



(12) 发明专利

(10) 授权公告号 CN 114595725 B

(45) 授权公告日 2024. 02. 20

(21) 申请号 202210253209.3

G06F 18/25 (2023.01)

(22) 申请日 2022.03.15

G06N 3/0464 (2023.01)

(65) 同一申请的已公布的文献号

G06N 3/048 (2023.01)

申请公布号 CN 114595725 A

G06N 3/09 (2023.01)

(43) 申请公布日 2022.06.07

A61B 5/372 (2021.01)

A61B 5/00 (2006.01)

(73) 专利权人 合肥工业大学

(56) 对比文件

地址 230009 安徽省合肥市包河区屯溪路  
193号

AU 2020103901 A4, 2021.02.11

CN 112766229 A, 2021.05.07

(72) 发明人 李畅 赵禹闾 宋仁成 刘羽  
成娟 陈勋

CN 113011330 A, 2021.06.22

CN 113673434 A, 2021.11.19

US 2018357542 A1, 2018.12.13

(74) 专利代理机构 安徽省合肥新安专利代理有  
限责任公司 34101

WO 2021143353 A1, 2021.07.22

专利代理师 陆丽莉 何梅生

岑仕杰;何元烈;陈小聪.结合注意力与无监督深度学习的单目深度估计.广东工业大学学报.2020,(第04期),全文.

张娜;唐贤伦;刘庆.基于半监督学习的脑电信号特征提取及识别.工程科学与技术.2017,(第S2期),全文.

(51) Int. Cl.

G06F 18/10 (2023.01)

G06F 18/213 (2023.01)

G06F 18/22 (2023.01)

G06F 18/24 (2023.01)

G06F 18/214 (2023.01)

审查员 张媛媛

权利要求书3页 说明书8页 附图4页

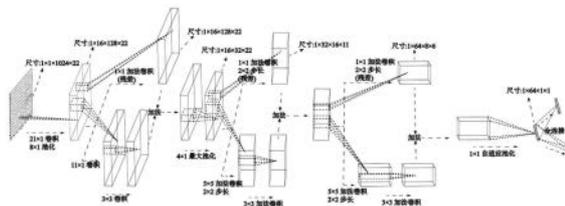
(54) 发明名称

一种基于加法网络和监督对比学习的脑电信号分类方法

价值。

(57) 摘要

本发明公开了一种基于加法网络和监督对比学习的脑电信号分类方法,其步骤包括:1,对于原始脑电数据进行数据选择和切片的预处理;2,建立加法网络分类模型;3,设计混合损失函数,建立分类模型优化目标;4,输入数据对网络进行训练,利用训练好的最优模型完成脑电信号分类。本发明使用加法代替乘法运算,极大的降低了计算的复杂度和能量消耗,使用了监督对比损失和交叉熵损失混合的损失函数,无需对原始脑电信号进行人工提取特征或信号处理就能自动完成信号分类,并能够显著提升脑电信号分类准确率,从而增加脑电信号在医疗等领域的应用



1. 一种基于加法网络和监督对比学习的脑电信号分类方法,其特征是按如下步骤进行:

步骤1、获取有标注信息的脑电信号数据集,并对脑电信号数据集中的原始脑电信号进行通道数据选择和样本分割的预处理,从而获得N段时长为T的脑电信号样本并构成训练样本集,记为 $X = \{X_1, X_2, \dots, X_n, \dots, X_N\}$ ,其中, $X_n \in \mathbb{R}^{W \times H}$ 表示第n段脑电信号样本,H表示脑电信号的通道数, $W = T \times s$ 表示采样点数,s表示脑电信号的采样率;令第n段脑电信号样本 $X_n$ 所对应的标签记为 $Y_n$ ,则训练样本集X所对应的标签集合记为 $Y = \{Y_1, Y_2, \dots, Y_n, \dots, Y_N\}$ ;

步骤2、建立加法网络模型,并包含:一维卷积层、M个加法卷积模块、自适应池化层、投影层、分类层;

所述加法卷积模块由加法卷积层、加法卷积残差层构成;令第m个加法卷积模块的加法卷积核大小为 $h_m$ ,步长为 $w_m$ ,且各加法卷积层之间以及各加法卷积残差层之间均采用ReLU激活函数和批归一化操作;其中,仅第一个加法卷积块后设置有最大池化操作; $m = 1, 2, \dots, M$ ;

步骤2.1、对模型参数进行初始化:

对所有卷积层的权重使用xavier\_uniform\_初始化;

步骤2.2、将所述第n段脑电信号样本 $X_n \in \mathbb{R}^{W \times H}$ 输入所述加法网络模型中,先经过所述一维卷积层的时间特征提取和数据降维操作后,得到第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ ;其中, $F_{n,x}^0$ 表示所述一维卷积层输出的第n个一维卷积特征序列 $F_n^0$ 中的第x个特征图, $C_0$ 表示第n个特征序列 $F_n^0$ 中的特征图个数;

步骤2.3、所述加法卷积模块的处理:

步骤2.3.1、当 $m=1$ 时,将第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ 作为第m个加法卷积模块的输入,并记为第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ ;其中, $F_{n,x}^m$ 表示所述第m个加法卷积模块的特征序列 $F_n^m$ 中的第x个特征图, $C_m$ 表示第m个加法卷积模块的特征序列 $F_n^m$ 中的特征图个数;

步骤2.3.2、所述第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积层的处理,得到第m个加法卷积层特征序列 $A_n^m = \{A_{n,1}^m, A_{n,2}^m, \dots, A_{n,x}^m, \dots, A_{n,C_m}^m\}$ ;其中, $A_{n,x}^m$ 表示所述第m个加法卷积层输出的第m个加法卷积层特征序列 $A_n^m$ 中的第x个特征图;

所述第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积残差层的处理,得到第m个加法卷积残差层特征序列 $R_n^m = \{R_{n,1}^m, R_{n,2}^m, \dots, R_{n,x}^m, \dots, R_{n,C_m}^m\}$ ;其中, $R_{n,x}^m$ 表示所述第m个加法卷积残差层输出的第m个加法卷积残差层特征序列 $R_n^m$ 中的第x个特征图;

步骤2.3.3、将第m个加法卷积层输出的特征序列 $A_n^m$ 和第m个加法卷积残差层输出的特征序列 $R_n^m$ 相加后,得到第m个融合特征序列 $D_n^m = \{D_{n,1}^m, D_{n,2}^m, \dots, D_{n,x}^m, \dots, D_{n,C_m}^m\}$ ;其中, $D_{n,x}^m$ 表示第m个融合特征序列 $D_n^m$ 中的第x个特征图;

步骤2.3.4、判断 $m=1$ 是否成立,若成立,则对第m个融合特征序列 $D_n^m$ 进行最大池化操

作,获得第 $m+1$ 个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 否则,将第 $m$ 个融合特征序列  $D_n^m$  作为第 $m+1$ 个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 其中,  $F_{n,x}^{m+1}$  表示第 $m+1$ 个加法卷积模块的特征序列  $F_n^{m+1}$  中的第 $x$ 个特征图;  $C_{m+1}$  表示第 $m+1$ 个加法卷积模块的特征序列  $F_n^{m+1}$  中的特征图个数;

步骤2.3.5、将 $m+1$ 赋值给 $m$ ; 并判断 $m > M$ , 若成立, 则进入步骤2.3.6; 否则, 返回步骤2.3.2;

