

DOI:10.3969/j.issn.1005-202X.2022.09.017

医学信号处理与医学仪器

## 运动想象脑电多视角深度森林解码算法

郑龙鑫<sup>1</sup>, 苗敏敏<sup>1,2</sup>, 徐宝国<sup>3</sup>, 胡文军<sup>1,2</sup>

1. 湖州师范学院信息工程学院, 浙江 湖州 313000; 2. 浙江省现代农业资源智慧管理与应用研究重点实验室, 浙江 湖州 313000;  
3. 东南大学仪器科学与工程学院, 江苏 南京 210096

**【摘要】**针对运动想象脑电信号特征提取操作繁琐及解码精度低等问题,提出一种基于多视角深度森林的运动想象脑电解码算法。首先,通过子频带滤波及时间窗口划分对原始信号进行细粒度分析,生成空时频能量特征。然后,对上述空时频能量特征分别进行稀疏选择和时序扫描得到重要的浅层能量特征及多示例先验类别特征。继而,将上述两类特征进行融合构建运动想象脑电多视角特征集。最后,利用级联森林的逐层特征变换挖掘深层次的抽象特征进行脑电解码。根据脑机接口竞赛数据和自行采集的数据进行算法测试,并与单视角特征模型、传统共空间模式方法以及深度神经网络算法进行对比。在2个脑机接口竞赛数据集和1个真实数据集上分别取得了91.4%、75.2%和70.7%的最高平均分类准确率,结果表明该文所提多视角深度森林算法具有更优的分类识别准确率。

**【关键词】**运动想象脑电信号;解码算法;多视角;特征提取;深度森林

**【中图分类号】**R318;TP391.4

**【文献标志码】**A

**【文章编号】**1005-202X(2022)09-1159-08

## Multi view deep forest-based decoding algorithm for motor imagery EEG

ZHENG Longxin<sup>1</sup>, MIAO Minmin<sup>1,2</sup>, XU Baoguo<sup>3</sup>, HU Wenjun<sup>1,2</sup>

1. School of Information Engineering, Huzhou University, Huzhou 313000, China; 2. Zhejiang Province Key Laboratory of Smart Management and Application of Modern Agricultural Resources, Huzhou 313000, China; 3. School of Instrument Science and Engineering, Southeast University, Nanjing 210096, China

**Abstract:** A decoding algorithm based on multi view deep forest is proposed for solving the problems of complicated feature extraction and low decoding accuracy of motor imagery EEG signal. The energy feature in spatial-temporal-frequency domains which is generated by fine-grained analysis using subband filtering and time window division are processed with sparse selection and temporal scanning for obtaining important shallow energy features and multi instance a priori category features to construct a multi view feature set. Then the hierarchical feature transformation of cascaded forests is used to mine deep level abstract features for EEG coding. The algorithm is tested on two BCI competition datasets and a self-collected dataset, and it is compared with single view feature models, traditional CSP methods and deep neural network algorithms. The proposed method achieves the highest average classification accuracy (91.4%, 75.2% and 70.7%, respectively) in 2003 BCI competition dataset III, 2008 BCI competition dataset 2b and self-collected dataset, which suggests that the decoding algorithm based on multi view deep forest has better classification performance.

