer International Publishing, 2016: 21-37.
- [65] Cao Z J. Gravitational wave astronomy: chance and challenge to fundamental physics and astrophysics[J]. Science China Physics Mechanics & Astronomy, 2016, 59(11): 110431.

Initial study on the application of deep learning to the Gravitational Wave data analysis

Cao Zhoujian^a, Wang He^b, Zhu Jianyang^b

(a. Department of Astronomy; b. Department of Physics, Beijing Normal University, Beijing 100875, China)

Abstract: Till 2018-01-16, LIGO has successfully detected 6 gravitational wave events. It is expected that there will be more and more gravitational wave events be detected, and the gravitational wave astronomy will quickly start its big data phase. Deep learning has developed rapidly in recent years especially on big data processing. It has shown great advantages in the speed of data processing, accuracy and so on. There is few discussion about the application of deep learning to gravitational wave data analysis. On the one hand, the current article will introduce this problem. On the other hand, we will give a preliminary exploration of this problem. The most outstanding character of gravitational wave data is weak signal hided in strong noise. The current method of gravitational wave data analysis is using the matched filtering to excavate the gravitational wave signal from the strong noise. At the same time, the properties of the gravitational wave source can be determined by the matched filtering method, and the parameters of the source can be determined quantitatively. The weakness of the matched filtering method is that the amount of computation cost is huge and the speed of data processing is slow. In the face of future big data gravitational wave astronomy, this will be a great hidden challenge. Another potential problem of the matched filtering method is that a complete and accurate theoretical waveform template is a prerequisite making sure the matched filtering technique works. The consequence of this potential problem is that it is difficult for us to find the gravitational wave signals which is out of theoretical expectation. The data processing methods of deep learning can provide a way for solving these problems. At the same time, deep learning will encounter some of its own difficulties and problems. This article will discuss the aspects of network structure, training data preparation, training optimization, generalization ability of signal recognition, representation of data character and response to feature data occlusion.

Keywords: gravitational wave astronomy; matched filtering method; deep learning; numerical relativity; gravitational waveform template

[责任编辑 杨浦]