步骤2.3.6、将第 $M$ 个加法卷积模块的特征序列  $F_n^M = \{F_{n,1}^M, F_{n,2}^M, \dots, F_{n,x}^M, \dots, F_{n,C_M}^M\}$  通过自适应池化层的处理, 获得自适应池化层输出的特征向量  $\bar{v}_n^1 = \{v_{n,1}^1, v_{n,2}^1, \dots, v_{n,r}^1\}$ ; 其中,  $F_{n,x}^M$  表示第 $M$ 个加法卷积模块的特征序列  $F_n^M$  中的第 $x$ 个特征图,  $C_M$  表示第 $M$ 个加法卷积模块的特征序列  $F_n^M$  中的特征图个数,  $v_{n,r}^1$  表示所述自适应池化层输出的特征向量  $\bar{v}_n^1$  的第 $r$ 个特征值,  $r$  表示特征值的数量;

步骤2.4、所述投影层和分类层的处理;

步骤2.4.1、所述全连接投影层将自适应池化层输出的特征向量  $\bar{v}_n^1$  投影到特征空间, 获得投影层特征向量  $\bar{v}_n^2 = \{v_{n,1}^2, v_{n,2}^2, \dots, v_{n,r}^2\}$ ; 其中,  $v_{n,r}^2$  表示所述投影层特征向量  $\bar{v}_n^2$  的第 $r$ 个特征值;

所述自适应池化层特征向量  $\bar{v}_n^1$  同时通过全连接分类层的处理, 获得第 $n$ 个属于不同类别的概率  $p_n = \{p_{n,1}, p_{n,2}, \dots, p_{n,a}, \dots, p_{n,k}\}$ ; 其中,  $p_{n,a}$  表示所述分类层输出的第 $n$ 段脑电信号样本  $X_n$  属于第 $a$ 类的概率;  $k$  表示类别的数量;

步骤3、从所述训练样本集 $X$ 的若干段脑电信号样本中随机抽取若干个样本并构成一批次数据记为  $x = \{x_1, x_2, \dots, x_i, \dots, x_m\}$ ; 则对应的标签记为  $y = \{y_1, y_2, \dots, y_i, \dots, y_m\}$ ; 其中,  $x_i$  表示一批次数据中的第 $i$ 个脑电信号样本,  $y_i$  表示  $x_i$  的样本标签,  $m$  表示批次样本的数量;

所述一批次数据按照步骤2.2-步骤2.4的过程进行处理后, 由投影层输出特征向量  $V = \{\bar{v}_1^2, \bar{v}_2^2, \dots, \bar{v}_i^2, \dots, \bar{v}_m^2\}$ ; 其中,  $\bar{v}_i^2$  表示所述投影层输出的一批次数据中的第 $i$ 个脑电信号样本的特征向量; 由所述分类层输出概率  $P = \{p_1, p_2, \dots, p_i, \dots, p_m\}$ ; 其中,  $p_i$  表示所述分类层输出的一批次数据中的第 $i$ 个脑电信号样本的概率;

利用式(1)-式(3)建立混合损失函数  $L_n$ :

$$L = \alpha L^{\text{sup}} + (1 - \alpha) L^{\text{cross-entropy}} \quad (1)$$

$$L^{\text{sup}} = - \sum_i \frac{1}{m_{y_i}} \log \frac{\sum_{j=1}^m 1_{[y_j=y_i, j \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_j^2 / \tau)}{\sum_{t=1}^m 1_{[t \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_t^2 / \tau)} \quad (2)$$

$$L^{\text{cross-entropy}} = - \frac{1}{m} \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (3)$$

式(1)-式(3)中,  $\alpha$  是调整两类误差权重的参数,  $L^{\text{sup}}$  表示监督对比损失,  $L^{\text{cross-entropy}}$  表示交叉熵损失,  $m_{y_i}$  表示一批次样本中与第 $i$ 个脑电信号样本具有相同标签的样本个数,

$\mathbb{1}_{[y_j=y_i, j \neq i]}$  表示满足条件  $y_j=y_i, j \neq i$  时, 取值为1, 否则取值为0;  $\bar{v}_j^2$  表示所述投影层输出的一批次数据中的第  $j$  个脑电信号样本的特征向量,  $\tau$  表示控制训练平滑度的超参数,  $\bar{v}_t^2$  所述投影层输出的一批次数据中的第  $t$  个脑电信号样本的特征向量;

步骤4、基于训练样本集  $X$ , 使用Adam优化器对加法网络模型进行训练, 并计算混合损失函数  $L$ , 同时采用自适应学习率的方法调整训练过程中的学习率, 直到验证损失不再降低或者达到最大训练次数为止, 从而得到训练后的加法网络模型, 并用于对脑电信号进行分类。

## 一种基于加法网络和监督对比学习的脑电信号分类方法

### 技术领域

[0001] 本发明涉及脑电信号分类领域,具体的说是一种通过深度学习方法自动对受试者原始脑电数据进行分类预测的方法。

### 背景技术

[0002] 大脑控制着人的行为、情感以及其他的生理活动,大脑皮层中的电活动包含着丰富的信息,这些电活动可能包含人类的不同情感,运动想象,疾病的信息。随着脑机接口领域和智能医疗的发展,脑电信号已经被广泛应用于情感计算、运动想象、医疗健康等各个领域。如果能充分挖掘脑电信号的信息,准确的对不同的脑电信号分类,可以增加脑电信号在医疗等领域的使用价值。

[0003] 脑电图(EEG)是记录大脑皮层电活动的便携式设备,可以探测与脑电功能有关的各种信息。颅内EEG信号是通过置于头皮下的电极采集的,而头皮EEG信号是通过置于头皮表面的电极采集的。颅内脑电适用于长期植入式监测系统,通常具有较高的信噪比,而头皮脑电不需要植入,且对患者无创,因此在实际使用中较为普遍。对受试者EEG数据的研究表明,一些和脑电信号相关的活动在发作前几分钟到几小时就开始出现迹象,所以我们可以捕捉EEG信号中的信息来对相关活动进行预测分类。然而,对EEG信号的分析常常需要大量的专业知识和专家经验,这是一个耗时耗力的工程;而且EEG信号在时间上具有连续性,受试者在任意时刻都会输出脑电信号,所以我们需要一个能自动预测分类脑电信号的系统。

[0004] 在基于EEG信号的预测分类传统算法中,研究者通常先对EEG信号进行去噪,提取相关特征,再将获得的特征使用分类器进行分类获得预测效果。常用的特征例如 Hjorth 参数、统计矩、累积能量、自回归系数、Lyapunov 指数等。常用的分类器有支持向量机、贝叶斯分类器等。然而,提取这些特征也需要丰富的专家经验,分类的效果很大程度上也取决于提取的特征,这会导致泛化效果不佳;而且传统的分类器在提高脑电信号分类性能方面也存在不足。

[0005] 近年来,深度学习的方法被广泛应用于脑机接口领域,它能自动的从输入中学习更适合的特征,可以同时学习特征提取和分类的任务,在脑电信号分类任务中获得更加准确的预测效果。然而,深度学习的方法通常会伴随巨大的计算成本和硬件成本,在临床部署、移动应用和植入式设备应用方面存在缺陷。过去的方法主要致力于设计一种特征预处理的方法或者针对设计一种特殊的网络结构。特征预处理过程通常将原始脑电数据转换成各种形式的特征,也包括滤波去噪等操作,虽然可以获得更加“干净”的数据,但是同时也可能会丢失一些重要的信息;特殊的网络结构针对于特定的情况会有较好的效果,但是在复杂多样的环境中表现明显下降;而这些方法都忽略了数据之间的内在联系。