**Keywords:** motor imagery EEG signal; decoding algorithm; multi view; feature extraction; deep forest

### 前言

**【收稿日期】**2022-03-06

**【项目基金】**国家自然科学基金(62101189, U20A20228, 61772198);  
江苏省前沿引领技术基础研究专项(BK20192004);浙江省  
基础公益研究项目(LGN18F020002)

**【作者简介】**郑龙鑫, 硕士研究生, 研究方向: 机器学习及其在脑信息  
解码中的应用, E-mail: 1244542799@qq.com

**【通信作者】**苗敏敏, 博士, 硕士生导师, 研究方向: 生物医学信号处  
理、机器学习及其在脑信息解码中的应用, E-mail:  
02746@zjhu.edu.cn

脑机接口(Brain Computer Interface, BCI)系统不依赖于外围神经和肌肉组织,通过分析大脑神经活动识别人体运动意图控制外部设备,提供一种新的人机交互通道<sup>[1-3]</sup>。在神经损伤患者运动康复及生活辅助<sup>[4]</sup>、人脑状态监测<sup>[5]</sup>等众多领域有重要应用。基于头皮脑电(Electroencephalogram, EEG)的运动想象BCI可根据受试者运动意图控制外部辅助运动或康复训练设备<sup>[6-7]</sup>,持续刺激患者受损的运动感知反馈回路和初级运动皮层,并借助大脑的可塑性恢复脑区功能,在帮助截瘫及中风患者恢复基本自主能力方面具有重要的现实意义<sup>[8]</sup>。

EEG 信号通过脑脊液、头骨、软组织和头皮层层传导,空间分辨率和频率范围受限,信噪比低,具有显著的非线性非平稳特性,造成 EEG 特征难以学习。共空间模式(Common Spatial Pattern, CSP)常用于提取 EEG 信号中区分度较高的特征向量<sup>[9]</sup>。然而,CSP 对带通滤波的频段选择非常敏感。滤波器组共空间模式(Filter Band Common Spatial Pattern, FBCSP)<sup>[10]</sup>将一个宽频带划分为多个较小的子频段,然后使用互信息筛选子频段的 CSP 特征。稀疏滤波器组共空间模式(Sparse Filter Band Common Spatial Pattern, SFBCSP)<sup>[11]</sup>同样将一个宽频带划分为多个较小的子频段,使用稀疏回归模型提取重要的 CSP 特征。在提取出 CSP 特征后再使用支持向量机(Support Vector Machine, SVM)、随机森林和线性判别分析(Linear Discriminant Analysis, LDA)等分类器对特征进行分类。传统的特征工程算法通常需要人工设计,严重依赖领域知识,并且特征工程和特征分类通常具有不同的目标函数<sup>[12]</sup>,容易造成信息丢失。深度神经网络采用层次结构对信息进行分层处理,可充分挖掘 EEG 和运动想象语义间的复杂关系,从而实现自动特征工程。卷积神经网络(Convolutional Neural Network, CNN)目前广泛应用于运动想象 BCI 领域中。文献[13]采用导联投射方法获取运动想象 EEG 空间和时序表示,随后通过混合尺度卷积模块学习抽象特征。文献[14]首先采用小波核进行第 1 层的时频转换,然后通过第 2 个卷积层进行空间滤波处理。文献[15]提出一种新的基于电极位置的 EEG 三维表示用于进行多分支 CNN 模型训练。文献[16]提出一种融合时空特征的深度 CNN 进行运动想象 EEG 分类。

尽管深度神经网络在运动想象 EEG 解码中取得较好结果,但仍存在以下问题:深度神经网络具有大量超参数,并且其优良性能建立在精细的参数调整上;当训练数据量不足时,难以提取到具有表征性的特征并容易出现过拟合现象;现有深度神经网络的复杂层次结构及大量参数容易造成模型可解释性缺失并逐步“黑箱”化。考虑到深度神经网络的 3 个重要成功因素,即逐层处理、模型内特征变换和足够的

模型复杂度,文献[17]提出了深度森林模型。不同于神经网络通过反向传播更新可微非线性模块参数,深度森林是一种基于不可导组件的深度学习方法,本质上是一种新的决策树集成模型,使用堆叠结构逐层进行表征学习,挖掘深层次的抽象特征表达。相较于深度神经网络,深度森林模型超参数较少,不需要根据反向传播算法进行表示学习,同时其性能对于超参数设置具有较好的鲁棒性。此外,深度森林模型的结构无需预先设置,其模型复杂度由训练数据规模自适应确定,因此该模型适用于不同规模的数据集,目前在推荐系统、癌症疾病诊断、故障诊断等方面取得了与深度神经网络相当的效果<sup>[18]</sup>,但在运动想象 EEG 解码方面的研究及应用相对较少。

