



(12) 发明专利

(10) 授权公告号 CN 115169407 B

(45) 授权公告日 2023.04.18

(21) 申请号 202210840015.3

G06F 18/10 (2023.01)

(22) 申请日 2022.07.18

G06F 18/213 (2023.01)

(65) 同一申请的已公布的文献号

G06N 3/0464 (2023.01)

申请公布号 CN 115169407 A

G06N 3/09 (2023.01)

(43) 申请公布日 2022.10.11

(56) 对比文件

(73) 专利权人 中国科学院国家空间科学中心

CN 106840670 A, 2017.06.13

地址 100190 北京市海淀区中关村南二条1号

CN 113780106 A, 2021.12.10

CN 114638256 A, 2022.06.17

WO 2022120665 A1, 2022.06.16

(72) 发明人 牛文龙 高伟华 王鹏程 郭颖颐 彭晓东 郑伟 杨震

审查员 曾贞

(74) 专利代理机构 北京方安思达知识产权代理有限公司 11472

专利代理师 武玥 张红生

(51) Int. Cl.

G06F 18/24 (2023.01)

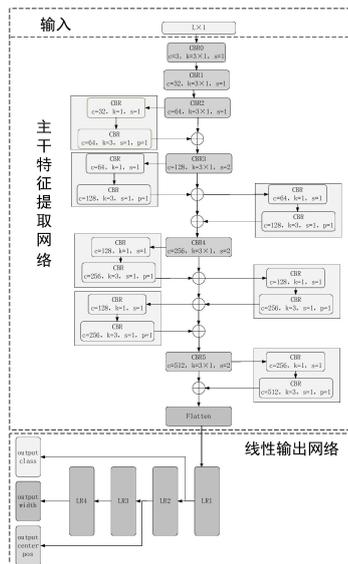
权利要求书4页 说明书8页 附图4页

(54) 发明名称

基于时域深度特征学习的微弱瞬态信号检测方法

(57) 摘要

本发明公开了基于时域深度特征学习的微弱瞬态信号检测方法... 该方法包括：将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模型... 同时输出该微弱瞬态信号在时域上的位置信息... 所述微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络... 本发明通过预处理，提高信号的信噪比，降低检测难度；通过在真实数据集中补充仿真数据，扩大一维时序信号数据集规模，显著提高了检测效果，具有更好的鲁棒性；通过多任务学习，输出信号的类别与位置，可以有效防止特征的丢失，并具备微弱瞬态信号定位能力。



1. 基于时域深度特征学习的微弱瞬态信号检测方法,所述方法包括:

将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模型,通过该微弱瞬态信号检测模型判断输入的一维时序信号中是否存在微弱瞬态信号,同时输出该微弱瞬态信号在时域上的位置信息,实现微弱瞬态信号判别和时域信息定位;

所述微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络;

所述一维深度残差网络包括依次连接的主干特征提取网络和线性输出网络;其中,

所述主干特征提取网络包括依次连接的20个CBR模块和7次残差连接,每个CBR模块,用于进一步提取瞬态信号的特征,包括一个一维卷积层Conv1D、一个批标准化层Batch Normalization和一个激活层ReLU;每个残差连接,用于防止微弱瞬态信号特征的丢失;在输入数据进入一维深度残差网络后,先由前两个CBR模块,即CBR0模块和CBR1模块提取浅层特征,再将CBR1模块的输出特征输入CBR2模块中;得到CBR2模块的输出特征后,开展第一次残差连接,具体结构为:将CBR2的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR2模块的输出特征相加,得到第一次残差连接的结果并输入CBR3模块中,开展第二次残差连接,具体结构为:将CBR3模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR3模块的输出特征相加,得到第二次残差连接的结果并开展第三次残差连接,具体结构为:将第二次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第二次残差连接的结果相加,得到第三次残差连接的结果并输入CBR4模块中,开展第四次残差连接,具体结构为:将CBR4模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR4模块的输出特征相加,得到第四次残差连接的结果并开展第五次残差连接,具体结构为:将第四次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第四次残差连接的结果相加,得到第五次残差连接的结果并开展第六次残差连接,具体结构为:将第五次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第五次残差连接的结果相加,得到第六次残差连接的结果并输入CBR5模块中,开展第七次残差连接,具体结构为:将CBR5模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR5模块的输出特征相加,得到第七次残差连接的结果并进行平坦化处理得到一维特征向量;

所述线性输出网络包括4个LR模块:即LR1模块、LR2模块和LR3模块和LR4模块,以及3个输出层:即output\_class层、output\_width层和output\_center\_pos层;每个LR模块用于对提取到的特征信息进行学习,为输出层提供更高维的特征,每个LR模块包括一个线性层Linear和一个激活层ReLU;每个输出层包括一个线性层和一个激活层;主干特征提取网络输出的一维特征向量输入LR1模块中,得到的输出特征同时输入LR2模块和output\_class层,经output\_class层处理后输出类别;将LR2模块的输出特征同时输入LR3模块和output\_center\_pos层,经output\_center\_pos层处理后输出微弱瞬态信号中心点;将LR3模块的输出特征经LR4模块输入output\_width层,经output\_width层处理后输出微弱瞬态信号宽度。

2. 根据权利要求1所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述预处理模块的处理过程包括:

使用小波基函数对一维时序信号进行小波分解、阈值化和小波重构,实现对一维时序信号的初步去噪;

对初步去噪后的一维时序信号进行标准化处理,使处理后的信号符合均值为0、方差为

1的分布；

根据一维深度残差网络输入长度L,将标准化处理后的一维时序信号进行分段:若信号长度大于L,将信号划分为若干个长度为L的信号片段;若信号长度小于L,将信号进行填充,使填充后的信号长度为L。

3.根据权利要求2所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述一维深度残差网络的输入为预处理后的一维时序信号,输出为该一维时序信号的类别、微弱瞬态信号中心点和微弱瞬态信号宽度,如果该一维时序信号中存在微弱瞬态信号,则类别为1;如果该一维时序信号中不存在微弱瞬态信号,则三个量均为0;其中,

所述类别,用于表示输入的一维时序信号内是否有微弱瞬态信号;

所述微弱瞬态信号中心点,用于表示微弱瞬态信号的中心位置;

所述微弱瞬态信号宽度,用于表示微弱瞬态信号的范围大小。

4.根据权利要求3所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述方法还包括一维深度残差网络的训练步骤;

步骤1) 根据实际应用场景采集瞬态信号,基于微弱瞬态信号的特征,生成仿真瞬态信号,在采集的瞬态信号中补充仿真瞬态信号,生成训练数据集和测试数据集;

步骤2) 设置一维深度残差网络多任务加权损失函数和网络训练参数,使用训练数据集在指定的平台下对一维深度残差网络进行训练,得到训练好的网络参数;

步骤3) 加载训练好的网络参数,使用测试数据集测试检测效果,调整网络参数,直至满足评价要求,得到最优网络。

5.根据权利要求4所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述步骤1) 包括:

步骤1-1) 在实际应用场景中采集包含微弱瞬态信号的一维时序信号,充分研究其微弱瞬态信号特征和背景噪声特征;

步骤1-2) 根据研究得到的微弱瞬态信号特征和背景噪声特征生成仿真微弱瞬态信号和仿真背景噪声信号,将背景噪声信号和微弱瞬态信号融合,通过调整背景噪声信号的幅度分布、方差与微弱瞬态信号的峰值和宽度生成不同信噪比下的数据,信噪比SNR满足下式:

$$SNR = 10 \log \frac{\frac{1}{P} \sum_{s=M}^N |t(s)|^2}{\frac{1}{L} \sum_{s=0}^{L-1} |n(s)|^2}$$

其中,P表示微弱瞬态信号长度,M到N表示微弱瞬态信号出现的范围,L表示背景噪声信号的长度,与一维深度残差网络输入长度一致,t(s)表示微弱瞬态信号,n(s)表示背景噪声信号,s表示时域变量;

步骤1-3) 对真实一维时序信号进行标注,标签格式为(class,center position,size),其中center position表示该微弱瞬态信号的中心位置,size表示微弱瞬态信号的宽度,class表示该一维时序信号内是否存在微弱瞬态信号,如果存在标注为1,不存在则class、center position和size均标注为0;

步骤1-4) 根据设定的信噪比范围生成若干条含微弱瞬态信号的一维时序信号;同时生成若干条不含微弱瞬态信号的一维时序信号,将真实瞬态信号与仿真瞬态信号进行组合,

经过预处理后按照预设比例划分为训练数据集和测试数据集。

6. 根据权利要求4所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述步骤2)包括:

步骤2-1) 设置一维深度残差网络多任务加权损失函数:

$$\text{Loss} = w_1 * \text{Loss}_c + w_2 * \text{Loss}_p + w_3 * \text{Loss}_s$$

其中,  $w_1, w_2, w_3$  分别表示人工指定的3种损失权重,  $\text{Loss}_c$  表示分类损失函数,  $\text{Loss}_p$  表示中心点损失函数,  $\text{Loss}_s$  表示宽度损失函数, 分别满足下式:

$$\text{Loss}_c = -\frac{1}{N} \sum_{i=1}^N [C_i \log(\hat{C}_i) + (1 - C_i) \log(1 - \hat{C}_i)]$$

$$\text{Loss}_p = -\frac{1}{2N} \sum_{i=1}^N (P_i - \hat{P}_i)^2$$

$$\text{Loss}_s = -\frac{1}{2N} \sum_{i=1}^N (S_i - \hat{S}_i)^2$$

其中,  $C_i, P_i, S_i$  分别表示第  $i$  个样本的真实类别、真实中心点和真实宽度,  $\hat{C}_i, \hat{P}_i, \hat{S}_i$  分别表示对应该样本的预测类别、预测中心点和预测宽度,  $N$  表示一次批量运算包含的样本个数;

步骤2-2) 使用满足需求的深度学习硬件设备训练网络, 基于深度学习框架搭建训练环境, 优化器为Adam, 设置参数惩罚系数为  $10^{-5}$ , 初始学习率为  $10^{-3}$ , batch size 为1024;

步骤2-3) 在训练中, 首先进行10个轮次的训练, 随后将学习率减小10倍, 继续训练, 使用有序字典保存训练得到的一维深度残差网络的结构和参数。

7. 根据权利要求4所述的基于时域深度特征学习的微弱瞬态信号检测方法,其特征在于,所述步骤3)包括:

步骤3-1) 将预处理后的测试数据集信号片段批量输入训练好的一维深度残差网络中, 获取检测结果;

针对信号分类任务, 使用ROC曲线评价检测的性能; 针对定位任务, 瞬态信号的中心点与宽度形成一个包围框, 采用交并比准确率IoU进行评价, 根据下式计算预测的包围框与真实包围框的IoU:

$$\text{IoU} = \frac{\min(E_T, E_P) - \max(S_T, S_P)}{\max(E_T, E_P) - \min(S_T, S_P)}$$

其中,  $E_T, E_P$  分别表示真实包围框、预测包围框的右边界,  $S_T, S_P$  分别表示真实包围框、预测包围框的左边界;

如果IoU大于设定的阈值, 则认为定位正确, 否则, 定位错误;

对网络参数不断调优, 直至满足设定的分类精度和定位精度的评价要求, 得到最优网络。

8. 一种基于时域深度特征学习的微弱瞬态信号检测系统,其特征在于,所述系统包括: 检测模块和微弱瞬态信号检测模型; 其中,

所述检测模块, 用于将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模

型,通过该微弱瞬态信号检测模型判断输入的一维时序信号中是否存在微弱瞬态信号,同时输出该微弱瞬态信号在时域上的位置信息,实现微弱瞬态信号判别和时域信息定位;

所述微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络;

所述一维深度残差网络包括依次连接的主干特征提取网络和线性输出网络;其中,

所述主干特征提取网络包括依次连接的20个CBR模块和7次残差连接,每个CBR模块,用于进一步提取瞬态信号的特征,包括一个一维卷积层Conv1D、一个批标准化层Batch Normalization和一个激活层ReLU;每个残差连接,用于防止微弱瞬态信号特征的丢失;在输入数据进入一维深度残差网络后,先由前两个CBR模块,即CBR0模块和CBR1模块提取浅层特征,再将CBR1模块的输出特征输入CBR2模块中;得到CBR2模块的输出特征后,开展第一次残差连接,具体结构为:将CBR2的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR2模块的输出特征相加,得到第一次残差连接的结果并输入CBR3模块中,开展第二次残差连接,具体结构为:将CBR3模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR3模块的输出特征相加,得到第二次残差连接的结果并开展第三次残差连接,具体结构为:将第二次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第二次残差连接的结果相加,得到第三次残差连接的结果并输入CBR4模块中,开展第四次残差连接,具体结构为:将CBR4模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR4模块的输出特征相加,得到第四次残差连接的结果并开展第五次残差连接,具体结构为:将第四次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第四次残差连接的结果相加,得到第五次残差连接的结果并开展第六次残差连接,具体结构为:将第五次残差连接的结果输入依次相连的两个CBR模块中,得到的输出特征与第五次残差连接的结果相加,得到第六次残差连接的结果并输入CBR5模块中,开展第七次残差连接,具体结构为:将CBR5模块的输出特征输入依次相连的两个CBR模块中,得到的输出特征与CBR5模块的输出特征相加,得到第七次残差连接的结果并进行平坦化处理得到一维特征向量;