### 发明内容

[0006] 本发明为克服现有技术的不足之处,提出一种基于加法网络和监督对比学习的脑

电信号分类方法,以期能在低耗能、低延时、硬件友好的环境下自动实现脑电信号的分类,并能够显著提升脑电信号分类准确率,从而增加脑电信号在医疗等领域的应用价值。

[0007] 本发明为达到上述发明目的,采用如下技术方案:

[0008] 本发明一种基于加法网络和监督对比学习的脑电信号分类方法的特点是按如下步骤进行:

[0009] 步骤1、获取有标注信息的脑电信号数据集,并对脑电信号数据集中的原始脑电信号进行通道数据选择和样本分割的预处理,从而获得N段时长为T的脑电信号样本并构成训练样本集,记为 $X = \{X_1, X_2, \dots, X_n, \dots, X_N\}$ ,其中, $X_n \in \mathbb{R}^{W \times H}$ 表示第n段脑电信号样本,H表示脑电信号的通道数, $W = T \times s$ 表示采样点数,s表示脑电信号的采样率;令第n段脑电信号样本 $X_n$ 所对应的标签记为 $Y_n$ ,则训练样本集X所对应的标签集合记为 $Y = \{Y_1, Y_2, \dots, Y_n, \dots, Y_N\}$ ;

[0010] 步骤2、建立加法网络模型,并包含:一维卷积层、M个加法卷积模块、自适应池化层、投影层、分类层;

[0011] 所述加法卷积模块由加法卷积层、加法卷积残差层构成;令第m个加法卷积块的加法卷积核大小为 $h_m$ ,步长为 $w_m$ ,且各加法卷积层之间以及各加法卷积残差层之间均采用ReLU激活函数和批归一化操作;其中,仅第一个加法卷积块后设置有最大池化操作; $m = 1, 2, \dots, M$ ;

[0012] 步骤2.1、对模型参数进行初始化:

[0013] 对所有卷积层的权重使用xavier\_uniform\_初始化;

[0014] 步骤2.2、将所述第n段脑电信号样本 $X_n \in \mathbb{R}^{W \times H}$ 输入所述加法网络模型中,先经过所述一维卷积层的时间特征提取和数据降维操作后,得到第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ ;其中, $F_{n,x}^0$ 表示所述一维卷积层输出的第n个一维卷积特征序列 $F_n^0$ 中的第x个特征图, $C_0$ 表示第n个特征序列 $F_n^0$ 中的特征图个数;

[0015] 步骤2.3、所述加法卷积模块的处理:

[0016] 步骤2.3.1、当 $m=1$ 时,将第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ 作为第m个加法卷积模块的输入,并记为第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ ;其中, $F_{n,x}^m$ 表示所述第m个加法卷积模块的特征序列 $F_n^m$ 中的第x个特征图, $C_m$ 表示第m个加法卷积模块的特征序列 $F_n^m$ 中的特征图个数;

[0017] 步骤2.3.2、所述第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积层的处理,得到第m个加法卷积层特征序列 $A_n^m = \{A_{n,1}^m, A_{n,2}^m, \dots, A_{n,x}^m, \dots, A_{n,C_m}^m\}$ ;其中, $A_{n,x}^m$ 表示所述第m个加法卷积层输出的第m个加法卷积层特征序列 $A_n^m$ 中的第x个特征图;

[0018] 所述第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积残差层的处理,得到第m个加法卷积残差层特征序列 $R_n^m = \{R_{n,1}^m, R_{n,2}^m, \dots, R_{n,x}^m, \dots, R_{n,C_m}^m\}$ ;其中, $R_{n,x}^m$ 表示所述第m个加法卷积残差层输出的第m个加法卷积残差层特征序列 $R_n^m$ 中的第x个特征图;

[0019] 步骤2.3.3、将第m个加法卷积层输出的特征序列  $A_n^m$  和第m个加法卷积残差层输出的特征序列  $R_n^m$  相加后,得到第m个融合特征序列  $D_n^m = \{D_{n,1}^m, D_{n,2}^m, \dots, D_{n,x}^m, \dots, D_{n,C_m}^m\}$ ; 其中,  $D_{n,x}^m$  表示第m个融合特征序列  $D_n^m$  中的第x个特征图;

[0020] 步骤2.3.4、判断  $m=1$  是否成立,若成立,则对第m个融合特征序列  $D_n^m$  进行最大池化操作,获得第m+1个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 否则,将第m个融合特征序列  $D_n^m$  作为第m+1个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 其中,  $F_{n,x}^{m+1}$  表示第m+1个加法卷积模块的特征序列  $F_n^{m+1}$  中的第x个特征图;  $C_{m+1}$  表示第m+1个加法卷积模块的特征序列  $F_n^{m+1}$  中的特征图个数;

[0021] 步骤2.3.5、将m+1赋值给m; 并判断  $m > M$ , 若成立,则进入步骤2.3.6; 否则,返回步骤2.3.2;

[0022] 步骤2.3.6、将第M个加法卷积模块的特征序列  $F_n^M = \{F_{n,1}^M, F_{n,2}^M, \dots, F_{n,x}^M, \dots, F_{n,C_M}^M\}$  通过自适应池化层的处理,获得自适应池化层输出的特征向量  $\bar{v}_n^1 = \{v_{n,1}^1, v_{n,2}^1, \dots, v_{n,r}^1\}$ ; 其中,  $F_{n,x}^M$  表示第M个加法卷积模块的特征序列  $F_n^M$  中的第x个特征图,  $C_M$  表示第M个加法卷积模块的特征序列  $F_n^M$  中的特征图个数,  $v_{n,r}^1$  表示所述自适应池化层输出的特征向量  $\bar{v}_n^1$  的第r个特征值, r 表示特征值的数量;

[0023] 步骤2.4、所述投影层和分类层的处理;

[0024] 步骤2.4.1、所述全连接投影层将自适应池化层输出的特征向量  $\bar{v}_n^1$  投影到特征空间,获得投影层特征向量  $\bar{v}_n^2 = \{v_{n,1}^2, v_{n,2}^2, \dots, v_{n,r}^2\}$ ; 其中,  $v_{n,r}^2$  表示所述投影层特征向量  $\bar{v}_n^2$  的第r个特征值;

[0025] 所述自适应池化层特征向量  $\bar{v}_n^1$  同时通过全连接分类层的处理,获得第n个属于不同类别的概率  $p_n = \{p_{n,1}, p_{n,2}, \dots, p_{n,a}, \dots, p_{n,k}\}$ ; 其中,  $p_{n,a}$  表示所述分类层输出的第n段脑电信号样本  $X_n$  属于第a类的概率; k 表示类别的数量;

[0026] 步骤3、从所述训练样本集X的若干段脑电信号样本中随机抽取若干个样本并构成一批次数据记为  $x = \{x_1, x_2, \dots, x_i, \dots, x_m\}$ ; 则对应的标签记为  $y = \{y_1, y_2, \dots, y_i, \dots, y_m\}$ ; 其中,  $x_i$  表示一批次数据中的第i个脑电信号样本,  $y_i$  表示  $x_i$  的样本标签, m 表示批次样本的数量;