深度森林是由多粒度扫描模块和级联森林结构组成的一种典型集成学习模型,增加输入特征多样性及互补性是提升集成分类器性能的关键手段。多视角学习技术利用互补原则或共识原则,被广泛应用于 EEG 信号的癫痫检测中<sup>[19]</sup>。考虑到运动想象 EEG 具有显著的空间-频率-时间域特性,本文首先通过子频带滤波及时间窗口划分对原始信号进行细粒度分析和局部能量特征生成,并对特征进行稀疏选择保留重要特征;同时,为了进一步提升时序感知和表示学习能力,对上述 EEG 时频能量特征矩阵按时间轴进行扫描得到先验类别知识;随后,将浅层能量特征和扫描所得的先验类别特征进行组合构造出多视角特征集;最后,使用级联森林的逐层特征变换挖掘深层次的抽象特征用于分类识别。根据 BCI 竞赛数据集和实际采集的运动想象 EEG 数据集对本文所提出的多视角深度森林(Multi View Deep Forest, MVDF)进行测试,通过与相关的深度神经网络方法对比,验证本文方法的有效性。

1 数据集与预处理

实验数据包含第 II 届 BCI 竞赛数据集 III 和第 IV 届 BCI 竞赛数据集 2b 以及 1 个自行采集的数据集,3 个数据集的详细描述见表 1。

第 II 届 BCI 竞赛数据集 III 记录了 1 位 25 岁女性受试者左右手运动想象 EEG 信号,采集分为 7 个阶

表 1 实验数据集组成和描述

Table 1 Composition and description of experiment datasets

数据集	被试者个数	选用 EEG 通道	样本个数	采样频率/Hz	运动想象类别数
BCI II (III)	1	C3,C4	280	128	2
BCI IV (2b)	9	C3,C4	400	250	2
真实数据集	5	C3,C4	160	1 000	2

段,每个阶段进行40次试验,共计280次试验。每次试验共持续9 s,实验开始的前2 s为休息时间,2~3 s屏幕出现“+”号提示,3~9 s受试者根据屏幕上的箭头指向进行运动想象。第IV届BCI竞赛数据集2b采集自9名右利手、视觉良好的受试者。EEG信号采样频率为250 Hz,经过0.5~100.0 Hz的带通滤波处理和50 Hz的陷波滤波处理。该数据集的训练数据集中共包含3个阶段,其中前两个阶段无反馈,后一个阶段包含反馈。在无反馈阶段,每次试验均以“+”号和声学提示开始,在第3秒时随机显示持续1.25 s向左或右的箭头,4~7 s间受试者根据指示进行运动想象。每个阶段均采集左右手运动想象EEG样本120个(左、右手各60个),两个阶段共包含240个样本。在有反馈阶段,试验开始时出现灰色笑脸,在3.0~7.5 s,受试者需根据箭头指示进行左右手运动想象以完成指定的任务。本文使用上述3个阶段内的EEG数据进行算法性能评估,样本总量为400。

本文进一步选用Neuroscan公司生产的SynAmps II型EEG采集系统并根据国际标准10/20放置电极,采集左右手运动想象EEG。EEG采样频率为1 000 Hz,经过0.5~200.0 Hz的带通滤波处理,为了降低计算开销,将原始EEG降采样至100 Hz。该数据集共包含5名被试者,每一名被试者在同一天内共进行4个阶段的运动想象实验,每个阶段包含左、

右手运动想象任务各20个,因此每一名被试者的样本总量为160。在每一次试验中,前4 s为休息时间,4~5 s为提示准备时间,5~9 s内被试者根据视觉指示完成运动想象任务。

## 2 研究方法

深度森林是一种决策树森林的集成模型,包含多粒度扫描模块和级联森林两部分<sup>[17]</sup>,通过多粒度扫描模块增强特征的多样性,并利用级联森林增加模型的复杂度<sup>[20]</sup>。