所述线性输出网络包括4个LR模块:即LR1模块、LR2模块和LR3模块和LR4模块,以及3个输出层:即output\_class层、output\_width层和output\_center\_pos层;每个LR模块用于对提取到的特征信息进行学习,为输出层提供更高维的特征,每个LR模块包括一个线性层Linear和一个激活层ReLU;每个输出层包括一个线性层和一个激活层;主干特征提取网络输出的一维特征向量输入LR1模块中,得到的输出特征同时输入LR2模块和output\_class层,经output\_class层处理后输出类别;将LR2模块的输出特征同时输入LR3模块和output\_center\_pos层,经output\_center\_pos层处理后输出微弱瞬态信号中心点;将LR3模块的输出特征经LR4模块输入output\_width层,经output\_width层处理后输出微弱瞬态信号宽度。

## 基于时域深度特征学习的微弱瞬态信号检测方法及系统

### 技术领域

[0001] 本发明涉及微弱瞬态信号检测领域,具体涉及基于时域深度特征学习的微弱瞬态信号检测方法及系统。

### 背景技术

[0002] 瞬态信号指波形、出现位置未知的一维信号,一般由瞬态冲击形成。对瞬态信号进行检测是指从一维时序信号中区分出瞬态信号。由于一维时序信号含有大量背景噪声信号,若将瞬态信号看作有效信号,则微弱瞬态信号一般为信噪比小于3dB的一维时序信号,由于该瞬态信号存在幅度小、持续时间短、不易与背景区分、信噪比较低的特点,因此针对微弱瞬态信号进行检测一直是学术界的难题之一。

[0003] 现阶段针对瞬态信号的检测方法主要分为两类,一是基于信号分析的传统检测方法,二是基于机器学习的检测方法。

[0004] 基于信号分析的检测方法主要基于时频分析方法,如离散傅里叶变换、短时傅里叶变换、小波变换等。时频分析方法将一维时域信号变换到二维的时频平面,从而利用时频信息完成对瞬态信号的检测。如王红萍等人将水声瞬态信号进行短时傅里叶变换,随后使用RPCA和NMF算法对时频矩阵进行分解,检测其中是否存在目标信号,取得了较好的效果。1954年,Page针对水声瞬态信号提出了Page-Test算法,近期提出的算法很多将时频分析与Page Test算法结合。韩建辉等人首先使用小波变换提高信号的信噪比,然后使用Page Test算法对水声信号进行检测。2016年,Wu Bo等人提出了WP-Page Test算法,该算法同样使用小波变换提高信号的信噪比,随后使用Page Test算法检测高信噪比信号,提高了瞬态信号的检测效果。

[0005] 基于机器学习的检测方法将信号看作一个一维向量,使用机器学习方法对其进行检测。刘刚等人提出了一种优化的核极限学习机微弱信号检测方法,通过核极限学习机对经相空间重构后的各模态函数分别建立预测模型,利用人工蜂群算法对核极限学习机的正则化系数和核参数进行优化,重构预测信号,从预测误差中检测出混沌海杂波背景中的微弱信号。吴勇等人提出了一种基于核函数的瞬态信号检测方法,使用核函数计算瞬态信号与背景信号在高维空间的距离,对距离进行阈值判定以辨别出该信号是否存在瞬态信号。

[0006] 现在,深度学习方法也进入了信号检测领域。2017年,冯亮提出了一种深度信念网络用于检测微弱信号。2021年,Zhijian Wang等人从数据驱动的角度提出了一种基于AlexNet的信号检测方法,其首先将时域振动信号转换为二维数据,然后使用AlexNet对此二维数据进行分类检测。

[0007] 目前,信号分析方法和深度学习方法在瞬态信号检测领域各有千秋,但均存在针对幅度大、持续时间长、信噪比高下的瞬态信号有效,而对于微弱瞬态信号检测效果差的问题,且无法获得瞬态信号出现、结束的时间,即不能对瞬态信号进行定位,实际应用效果有限。

## 发明内容

[0008] 针对现有技术微弱瞬态信号检测领域中存在的分类效果差、无法定位问题,本发明的目的在于克服现有技术缺陷,提出了基于时域深度特征学习的微弱瞬态信号检测方法及系统,通过设计、训练一维深度残差网络,使网络充分学习瞬态信号的特征,实现对瞬态信号的有效检测,包括判别该信号是否存在瞬态信号及对该瞬态信号进行定位,本发明可以很好地解决微弱瞬态信号检测难题,提高检测准确率,并实现瞬态信号定位效果。

[0009] 所述方法包括:

[0010] 将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模型,通过该微弱瞬态信号检测模型判断输入的一维时序信号中是否存在微弱瞬态信号,同时输出该微弱瞬态信号在时域上的位置信息,实现微弱瞬态信号判别和时域信息定位;

[0011] 所述微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络。

[0012] 作为上述方法的一种改进,所述预处理模块的处理过程包括:

[0013] 使用小波基函数对一维时序信号进行小波分解、阈值化和小波重构,实现对一维时序信号的初步去噪;

[0014] 对初步去噪后的一维时序信号进行标准化处理,使处理后的信号符合均值为0、方差为1的分布;

[0015] 根据一维深度残差网络输入长度L,将标准化处理后的一维时序信号进行分段:若信号长度大于L,将信号划分为若干个长度为L的信号片段;若信号长度小于L,将信号进行填充,使填充后的信号长度为L。

[0016] 作为上述方法的一种改进,所述一维深度残差网络的输入为预处理后的一维时序信号,

[0017] 输出为该一维时序信号的类别、微弱瞬态信号中心点和微弱瞬态信号宽度,如果该一维时序信号中存在微弱瞬态信号,则类别为1;如果该一维时序信号中不存在微弱瞬态信号,则三个量均为0;其中,

[0018] 所述类别,用于表示输入的一维时序信号内是否有微弱瞬态信号;

[0019] 所述微弱瞬态信号中心点,用于表示微弱瞬态信号的中心位置,即微弱瞬态信号出现的中心时刻;

[0020] 所述微弱瞬态信号宽度,用于表示微弱瞬态信号的范围大小,即该微弱瞬态信号持续的时间。

[0021] 作为上述方法的一种改进,所述一维深度残差网络包括依次连接的主干特征提取网络和线性输出网络;其中,

[0022] 所述主干特征提取网络包括20个CBR模块和7次残差连接,前两个CBR模块,用于提取信号的浅层信息,从第三个CBR模块开始,每进行两或三次CBR模块处理后均使用一次残差连接,以防止微弱瞬态信号特征的丢失;

[0023] 每个CBR模块,用于进一步的提取瞬态信号的特征,包括一个一维卷积层Conv1D、一个批标准化层Batch Normalization和一个激活层ReLU;

[0024] 所述线性输出网络包括4个LR模块和3个输出层;LR模块,用于对提取到的特征信息进行学习,为输出层提供更高维的特征,每个LR模块包括一个线性层Linear和一个激活

层ReLU;输出层分别输出类别、微弱瞬态信号中心点和微弱瞬态信号宽度。

[0025] 作为上述方法的一种改进,所述方法还包括一维深度残差网络的训练步骤;