[0027] 所述一批次数据按照步骤2.2-步骤2.4的过程进行处理后,由投影层输出特征向量  $V = \{\bar{v}_1^2, \bar{v}_2^2, \dots, \bar{v}_i^2, \dots, \bar{v}_m^2\}$ ; 其中,  $\bar{v}_i^2$  表示所述投影层输出的一批次数据中的第i个脑电信号样本的特征向量; 由所述分类层输出概率  $P = \{p_1, p_2, \dots, p_i, \dots, p_m\}$ ; 其中,  $p_i$  表示所述分类层输出的一批次数据中的第i个脑电信号样本的概率;

[0028] 利用式(1)-式(3)建立混合损失函数  $L_n$ :

[0029]  $L = \alpha L^{\text{sup}} + (1 - \alpha) L^{\text{cross-entropy}}$  (1)

$$[0030] \quad L^{\text{sup}} = - \sum_i \frac{1}{m_{y_i}} \log \frac{\sum_{j=1}^m 1_{[y_j=y_i, j \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_j^2 / \tau)}{\sum_{t=1}^m 1_{[t \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_t^2 / \tau)} \quad (2)$$

$$[0031] \quad L^{\text{cross-entropy}} = - \frac{1}{m} \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (3)$$

[0032] 式(1) - 式(3)中,  $\alpha$ 是调整两类误差权重的参数,  $L^{\text{sup}}$ 表示监督对比损失,  $L^{\text{cross-entropy}}$ 表示交叉熵损失,  $m_{y_i}$ 表示一批次样本中与第i个脑电信号样本具有相同标签的样本个数,  $1_{[y_j=y_i, j \neq i]}$ 表示满足条件 $y_j = y_i, j \neq i$ 时, 取值为1, 否则取值为0;  $\bar{v}_j^2$ 表示所述投影层输出的一批数据中的第j个脑电信号样本的特征向量,  $\tau$ 表示控制训练平滑度的超参数,  $\bar{v}_t^2$ 表示所述投影层输出的一批数据中的第t个脑电信号样本的特征向量;

[0033] 步骤4、基于训练样本集X, 使用Adam优化器对加法网络模型进行训练, 并计算混合损失函数L, 同时采用自适应学习率的方法调整训练过程中的学习率, 直到验证损失不再降低或者达到最大训练次数为止, 从而得到训练后的加法网络模型, 并用于对脑电信号进行分类。

[0034] 1、本发明提出了一种基于深度学习的加法网络模型, 首次在脑电信号分类中使用加法网络, 使用廉价的加法代替复杂的乘法运算, 实现了更低的计算成本和硬件成本, 同时保持了相同的准确度。

[0035] 2、本发明首次在脑电信号分类使用监督对比损失, 对比损失可以充分探索数据的内在联系, 将同一类的数据集中在一起, 同时远离不同类的数据, 结合交叉熵损失, 从而提高了脑电信号的分类性能。

[0036] 3、本发明是一种端到端的结构模型, 不需要预先对原始EEG信号进行手动去噪和特征预处理过程, 直接从原始EEG数据进行训练学习, 更符合深度学习数据驱动模式, 从而不需要大量专家经验和专业知识, 获得更好的泛化性。

## 附图说明

[0037] 图1为本发明网络结构示意图;

[0038] 图2为传统卷积计算的示意图;

[0039] 图3为本发明加法卷积计算的示意图;

[0040] 图4为本发明对比学习的示意图;

[0041] 图5为CHB-MIT数据库中脑电信号分类AUC效果对比图;

[0042] 图6为CHB-MIT数据库中脑电信号分类灵敏度效果对比图;

[0043] 图7为CHB-MIT数据库中脑电信号分类FPR效果对比图。

## 具体实施方式

[0044] 本实施例中, 一种基于加法网络和监督对比学习的脑电信号分类方法主要是利用加法网络来进行脑电信号分类。加法网络通过改变卷积过程中的相似性度量, 使用加法代替卷积中乘法, 从而减少计算开销, 结合监督对比学习, 使同类样本相互靠近, 不同类的样本相互远离, 最终达到准确的分类效果。如图1所示, 具体的说, 该方法是按如下步骤进行:

[0045] 步骤1、获取有标注信息的脑电信号数据集,并对脑电信号数据集中的原始脑电信号进行通道数据选择和样本分割的预处理,从而获得N段时长为T的脑电信号样本并构成训练样本集,记为 $X = \{X_1, X_2, \dots, X_n, \dots, X_N\}$ ,其中, $X_n \in \mathbb{R}^{W \times H}$ 表示第n段脑电信号样本,H表示脑电信号的通道数, $W = T \times s$ 表示采样点数,s表示脑电信号的采样率;令第n段脑电信号样本 $X_n$ 所对应的标签记为 $Y_n$ ,则训练样本集X所对应的标签集合记为 $Y = \{Y_1, Y_2, \dots, Y_n, \dots, Y_N\}$ ;本方法使用公开脑电癫痫数据集CHB-MIT和Kaggle;

[0046] 步骤2、建立加法网络模型,并包含:一维卷积层、M个加法卷积模块、自适应池化层、投影层、分类层;

[0047] 加法卷积模块由加法卷积层、加法卷积残差层构成;令第m个加法卷积块的加法卷积核大小为 $h_m$ ,步长为 $w_m$ ,且各加法卷积层之间以及各加法卷积残差层之间均采用ReLU激活函数和批归一化操作;其中,仅第一个加法卷积块后设置有最大池化操作; $m = 1, 2, \dots, M$ ;本方法设置 $M = 3$ ;  $h_1 = 11 \times 1, s_1 = 1 \times 1$ ;  $h_2 = 5 \times 5, s_1 = 2 \times 2$ ;  $h_3 = 5 \times 5, s_1 = 2 \times 2$ ;

[0048] 步骤2.1、对模型参数进行初始化:

[0049] 对所有卷积层的权重使用xavier\_uniform\_初始化;

[0050] 步骤2.2、将第n段脑电信号样本 $X_n \in \mathbb{R}^{W \times H}$ 输入加法网络模型中,先经过一维卷积层的时间特征提取和数据降维操作后,得到第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ ;其中, $F_{n,x}^0$ 表示一维卷积层输出的第n个一维卷积特征序列 $F_n^0$ 中的第x个特征图, $C_0$ 表示第n个特征序列 $F_n^0$ 中的特征图个数;因为使用的是原始的脑电信号,所以信号中包含噪声信息,使用一维卷积可以起到去噪的功能,同时可以降低数据维度大小,本实验使用的卷积核大小为 $21 \times 1$ ,步长为1,最大池化操作大小为 $8 \times 1$ ;

[0051] 步骤2.3、加法卷积模块的处理:

[0052] 步骤2.3.1、当 $m = 1$ 时,将第n个一维卷积特征序列 $F_n^0 = \{F_{n,1}^0, F_{n,2}^0, \dots, F_{n,x}^0, \dots, F_{n,C_0}^0\}$ 作为第m个加法卷积模块的输入,并记为第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ ;其中, $F_{n,x}^m$ 表示第m个加法卷积模块的特征序列 $F_n^m$ 中的第x个特征图, $C_m$ 表示第m个加法卷积模块的特征序列 $F_n^m$ 中的特征图个数;