### 2.1 扫描模块

图1所示为二分类场景下的扫描模块示意图。假设输入样本的特征尺寸为 $5 \times 7$ ,使用滑动窗口扫描原始特征,每一次扫描提取的特征被称为1个示例,示例具有与原始特征一样的类别标签。滑动窗口的大小设为 $1 \times 7$ ,采用无重叠窗口的移动方式,每次向下移动1个单位,则得到5个示例。假设训练数据集中共有 $N$ 个样本,经过上述扫描操作共得到 $N \times 5$ 个示例。将所得的所有示例用于随机森林(Random Forest, RF)及完全随机森林(Complete Random Forest, CRF)模型的训练。训练完毕后,针对单个输入样本,RF及CRF均会生成5个二分类概率向量,最终拼接为尺寸为 $20 \times 1$ 的特征向量。

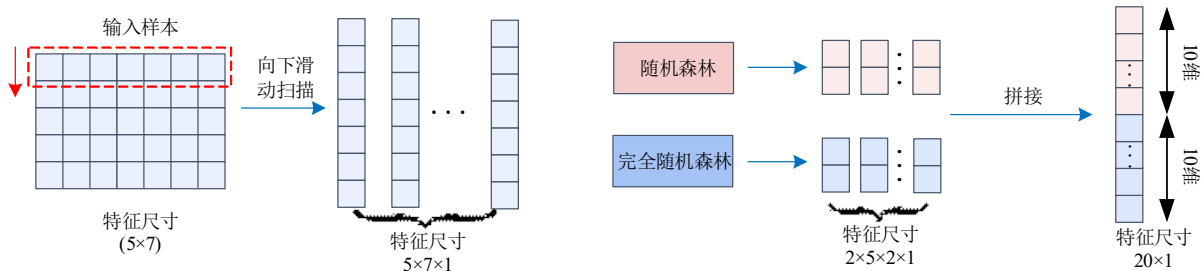


图1 扫描结构(二分类场景)  
Figure 1 Scanning structure (two classification scenarios)

### 2.2 级联森林

级联森林的结构如图2所示。中间层接受上一层的输出特征,并将处理后的结果和原始特征拼接继续输出至下一层。为了增强特征的多样性,每一层都包含相同数量的RF和CRF,两者的差异在于决策树的分枝策略。RF随机选择 $\sqrt{d}$ 个特征( $d$ 是输入特征的维数)并选择基尼不纯度下降最大的特征进行分枝,而CRF则随机选择任意一个特征属性进行分枝。级联森林中每个森林是多棵决策树的集合,并且每棵决策树会生长到每个叶子结点只包含相同类别的示例或不超过指定数量的示例。

给定一个示例,则它所在叶子节点中可能包含同一类别或不同类别的训练样本。计算该示例所在叶子节点中不同类别样本的占比,然后平均同一个森林中所有决策树的类分布概率,最终得到所在森林的类别分布估计<sup>[21]</sup>。每个森林都使用 $k$ 折交叉验证降低过拟合的风险,最后输出的类向量是 $k$ 次实验的均值。当级联森林拓展新层级时,会使用验证集评估整个级联森林的分类效果。如果当前模型效果没有显著提升,则会停止生长<sup>[17]</sup>。因此,级联森林的层级是自适应的,可适应不同规模的数据集。