[0026] 步骤1) 根据实际应用场景采集瞬态信号,基于微弱瞬态信号的特征,生成仿真瞬态信号,在采集的瞬态信号中补充仿真瞬态信号,生成训练数据集和测试数据集;

[0027] 步骤2) 设置一维深度残差网络多任务加权损失函数和网络训练参数,使用训练数据集在指定的平台下对一维深度残差网络进行训练,得到训练好的网络参数;

[0028] 步骤3) 加载训练好的网络参数,使用测试数据集测试检测效果,调整网络参数,直至满足评价要求,得到最优网络。

[0029] 作为上述方法的一种改进,所述步骤1) 包括:

[0030] 步骤1-1) 在实际应用场景中采集包含微弱瞬态信号的一维时序信号,充分研究其微弱瞬态信号特征和背景噪声特征;

[0031] 步骤1-2) 根据研究得到的微弱瞬态信号特征和背景噪声特征生成仿真微弱瞬态信号和仿真背景噪声信号,将背景噪声信号和微弱瞬态信号融合,通过调整背景噪声信号的幅度分布、方差与微弱瞬态信号的峰值和宽度生成不同信噪比下的数据,信噪比SNR满足下式:

$$[0032] \quad SNR = 10 \log \frac{\frac{1}{P} \sum_{s=M}^N |t(s)|^2}{\frac{1}{L} \sum_{s=0}^{L-1} |n(s)|^2}$$

[0033] 其中,P表示微弱瞬态信号长度,M到N表示微弱瞬态信号出现的范围,L表示背景噪声信号的长度,与一维深度残差网络输入长度一致,t(s)表示微弱瞬态信号,n(s)表示背景噪声信号,s表示时域变量;

[0034] 步骤1-3) 对真实一维时序信号进行标注,标签格式为(class,center position,size),其中center position表示该微弱瞬态信号的中心位置,size表示微弱瞬态信号的宽度,class表示该一维时序信号内是否存在微弱瞬态信号,如果存在标注为1,不存在则class、center position和size均标注为0;

[0035] 步骤1-4) 根据设定的信噪比范围生成若干条含微弱瞬态信号的一维时序信号,即有目标信号;同时生成若干条不含微弱瞬态信号的一维时序信号,即无目标信号,将真实瞬态信号与仿真瞬态信号进行组合,经过预处理后按照预设比例划分为训练数据集和测试数据集。

[0036] 作为上述方法的一种改进,所述步骤2) 包括:

[0037] 步骤2-1) 设置一维深度残差网络多任务加权损失函数:

$$[0038] \quad Loss = w_1 * Loss_c + w_2 * Loss_p + w_3 * Loss_s$$

[0039] 其中, $w_1, w_2, w_3$ 分别表示人工指定的3种损失权重, $Loss_c$ 表示分类损失函数, $Loss_p$ 表示中心点损失函数, $Loss_s$ 表示宽度损失函数,分别满足下式:

$$[0040] \quad Loss_c = -\frac{1}{N} \sum_{i=1}^N [C_i \log(\hat{C}_i) + (1 - C_i) \log(1 - \hat{C}_i)]$$

$$[0041] \quad Loss_P = -\frac{1}{2N} \sum_{i=1}^N (P_i - \hat{P}_i)^2$$

$$[0042] \quad Loss_S = -\frac{1}{2N} \sum_{i=1}^N (S_i - \hat{S}_i)^2$$

[0043] 其中,  $C_i$ 、 $P_i$ 、 $S_i$  分别表示第  $i$  个样本的真实类别、真实中心点和真实宽度,  $\hat{C}_i$ 、 $\hat{P}_i$ 、 $\hat{S}_i$  分别表示对应该样本的预测类别、预测中心点和预测宽度,  $N$  表示一次批量运算包含的样本个数;

[0044] 步骤2-2) 使用满足需求的深度学习硬件设备训练网络, 基于深度学习框架搭建训练环境, 优化器为Adam, 设置参数惩罚系数为  $10^{-5}$ , 初始学习率为  $10^{-3}$ , batch size 为1024;

[0045] 步骤2-3) 在训练中, 首先进行10个轮次的训练, 随后将学习率减小10倍, 继续训练, 使用有序字典保存训练得到的一维深度残差网络的结构和参数。

[0046] 作为上述方法的一种改进, 所述步骤3) 包括:

[0047] 步骤3-1) 将预处理后的测试数据集信号片段批量输入训练好的一维深度残差网络中, 获取检测结果;

[0048] 针对信号分类任务, 使用ROC曲线 (受试者操作特性曲线, Receiver Operating Characteristic Curve) 评价检测的性能; 瞬态信号的中心点与宽度形成一个包围框, 采用交并比准确率IoU (Intersection over Union) 进行评价, 根据下式计算预测的包围框与真实包围框的IoU:

$$[0049] \quad IoU = \frac{\min(E_T, E_P) - \max(S_T, S_P)}{\max(E_T, E_P) - \min(S_T, S_P)}$$

[0050] 其中,  $E_T$ 、 $E_P$  分别表示真实包围框、预测包围框的右边界,  $S_T$ 、 $S_P$  分别表示真实包围框、预测包围框的左边界;

[0051] 如果IoU大于设定的阈值, 则认为定位正确, 否则, 定位错误;

[0052] 对网络参数不断调优, 直至满足设定的分类精度和定位精度的评价要求, 得到最优网络。

[0053] 一种基于时域深度特征学习的微弱瞬态信号检测系统, 所述系统包括: 检测模块和微弱瞬态信号检测模型; 其中,

[0054] 所述检测模块, 用于将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模型, 通过该微弱瞬态信号检测模型判断输入的一维时序信号中是否存在微弱瞬态信号, 同时输出该微弱瞬态信号在时域上的位置信息, 实现微弱瞬态信号判别和时域信息定位;

[0055] 所述微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络。

[0056] 与现有技术相比, 本发明的优势在于:

[0057] 1、本发明对一维时序信号进行预处理, 包括小波变换和标准化, 实现信号的初步去噪, 提高信号的信噪比, 降低检测难度;

[0058] 2、本发明通过在真实数据集中补充仿真数据, 扩大一维时序信号数据集规模, 显著提高了检测效果, 尤其在多种不同的真实场景下, 本发明提出的方法具有更好的鲁棒性;

[0059] 3、本发明使用一维深度残差网络提取微弱瞬态信号的特征,通过多任务学习,输出信号的类别与位置,可以有效防止特征的丢失,并具备一定的微弱瞬态信号定位能力;

[0060] 4、本发明使用人工设计的多任务加权损失函数进行网络训练,可以保证在训练过程中分类和定位任务的优化达到最优平衡,防止网络仅在单一任务上表现效果好,而在其他任务效果不佳。

### 附图说明

[0061] 图1是本发明方法中钟形瞬态信号的示意图;