[0053] 步骤2.3.2、第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积层的处理,得到第m个加法卷积层特征序列 $A_n^m = \{A_{n,1}^m, A_{n,2}^m, \dots, A_{n,x}^m, \dots, A_{n,C_m}^m\}$ ;其中, $A_{n,x}^m$ 表示第m个加法卷积层输出的第m个加法卷积层特征序列 $A_n^m$ 中的第x个特征图;

[0054] 第m个加法卷积模块的特征序列 $F_n^m = \{F_{n,1}^m, F_{n,2}^m, \dots, F_{n,x}^m, \dots, F_{n,C_m}^m\}$ 经过自身第m个加法卷积残差层的处理,得到第m个加法卷积残差层特征序列 $R_n^m = \{R_{n,1}^m, R_{n,2}^m, \dots, R_{n,x}^m, \dots, R_{n,C_m}^m\}$ ;其中, $R_{n,x}^m$ 表示第m个加法卷积残差层输出的第m个加法卷积残差层特征序列 $R_n^m$ 中的第x个特征图;传统卷积是通过计算特征图和滤波器之间的内积来计算相似度,而加法卷积是通过计算特征图和滤波器之间的L1距离来计算相似度;假设网络某一层的滤波器为 $F \in \mathbb{R}^{h \times w \times c_{in} \times c_{out}}$ ,其中,滤波器尺寸大小为 $h \times w$ , $c_{in}$ 和 $c_{out}$ 代表输入通道数和输出通道数;输

入特征图为  $I \in \mathbb{R}^{H \times W \times c_{in}}$ , 其中, H和W表示输入特征图尺寸大小; 则输出特征O的计算如式(1):

$$[0055] \quad O(a,b,c) = \sum_{r=0}^{h-1} \sum_{s=0}^{w-1} \sum_{t=1}^{c_{in}} I(a+r, b+s, t) \cdot F(r, s, t, c) \quad (1)$$

[0056] 式(1)中,  $1 \leq a \leq H, 1 \leq b \leq W, 1 \leq c \leq c_{out}$ , 输出特征O越大, 两者相似性越高, 如图2所示; 加法卷积通过将乘法换成减法(计算机中加法通过减法补码转换很方便) 计算L1距离, 计算如式(2):

$$[0057] \quad O(a,b,c) = - \sum_{r=0}^{h-1} \sum_{s=0}^{w-1} \sum_{t=1}^{c_{in}} |I(a+r, b+s, t) - F(r, s, t, c)| \quad (2)$$

[0058] 取L1距离的相反数作为相似性度量, 输出特征O越大, L1距离越小, 两者相似性越高, 如图3所示; 由于传统卷积计算出来的值可能为正或者负, 而加法卷积计算出来的值只能为负, 所以本文使用传统卷积中的批归一化进行处理, 这样就可以更好的使用传统的激活函数。

[0059] 步骤2.3.3、将第m个加法卷积层输出的特征序列  $A_n^m$  和第m个加法卷积残差层输出的特征序列  $R_n^m$  相加后, 得到第m个融合特征序列  $D_n^m = \{D_{n,1}^m, D_{n,2}^m, \dots, D_{n,x}^m, \dots, D_{n,C_m}^m\}$ ; 其中,  $D_{n,x}^m$  表示第m个融合特征序列  $D_n^m$  中的第x个特征图;

[0060] 步骤2.3.4、判断  $m=1$  是否成立, 若成立, 则对第m个融合特征序列  $D_n^m$  进行最大池化操作, 获得第m+1个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 否则, 将第m个融合特征序列  $D_n^m$  作为第m+1个加法卷积模块的特征序列  $F_n^{m+1} = \{F_{n,1}^{m+1}, F_{n,2}^{m+1}, \dots, F_{n,x}^{m+1}, \dots, F_{n,C_{m+1}}^{m+1}\}$ ; 其中,  $F_{n,x}^{m+1}$  表示第m+1个加法卷积模块的特征序列  $F_n^{m+1}$  中的第x个特征图;  $C_{m+1}$  表示第m+1个加法卷积模块的特征序列  $F_n^{m+1}$  中的特征图个数;

[0061] 步骤2.3.5、将m+1赋值给m; 并判断  $m > M$ , 若成立, 则进入步骤2.3.6; 否则, 返回步骤2.3.2;

[0062] 步骤2.3.6、将第M个加法卷积模块的特征序列  $F_n^M = \{F_{n,1}^M, F_{n,2}^M, \dots, F_{n,x}^M, \dots, F_{n,C_M}^M\}$  通过自适应池化层的处理, 获得自适应池化层输出的特征向量  $\bar{v}_n^1 = \{v_{n,1}^1, v_{n,2}^1, \dots, v_{n,r}^1\}$ ; 其中,  $F_{n,x}^M$  表示第M个加法卷积模块的特征序列  $F_n^M$  中的第x个特征图,  $C_M$  表示第M个加法卷积模块的特征序列  $F_n^M$  中的特征图个数,  $v_{n,r}^1$  表示自适应池化层输出的特征向量  $\bar{v}_n^1$  的第r个特征值, r表示特征值的数量;

[0063] 步骤2.4、投影层和分类层的处理;

[0064] 步骤2.4.1、全连接投影层将自适应池化层输出的特征向量  $\bar{v}_n^1$  投影到特征空间, 获得投影层特征向量  $\bar{v}_n^2 = \{v_{n,1}^2, v_{n,2}^2, \dots, v_{n,r}^2\}$ ; 其中,  $v_{n,r}^2$  表示投影层特征向量  $\bar{v}_n^2$  的第r个特征值;

[0065] 自适应池化层特征向量  $\bar{v}_n^1$  同时通过全连接分类层的处理, 获得第n个属于不同类别的概率  $p_n = \{p_{n,1}, p_{n,2}, \dots, p_{n,a}, \dots, p_{n,k}\}$ ; 其中,  $p_{n,a}$  表示分类层输出的第n段脑电信号样

本 $X_n$ 属于第 $a$ 类的概率; $k$ 表示类别的数量;通过投影层将特征向量投影到特征空间,使用归一化将它们的长度缩放为1,这样所有特征向量落到一个超球面上,然后使用对比损失将同类的投影特征聚集,不同类的特征向量远离,如图4所示;

[0066] 步骤3、从训练样本集 $X$ 的若干段脑电信号样本中随机抽取若干个样本并构成一批次数据记为 $x = \{x_1, x_2, \dots, x_i, \dots, x_m\}$ ;则对应的标签记为 $y = \{y_1, y_2, \dots, y_i, \dots, y_m\}$ ;其中, $x_i$ 表示一批次数据中的第 $i$ 个脑电信号样本, $y_i$ 表示 $x_i$ 的样本标签, $m$ 表示批次样本的数量;

[0067] 一批次数据按照步骤2.2-步骤2.4的过程进行处理后,由投影层输出特征向量 $V = \{\bar{v}_1^2, \bar{v}_2^2, \dots, \bar{v}_i^2, \dots, \bar{v}_m^2\}$ ;其中, $\bar{v}_i^2$ 表示投影层输出的一批次数据中的第 $i$ 个脑电信号样本的特征向量;由分类层输出概率 $P = \{p_1, p_2, \dots, p_i, \dots, p_m\}$ ;其中, $p_i$ 表示分类层输出的一批次数据中的第 $i$ 个脑电信号样本的概率;