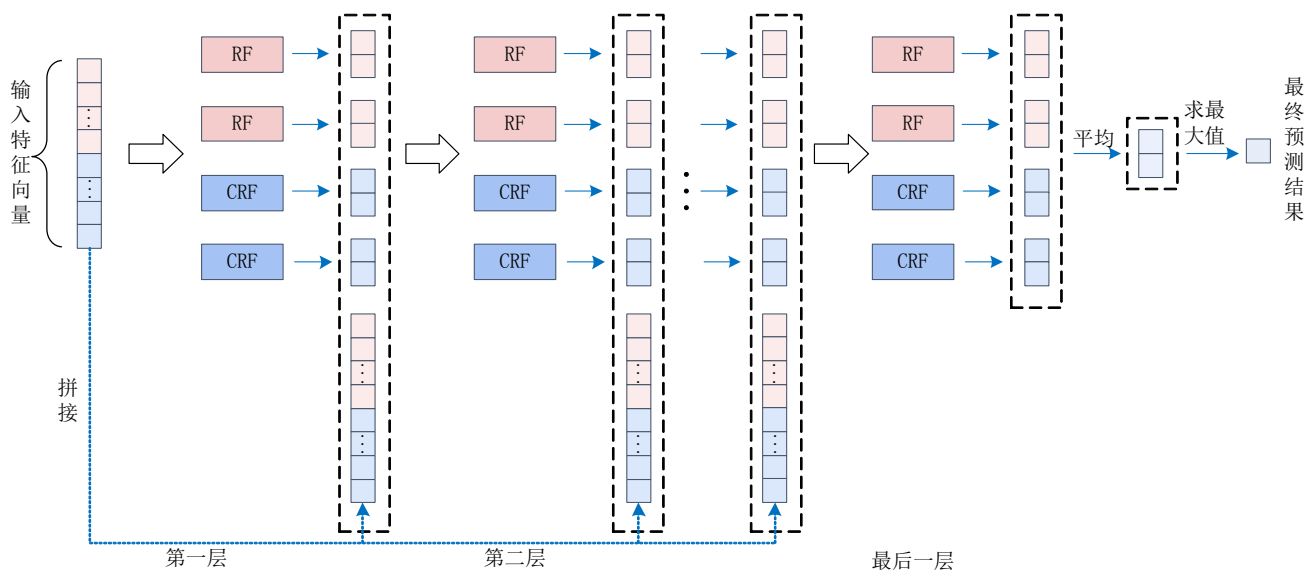


图2 级联森林  
Figure 2 Cascade forest

2.3 运动想象 EEG 空时频特征生成

运动想象BCI系统具有明显对侧效应的事件相关去同步(Event-Related Desynchronization, ERD)和事件相关同步(Event-Related Synchronization, ERS)现象,表现为 EEG 信号节律成分的短暂振幅衰减和增强。现有研究表明,ERD/ERS 现象通常出现在初级运动皮层,且考虑到具备高实用性的BCI系统需采用少量电极<sup>[22]</sup>,使用 C3 和 C4 导联的信号生成空时频特征。选择固定时间窗口和滑动步长对 EEG 数据进行时序切分。然后,针对单一电极导联特定时间窗口内的 EEG 信号进行子频带滤波,在 4~40 Hz 宽频段内,设置子频带宽度为 4 Hz,滑动步长为 2 Hz,共得到 17 个重叠的子频带。针对单一电极导联特定时间窗口内的任一子频带,分别计算其 EEG 能量特征,流程如图 3 所示。

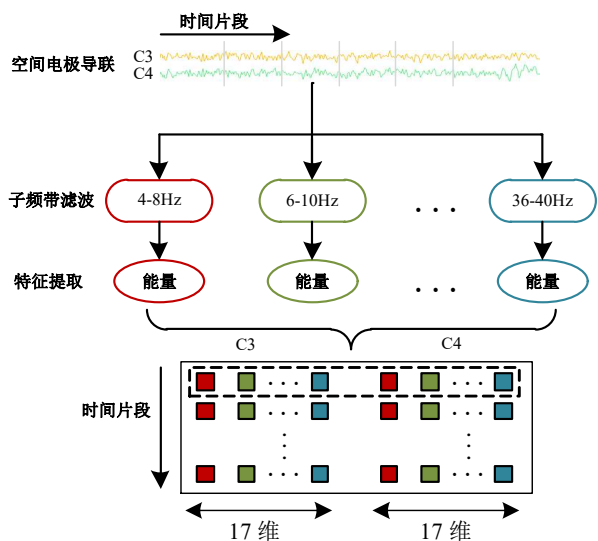


图3 特征生成流程图  
Figure 3 Flowchart of feature generation

$$P = \log(\text{var}(X)) \tag{1}$$

其中, $X$ 为 EEG 信号。最后,将 C3 和 C4 空间电极导联处不同子频带内的能量特征进行横向拼接,并按时间轴进行纵向扩展,得到最终的特征矩阵。

2.4 MVDF

基于生成的原始空时频特征矩阵,本文提出一种融合浅层能量特征和先验类别特征的多视角特征学习方法,进一步利用深度级联森林进行逐层特征变换挖掘深层次的抽象特征进行分类识别,具体模型如图 4 所示。