[0062] 图2是本发明方法中一维深度残差网络示意图;

[0063] 图3是本发明方法中CBR模块图;

[0064] 图4是本发明方法中LR模块图;

[0065] 图5是本发明方法中对不同信噪比的信号分类结果;

[0066] 图6是本发明方法中对不同信噪比的信号定位结果。

### 具体实施方式

[0067] 针对上述方法存在的问题,本发明提出了基于时域深度特征学习的微弱瞬态信号检测方法及系统,将经过预处理后的一维时序信号输入训练好的一维深度残差网络中,判别信号中是否有瞬态信号的同时输出瞬态信号的位置,实现了低信噪比下微弱瞬态信号的有效检测。

[0068] 下面结合附图和实施例对本发明的技术方案进行详细的说明。

[0069] 实施例1

[0070] 本发明的实施例1提出了一种基于时域深度特征学习的微弱瞬态信号检测方法,方案由四个部分组成:首先根据实际应用场景采集瞬态信号,充分研究微弱瞬态信号的特征,生成仿真瞬态信号。通过在真实瞬态信号中补充仿真瞬态信号,生成训练数据集和测试数据集,并对真实瞬态信号和仿真瞬态信号进行小波变换,降低检测难度;随后搭建针对微弱瞬态信号检测任务的一维深度残差网络模型;之后设置一维深度残差网络多任务加权损失函数,并调整训练参数以得到最优模型。最后对训练得到的模型开展实验,使用测试数据集测试检测效果,验证模型的检测性能。

[0071] 第一步:制作数据集

[0072] 步骤A:根据实际应用场景采集瞬态信号,充分研究微弱瞬态信号的特征,生成仿真瞬态信号。通过在真实瞬态信号中补充仿真瞬态信号,生成训练数据集和测试数据集,具体步骤如下:

[0073] 步骤A1:瞬态信号的类型丰富,需要根据实际应用场景采集特定类型的信号,随后充分研究信号的特征,包括瞬态信号的形状以及背景噪声信号的幅度分布、方差等。

[0074] 步骤A2:根据实际应用场景下瞬态信号的特征生成仿真瞬态信号和背景噪声信号,控制瞬态信号的形状保持一致、出现位置随机。本发明具体研究的微弱瞬态信号和背景噪声信号以钟形信号和高斯白噪声信号为例,但不限于这两种信号,其中钟形信号如图1所示,使用式(1)进行描述。

$$[0075] \quad s(k) = Ae^{-\frac{(t-t_0)^2}{2\sigma^2}}, \quad t_1 < t < t_2 \quad (1)$$

[0076] 式(1)中,A表示微弱瞬态信号的峰值, $\sigma$ 表示钟形信号的方差, $t_1$ 和 $t_2$ 分别表示微弱瞬态信号开始和结束的时间, $t_0 = t_1 + (t_2 - t_1) / 2$ ,表示微弱瞬态信号中心所处的时间。

[0077] 步骤A3:将背景噪声信号和微弱瞬态信号融合,通过调整背景噪声信号的幅度分布、方差与微弱瞬态信号的峰值、宽度即可生成不同信噪比下的数据,信噪比计算公式如式(2)所示。

$$[0078] \quad SNR = 10 \log \frac{\frac{1}{P} \sum_{s=M}^N |t(s)|^2}{\frac{1}{L} \sum_{s=0}^{L-1} |n(s)|^2} \quad (2)$$

[0079] 式(2)中,P表示微弱瞬态信号长度,M到N表示微弱瞬态信号出现的范围,L表示背景噪声信号的长度,与一维深度残差网络输入长度一致,t(s)表示微弱瞬态信号,n(s)表示背景噪声信号,s表示时域变量;

[0080] 步骤A4:对真实瞬态信号进行标注,标签格式为(class,center position,size),其中center position表示该瞬态信号的中心位置;size表示瞬态信号的宽度;class表示该信号内是否存在瞬态信号,如果存在标注为1,不存在则class、center position和size均标注为0。

[0081] 步骤A5:在具体的应用场景下选择需要生成的微弱瞬态信号的信噪比范围,生成仿真瞬态信号。本发明指定的信噪比范围为-3dB~3dB,在该信噪比范围内生成80000条含微弱瞬态信号的背景噪声信号,即有目标信号;同时生成80000条不含微弱瞬态信号的背景噪声信号,即无目标信号,共计160000条信号。将真实瞬态信号与仿真瞬态信号进行组合,经过预处理后,按照8:2划分为训练数据集和测试数据集。

[0082] 第二步:搭建一维深度残差网络模型

[0083] 步骤B:搭建针对微弱瞬态信号检测任务的一维深度残差网络模型,该网络模型由输入(Input)、主干特征提取网络(Backbone)、线性输出网络(LinearOutput)组成,如图2所示,抽象化的数学表达如式(3)、(4)所示。

$$[0084] \quad \text{Temp} = \text{Backbone}(\text{Input}) \quad (3)$$

$$[0085] \quad (\text{class}, \text{center position}, \text{size}) = \text{LinearOutput}(\text{Temp}) \quad (4)$$

[0086] 其中Temp表示网络处理的中间结果,是一个抽象后的变量。

[0087] 主干特征提取网络由20个CBR模块和7次残差连接组成,线性输出网络由4个LR模块和3个输出层组成。具体过程包括:

[0088] 步骤B1:一维深度残差网络的输入为L\*1的信号。若信号长度大于L,则需要将信号划分为若干个长度为L的信号片段;若信号长度小于L,则需要将信号进行填充,使填充后的信号长度为L。本发明L指定为512。

[0089] 步骤B2:主干特征提取网络的基本单元为CBR模块,如图3所示。由一个一维卷积层(Conv1D)、一个批标准化层(Batch Normalization)和一个激活层(ReLU)组成。一维卷积层用于提取信号中的局部特征,随后对提取到的特征进行批标准化,最后将特征使用ReLU激活函数进行非线性化激活处理,这样做可以抑制数据分布的变化、加快收敛速度,避免梯度消失和梯度爆炸问题。每经过一次CBR模块,瞬态信号的特征都得到进一步的提取。

[0090] 步骤B3:主干特征提取网络中前两个CBR模块提取信号的浅层信息,从第三个CBR模块开始,每进行两或三次CBR模块处理后都会使用一次残差连接,将CBR模块的输入特征直接与输出特征相加,防止瞬态信号特征的丢失,网络中共进行了7次残差连接,残差连接的公式如式(5)~(7)所示。

$$[0091] \quad X_1 = \text{CBR}(X) \quad (5)$$

$$[0092] \quad X_2 = \text{CBR}(X) \quad (6)$$

$$[0093] \quad R = X + X_2 \quad (7)$$

[0094] 其中X表示输入特征, $X_i$ 表示经过*i*次CBR模块处理后提取的特征,R表示将原始输入特征X与经过*i*次CBR模块的特征相加后的特征。

[0095] 步骤B4:线性输出层包括四个LR模块和三个输出层。每个LR模块包括一个线性层(Linear)和一个激活层(ReLU),如图4所示。LR模块可以对提取到的特征信息进行学习,为输出层提供更高维的特征。在本网络中输出三个数据,分别是类别(class)、中心点(center position)和宽度(size),其中类别表示该信号内是否有瞬态信号,中心点表示瞬态信号的中心位置,宽度表示瞬态信号的范围大小。如果该信号内存在瞬态信号,则输出类别、中心点和宽度信息,否则网络均输出0。在不同的网络层输出不同的数据可以将网络解耦,使得每层只关注于当前的输出,防止由于优化一个输出对其他数据产生影响。