[0068] 利用式(3)-式(5)建立混合损失函数 $L_n$ :

$$[0069] \quad L = \alpha L^{\text{sup}} + (1 - \alpha) L^{\text{cross-entropy}} \quad (3)$$

$$[0070] \quad L^{\text{sup}} = - \sum_i \frac{1}{m_{y_i}} \log \frac{\sum_{j=1}^m 1_{[y_j=y_i, j \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_j^2 / \tau)}{\sum_{t=1}^m 1_{[t \neq i]} \exp(\bar{v}_i^2 \cdot \bar{v}_t^2 / \tau)} \quad (4)$$

$$[0071] \quad L^{\text{cross-entropy}} = - \frac{1}{m} \sum_i [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (5)$$

[0072] 式(3)-式(5)中, $\alpha$ 是调整两类误差权重的参数, $L^{\text{sup}}$ 表示监督对比损失, $L^{\text{cross-entropy}}$ 表示交叉熵损失, $m_{y_i}$ 表示一批次样本中与第 $i$ 个脑电信号样本具有相同标签的样本个数, $1_{[y_j=y_i, j \neq i]}$ 表示满足条件 $y_j=y_i, j \neq i$ 时,取值为1,否则取值为0; $\bar{v}_j^2$ 表示投影层输出的一批次数据中的第 $j$ 个脑电信号样本的特征向量, $\tau$ 表示控制训练平滑度的超参数, $\bar{v}_t^2$ 投影层输出的一批次数据中的第 $t$ 个脑电信号样本的特征向量;

[0073] 步骤4、基于训练样本集 $X$ ,使用Adam优化器对加法网络模型进行训练,并计算混合损失函数 $L$ ,同时采用自适应学习率的方法调整训练过程中的学习率,直到验证损失不再降低或者达到最大训练次数为止,从而得到训练后的加法网络模型,并用于对脑电信号进行分类。因为相似度计算的方法改变,所以梯度反向传播的函数也发生改变,这导致了不同层之间的梯度大小差异变大,为了使网络能收敛并学习到更优的模型,本发明使用了自适应学习率的方法,根据每层的参数多数来调整学习率,计算如式(6)-式(7):

$$[0074] \quad \Delta F_1 = \eta \times \theta_1 \times \Delta L(F_1) \quad (6)$$

$$[0075] \quad \theta_1 = \frac{\lambda \sqrt{z}}{\|\Delta L(F_1)\|_2} \quad (7)$$

[0076] 式(6)-式(7)中, $\eta$ 表示整体学习率, $\theta_1$ 是网络第1层的局部学习率, $\Delta L(F_1)$ 是网络第1层的滤波器的梯度; $\lambda$ 表示控制局部学习率大小的超参数, $z$ 表示第1层滤波器 $F_1$ 的参数数量;

[0077] 具体实施中,加法网络和监督对比学习网络(SCL-AddNets)与一些先进的脑电信号分类深度学习方法例如一维卷积神经网络(1D+CNN)、深度卷积神经网络+多层感知机

(DCNN+MLP)、深度神经网络+双向长短期记忆网络(DCNN+Bi-LSTM),以及残差网络(ResCNN)进行对比。在CHB-MIT和Kaggle数据库上的性能指标如下表:

[0078] 表1.CHB-MIT数据库上不同方法对脑电信号分类的平均性能

[0079]		灵敏度(%)	AUC	FPR(\h)
	1D+CNN	88.7	0.881	0.172
	DCNN+MLP	87.8	0.861	0.208
	ResCNN	89.9	0.911	0.140
	SCL-AddNets	94.9	0.942	0.077

[0080] 表2.Kaggle数据库上不同方法对脑电信号分类的平均性能

[0081]		灵敏度(%)	AUC	FPR(\h)
	1D+CNN	80.9	0.808	0.134
	DCNN+MLP	82.9	0.811	0.156
	ResCNN	81.2	0.829	0.161
	SCL-AddNets	89.1	0.831	0.120

[0082] 表3.不同方法计算复杂度和参数数量对比

[0083]		参数量( $\times 10^6$ )	乘法次数	加法次数	耗能(mJ)	延迟
	1D+CNN	1.07	$0.80 \times 10^9$	$0.80 \times 10^9$	3.68	4.80
	DCNN+MLP	0.43	$0.45 \times 10^9$	$0.45 \times 10^9$	2.07	2.70
	ResCNN	0.12	$0.31 \times 10^9$	$0.31 \times 10^9$	1.43	1.86
	SCL-AddNets	0.12	$7.57 \times 10^6$	$0.54 \times 10^9$	0.51	1.11

[0084] 19名受试者的留一交叉验证结果如图5、图6、图7所示。结果分析:

[0085] 表1和表2实验结果表明,与脑电信号分类领域其他的深度学习方法1D+CNN、DCNN+MLP和ResCNN相比,SCL-AddNets在各项指标上都有提升,在两个数据库上能更准确的预测发作前期类的同时,降低在发作间期类中的错误报警次数。从表3中可以看出,SCL-AddNets将大量乘法运算换成了加法运算,在耗能和延迟上都有很大的提升。此外,从图4、图5、图6中可以发现,该模型在大多数受试者上都有明显的改善,对于不同受试者来说,不同类型脑电信号的类型区域和信号的分布是不一样的,说明该方法对不同受试者均有很好的识别能力和很强的泛化效果。

[0086] 综上所述,本发明充分利用原始EEG信号所含有的丰富脑电信息,使用加法网络减少计算成本,同时保持分类精度,结合监督对比学习,使同类的样本互相靠近,异类样本互相远离,达到更精确的脑电信号分类效果。在公开数据集CHB-MIT和Kaggle的二分类测试中,能更快、更准确的分类发作前期类的脑电数据,同时降低了发作间期类中的错误报警次数,优于多数的传统深度学习方法。