原始的空时频特征矩阵中包含多个子频带及时间窗口内的能量特征,考虑到 ERD/ERS 现象通常出现在局部的子频带及时间段内,因此原始特征矩阵中的特征元素在重要性方面存在较大差异,并且包含较多的冗余特征。基于以上分析,针对浅层的局部空时频能量特征,本文利用 LASSO 模型进行属性重要性度量及特征选择。LASSO 模型使用  $l_1$  正则化约束模型的复杂度,具体如公式(2)所示:

$$\text{loss}(\beta) = ||y - X^T \beta||^2 + \varphi ||\beta||_1 \tag{2}$$

其中, $\beta$ 为回归系数,参数  $\varphi$  决定回归系数被压缩的程度,通过上式可将较小的回归系数压缩至 0 并删除系数为 0 的冗余特征。

使用扫描模块进行特征转化,获得样本的先验类别特征。本文根据尺寸为 1×34 的窗口获取示例,在时间维度上按照步长为 1 的设置进行滑动,利用所得示例训练 RF 和 CRF 并生成类别概率特征。最后,将扫描模块输出的类别概率特征和经过选择后的浅层空时频能量特征进行拼接,输入到级联森林。实际分类应用中包含训练和测试两个过程,表 2 是本文模型的训练和测试详细过程。