[0096] 第三步:训练网络模型

[0097] 步骤C:设置一维深度残差网络多任务加权损失函数、模型训练参数,在指定的训练平台下训练网络模型,具体过程包括:

[0098] 步骤C1:一维深度残差网络输出三个信息,即信号的类别,瞬态信号的宽度和中心点,因此损失函数由三个部分组成,即分类损失函数、中心点损失函数、宽度损失函数,其中分类损失函数采用二分类交叉熵损失函数,中心点损失函数和宽度损失函数采用均方差损失函数。这三部分损失数量级存在显著差异,为防止某一部分损失过大将网络参数带偏,对分类损失函数、中心点损失函数和宽度损失函数进行人工加权,保持三部分损失在同一个数量级上,最终得到的加权损失函数如公式(8)所示。

$$[0099] \quad \text{Loss} = w_1 * \text{Loss}_c + w_2 * \text{Loss}_p + w_3 * \text{Loss}_s \quad (8)$$

[0100] 其中 $w_i$ 表示人工指定的损失权重, $\text{Loss}_c$ 表示分类损失函数, $\text{Loss}_p$ 表示中心点损失函数, $\text{Loss}_s$ 表示宽度损失函数,这三部分公式分别如式(9)、(10)、(11)所示。

$$[0101] \quad \text{Loss}_c = -\frac{1}{N} \sum_{i=1}^N [C_i \log(\hat{C}_i) + (1 - C_i) \log(1 - \hat{C}_i)] \quad (9)$$

$$[0102] \quad \text{Loss}_p = -\frac{1}{2N} \sum_{i=1}^N (P_i - \hat{P}_i)^2 \quad (10)$$

$$[0103] \quad \text{Loss}_s = -\frac{1}{2N} \sum_{i=1}^N (S_i - \hat{S}_i)^2 \quad (11)$$

[0104] 其中 $C_i$ 、 $P_i$ 、 $S_i$ 表示真实类别、真实中心点和真实宽度, $\hat{C}_i$ 、 $\hat{P}_i$ 、 $\hat{S}_i$ 表示预测类别、预测中心点和预测宽度,N表示一次批量运算包含的样本个数。

[0105] 步骤C2:使用满足要求的深度学习硬件设备训练网络模型,基于深度学习框架搭建训练环境,训练中使用的优化器为Adam,设置的参数惩罚系数为 $10^{-5}$ ,初始学习率设置为 $10^{-3}$ ,batch size设置为1024。在训练中,首先进行10个epoch的训练,随后将学习率减小10倍,继续训练。使用有序字典保存训练得到的网络模型的结构和参数。

[0106] 第四步:微弱瞬态信号检测实验

[0107] 步骤D:读取训练得到的模型文件,生成网络模型,使用测试数据集测试检测效果,具体过程包括:

[0108] 步骤D1:对信号进行预处理,即首先使用小波基函数对一维时序信号进行小波分解、阈值化和小波重构,实现对一维时序信号的初步去噪。随后对一维时序信号进行标准化处理,使处理后的信号符合均值为0、方差为1的分布。最后根据一维深度残差网络输入长度(L\*1)将信号划分为若干个信号片段,对于长度不足L的信号片段,对其填充后输入网络;

[0109] 步骤D2:加载训练好的模型参数,将信号片段批量输入一维深度残差网络中,获取检测结果,即网络输出的三个变量(class,center position,size);

[0110] 步骤D3:对检测结果进行评价。本发明对检测效果的评价包括两个方面,针对信号分类任务,使用ROC曲线(受试者操作特性曲线,Receiver Operating Characteristic Curve)评价检测的性能,曲线越靠近左上角,则表明分类效果越好;针对定位任务,采用交并比(Intersection Over Union,IoU)准确率进行评价,瞬态信号的中心点与宽度会形成一个包围框,计算预测的包围框与真实包围框的IoU,如果IoU大于设定的阈值,通常阈值范围为0-1,例如取0.5,则认为定位正确,IoU的计算方式如式(12)所示。

$$[0111] \quad IoU = \frac{\min(E_T, E_P) - \max(S_T, S_P)}{\max(E_T, E_P) - \min(S_T, S_P)} \quad (12)$$

[0112] 其中 $E_T$ 、 $E_P$ 分别表示真实包围框、预测包围框的右边界, $S_T$ 、 $S_P$ 分别表示真实包围框、预测包围框的左边界。

[0113] 为了达到有效的检测能力,需要保证分类精度至少达到80%,定位精度至少为60%。通过对网络模型的参数不断调优,最终本发明的检测性能达到了理想的效果,具体的检测结果如图5和图6所示。可以看到所有ROC曲线都非常靠近左上角,在虚警率为10%的情况下准确率可以达到80%以上,模型分类效果较好;定位准确率最高达到了90.4%,模型具备一定的定位性能。同时,检测效果随着信噪比的上升而上升,符合预期。

[0114] 实施例2

[0115] 本发明的实施例2提出了一种基于时域深度特征学习的微弱瞬态信号检测系统,基于实施例1的方法实现,所述系统包括:检测模块和微弱瞬态信号检测模型;其中,

[0116] 检测模块,用于将一维时序信号输入预先建立和训练好的微弱瞬态信号检测模型,通过该微弱瞬态信号检测模型判断输入的一维时序信号中是否存在微弱瞬态信号,同时输出该微弱瞬态信号在时域上的位置信息,实现微弱瞬态信号判别和时域信息定位;

[0117] 微弱瞬态信号检测模型包括依次连接的信号预处理模块和一维深度残差网络。

[0118] 最后所应说明的是,以上实施例仅用以说明本发明的技术方案而非限制。尽管参照实施例对本发明进行了详细说明,本领域的普通技术人员应当理解,对本发明的技术方案进行修改或者等同替换,都不脱离本发明技术方案的精神和范围,其均应涵盖在本发明的权利要求范围当中。