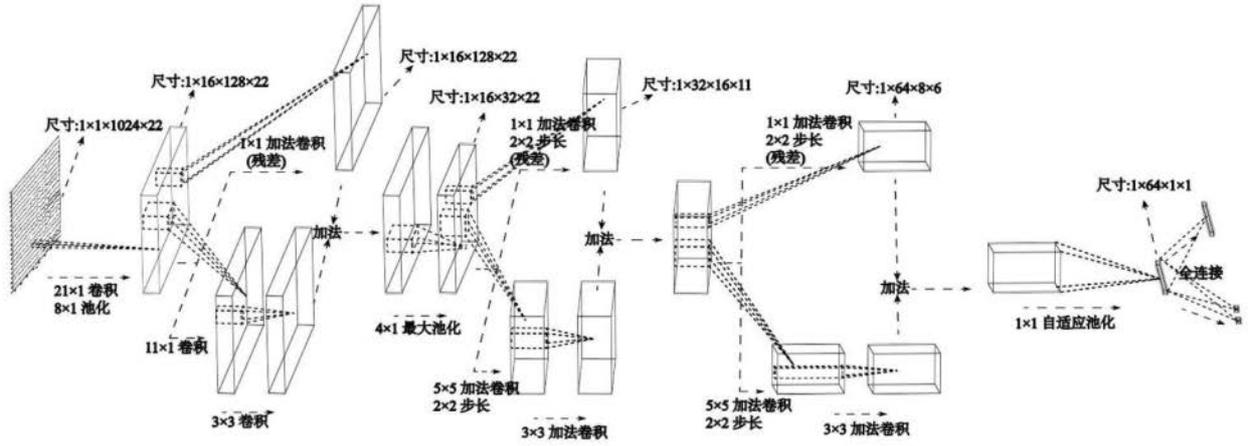


图1

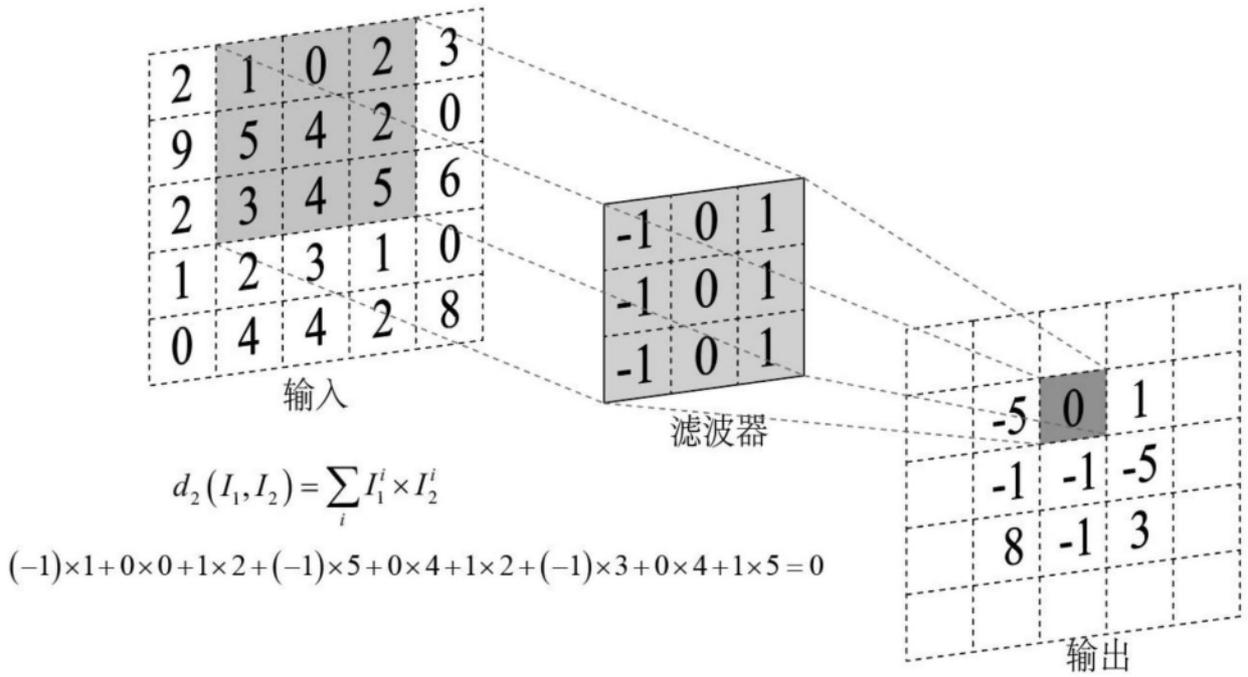


图2

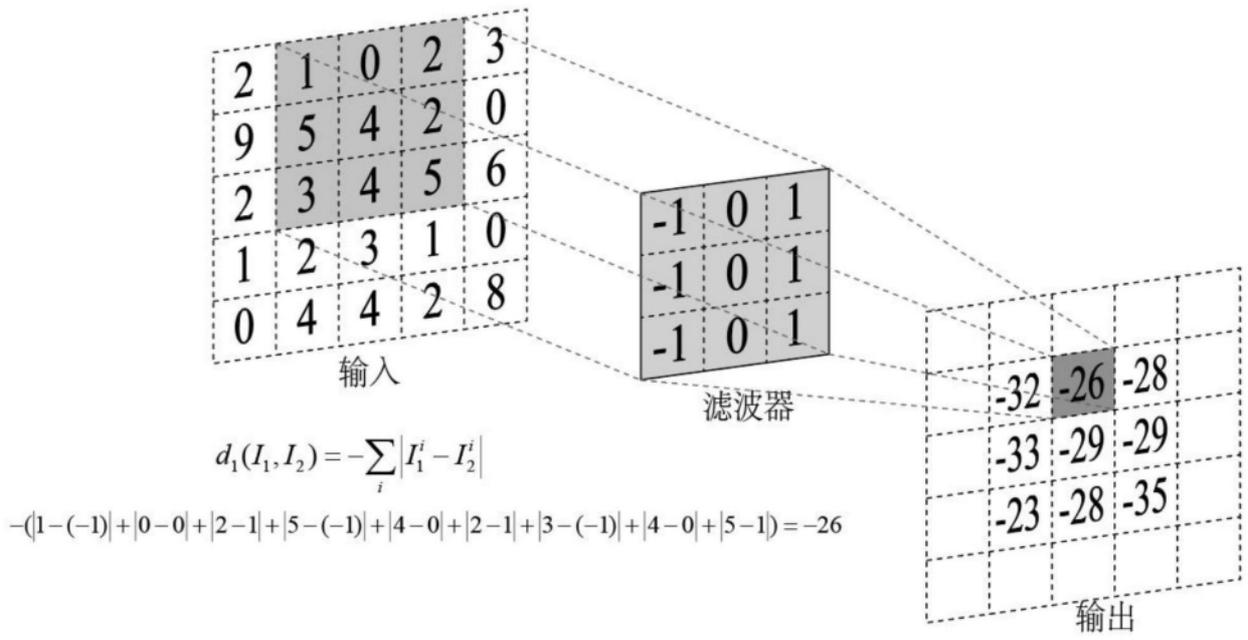


图3

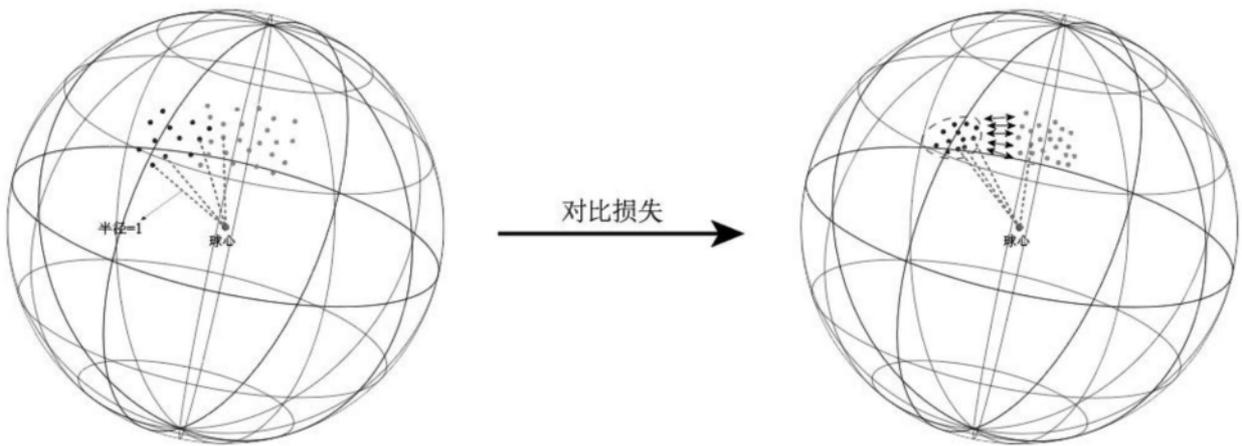