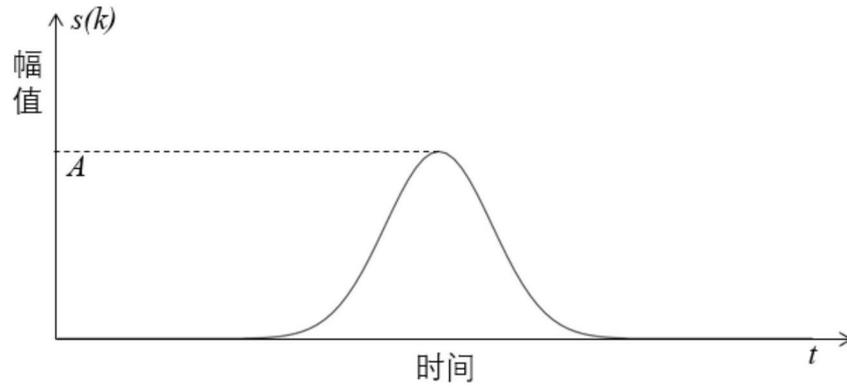


图1

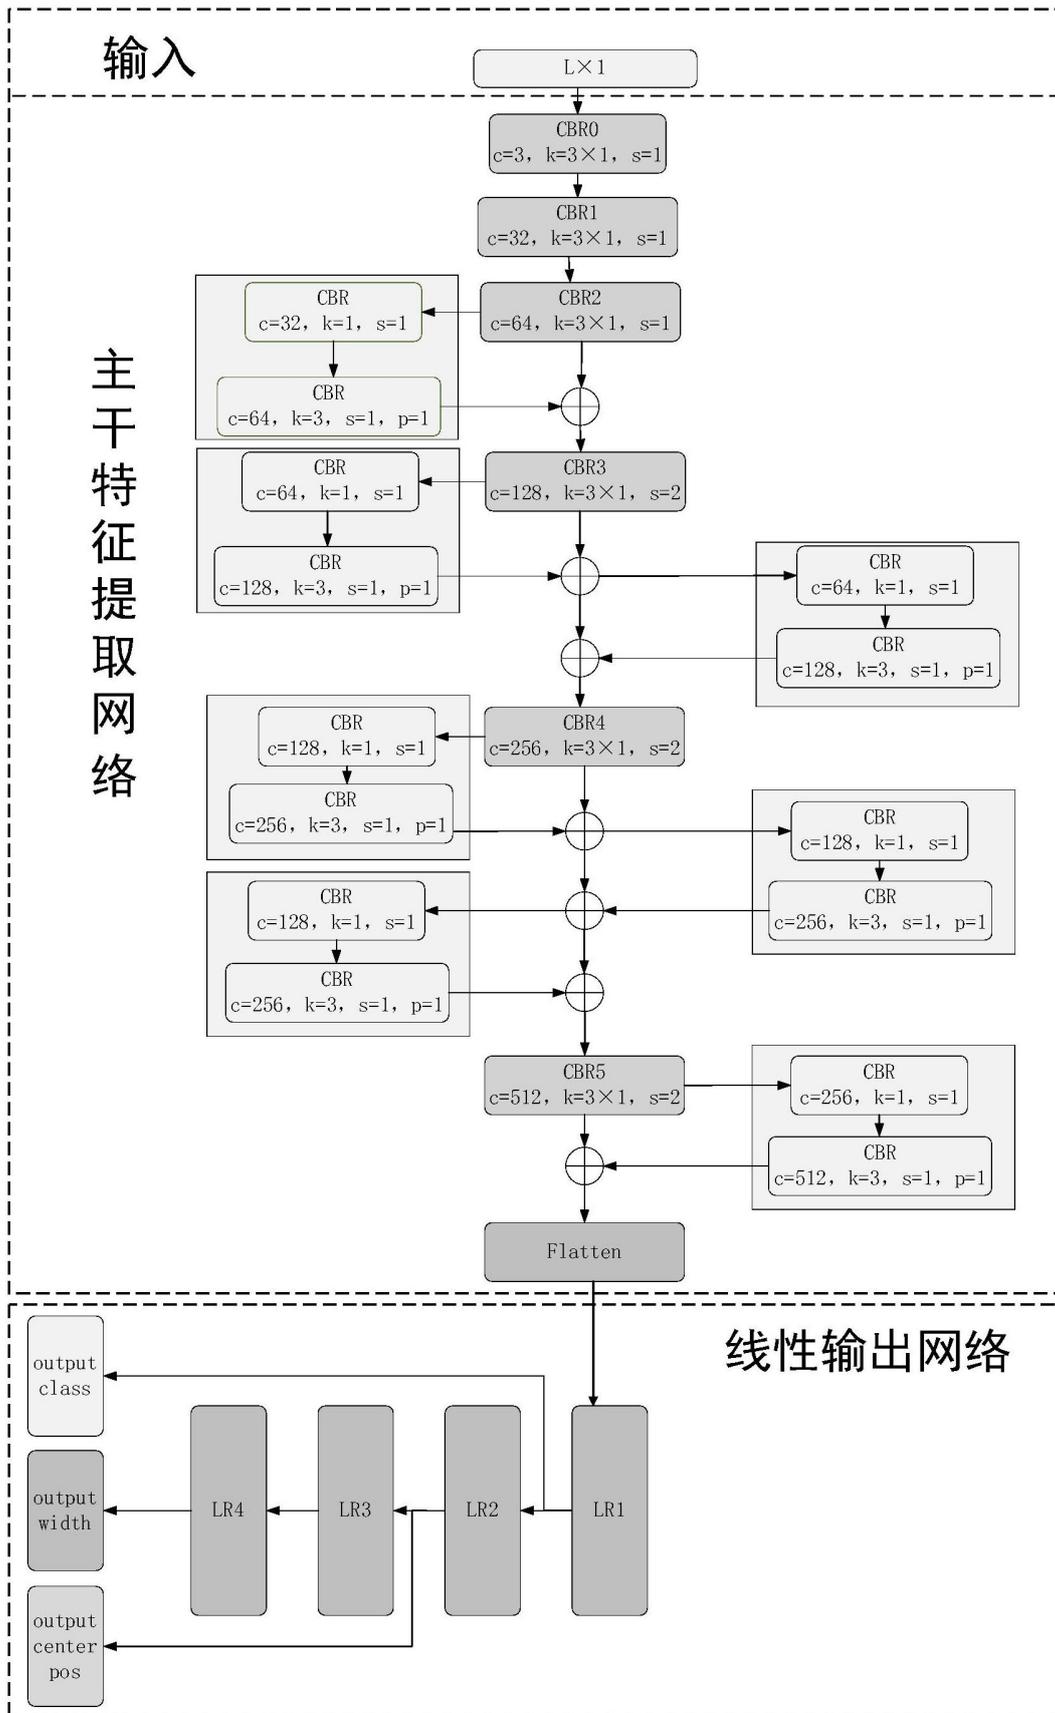


图2

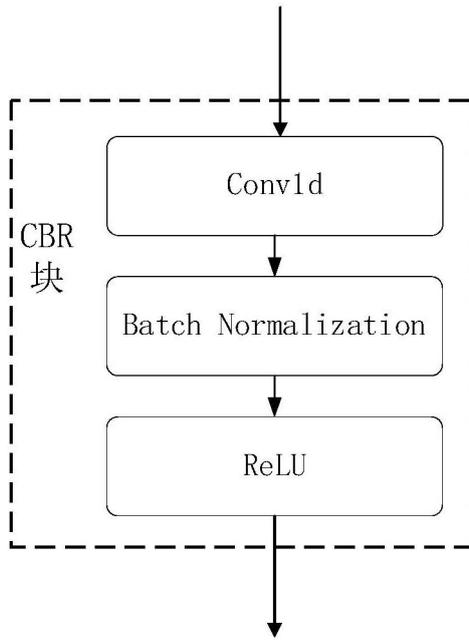


图3

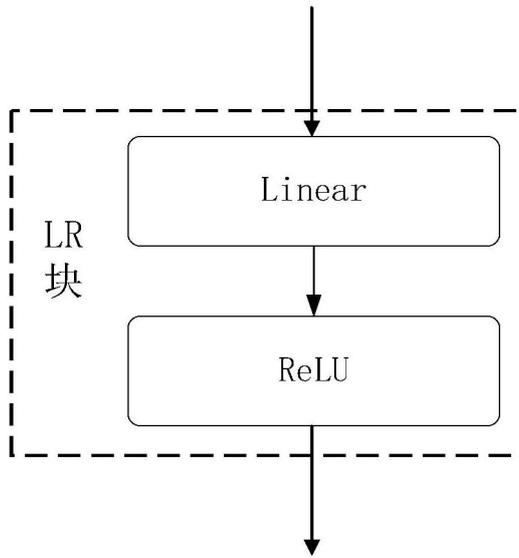


图4

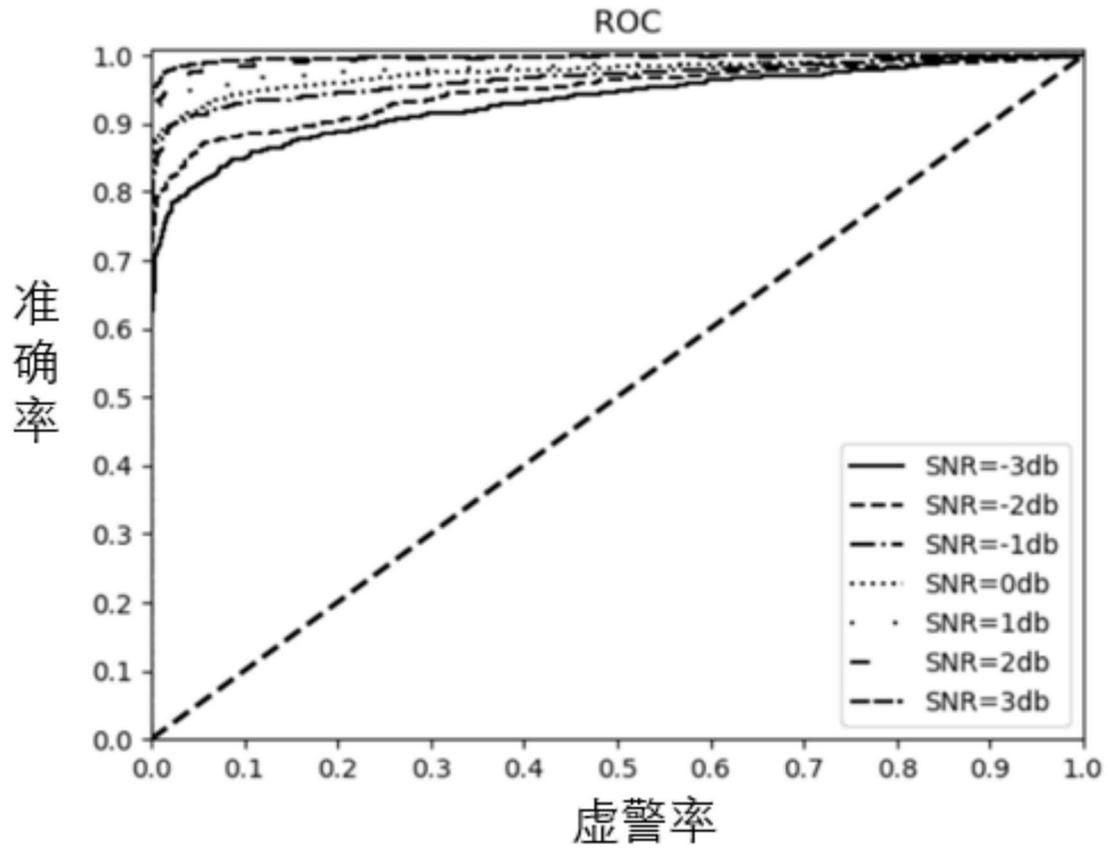


图5

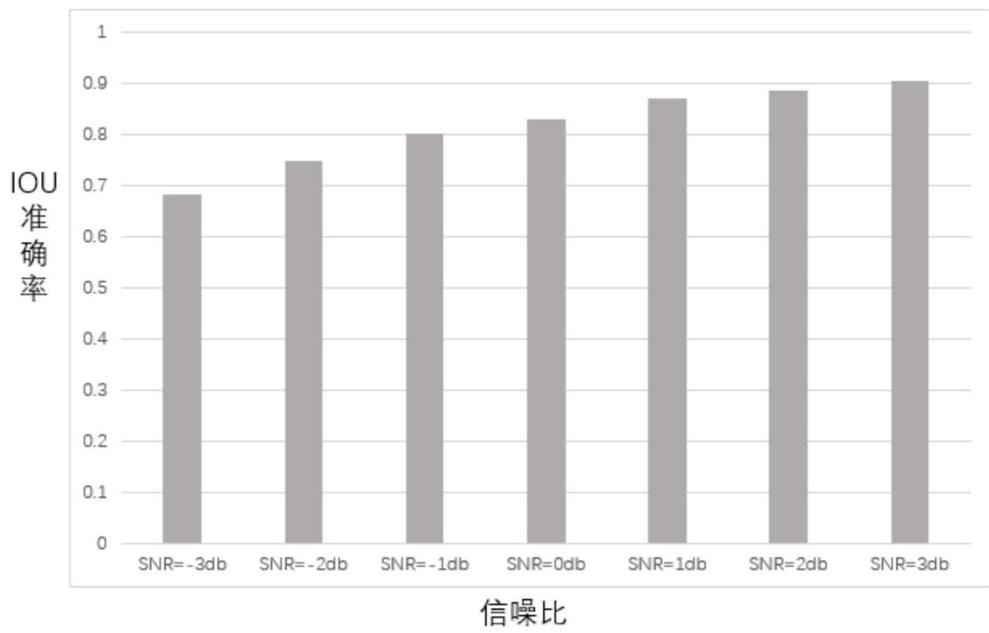


图6