图4

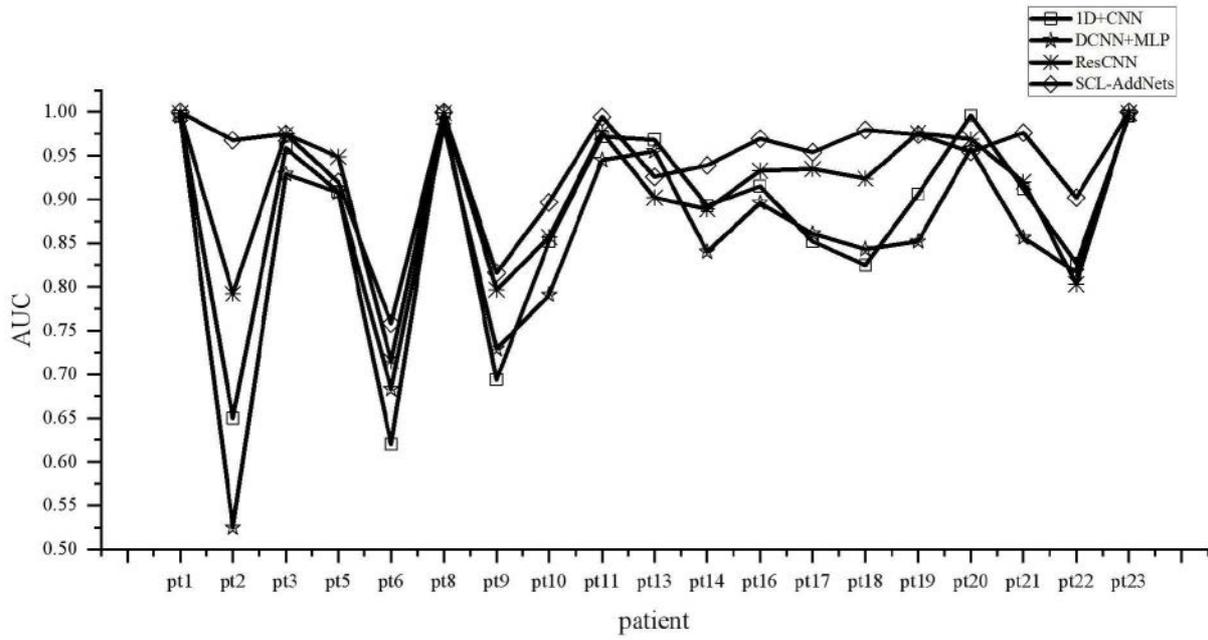


图5

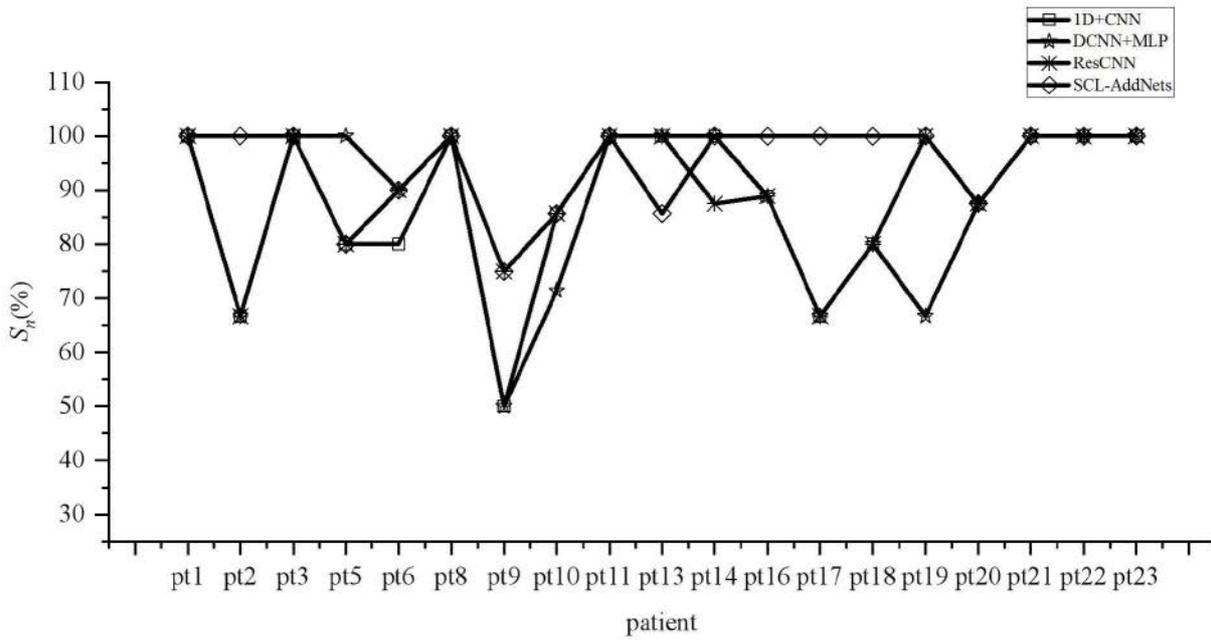


图6

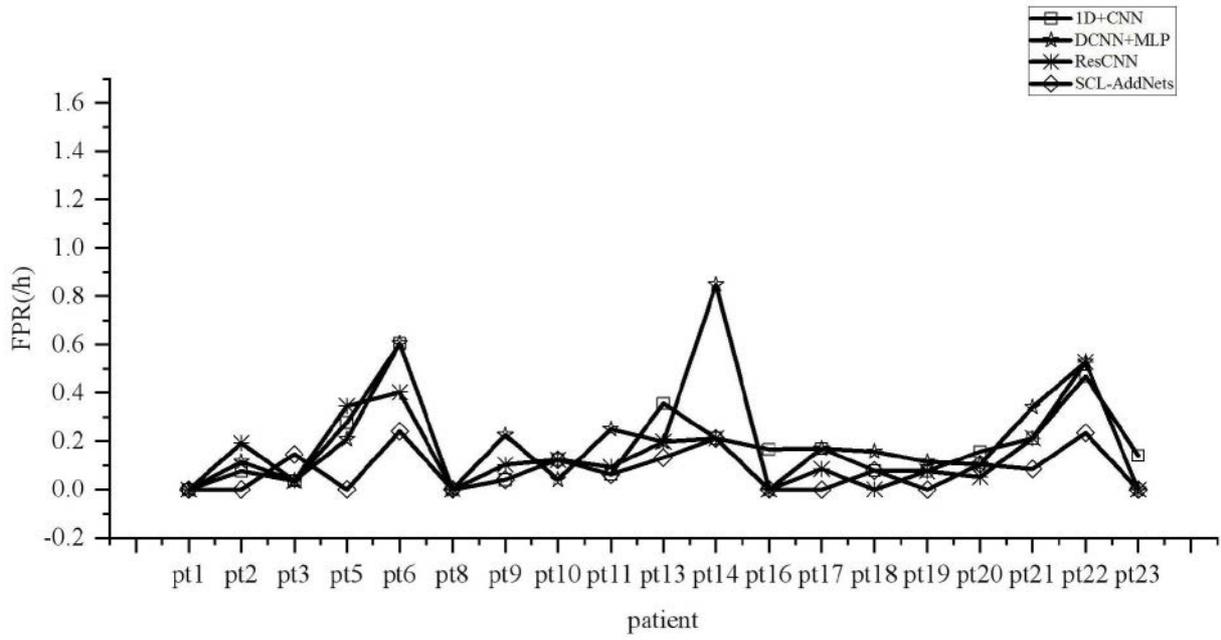


图7