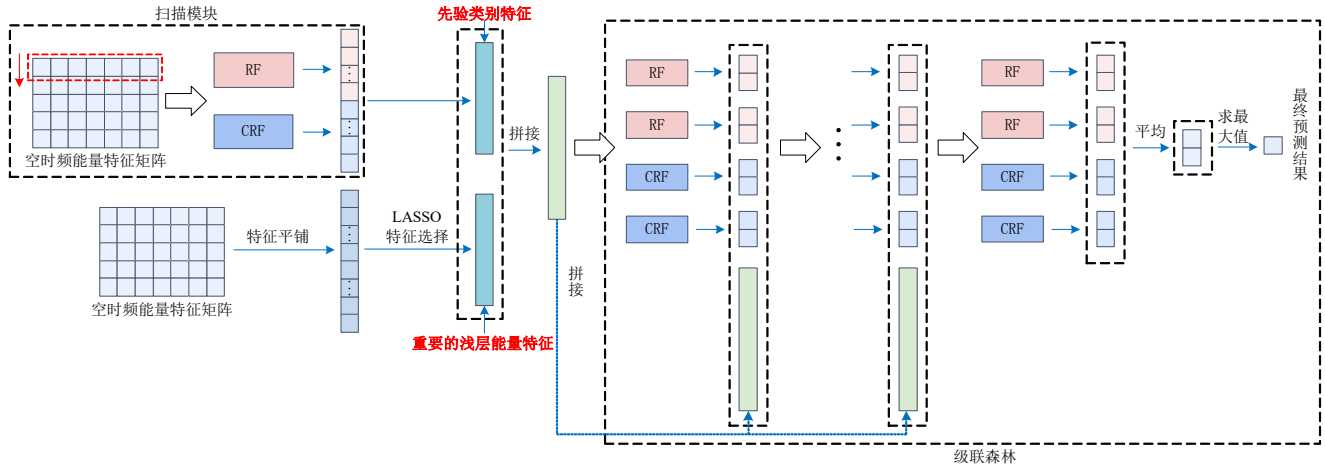


图4 多视角深度森林模型结构图

Figure 4 Structure of multi view deep forest model

表2 MVDF模型的训练及测试过程

Table 2 Training and testing processes of multi view deep forest model

训练过程:
步骤1 对C3和C4导联处的EEG信号进行子频带滤波,并提取不同时间段内的能量,获取原始的特征矩阵;
步骤2 将原始特征矩阵输入扫描模块,训练决策树森林;
步骤3 将原始特征矩阵平铺为一维特征向量,训练LASSO回归模型;
步骤4 将扫描模块输出的类别概率特征和经LASSO模型选择后的能量特征进行拼接,训练级联森林。
测试过程:
步骤1 对C3和C4导联处的EEG信号进行子频带滤波,并提取不同时间段内的能量,获取原始的特征矩阵;
步骤2 将原始特征矩阵输入扫描模块,根据决策树森林得到类别概率特征;
步骤3 将原始特征矩阵平铺为一维特征向量,然后使用LASSO模型对一维特征向量进行选择得到浅层能量特征;
步骤4 将类别概率特征和浅层能量特征进行拼接,输入级联森林,得到分类预测结果。

本文的MVRF模型中的扫描模块包含1个RF和CRF,2个森林都由树深为4的30棵决策树组成。针对级联森林部分,每一层由2个RF和2个CRF组成,每个森林包含深度为4的50棵决策树。对于一个二分类任务,每一个森林会输出一个二维的类别概率向量,4个森林所生成的4个类别概率向量会与原始特征拼接输入到下一层,并对最后一层输出结果进行求均值及最大值操作得到最终分类预测标签。

## 2.5 模型可解释性

可解释性是评价人工智能模型性能的重要指标。MVRF模型是一种决策树森林集成算法,本文采用决策树模型可视化及特征重要性评价等分析手段研究模型可解释性。CART决策树选择基尼不纯度下降最大的特征进行分枝,单一节点的基尼不纯度计算公式为:

$$\text{Gini}(D) = 1 - \sum_{k=1}^K \left( \frac{C_k}{|D|} \right)^2 \quad (3)$$

其中, $D$ 为此节点处的样本集合, $C_k$ 为集合 $D$ 中属于第 $k$ 类的样本子集, $K$ 为类别总数, $|\cdot|$ 为取得集合内

样本个数的操作。假设样本集合 $D$ 根据特征属性 $A$ 切分为子集 $D_l$ 和 $D_r$ ,切分之后的基尼不纯度计算公式为:

$$\text{Gini}(D|A) = \frac{|D_l|}{|D|} \text{Gini}(D_l) + \frac{|D_r|}{|D|} \text{Gini}(D_r) \quad (4)$$

在单一节点上遍历所有特征,选择使得 $\text{Gini}(D) - \text{Gini}(D|A)$ 最大的特征,即为该节点的最优分裂特征。假设节点 $D$ 根据特征 $A$ 分枝,则节点 $D$ 的基尼不纯度下降为 $\Delta\Phi(D)$ ,计算公式为:

$$\Delta\Phi(D) = \frac{|D|}{N} \left( \text{Gini}(D) - \frac{|D_l|}{|D|} \text{Gini}(D_l) - \frac{|D_r|}{|D|} \text{Gini}(D_r) \right) \quad (5)$$

其中, $N$ 为总样本数, $|D|$ 为节点 $D$ 的样本数, $|D_l|$ 和 $|D_r|$ 分别为节点 $D$ 分枝后左子树和右子树的样本数。设决策树 $T$ 中按照特征 $A$ 进行分枝的节点集合为 $V$ ,特征 $A$ 在决策树 $T$ 上的基尼不纯度减少总和为 $\text{GD}(T,A)$ ,则特征 $A$ 在RF上的重要性评价指标

GI( $A$ )即为特征 $A$ 在所有决策树上基尼不纯度减少量的总和<sup>[23]</sup>,GD( $T, A$ )和GI( $A$ )的计算公式分别为:

$$GD(T, A) = \sum_{\eta \in V} \Delta \Phi(\eta) \quad (6)$$

$$GI(A) = \sum_{T \in Q} \sum_{\eta \in V} \Delta \Phi(\eta) \quad (7)$$

公式(7)中 $Q$ 为RF所包含的决策树的集合。

### 3 结果与分析

#### 3.1 第II届BCI竞赛数据集III结果分析

针对该数据集,考虑到ERD/ERS现象的触发具有一定的滞后性并持续较短时间<sup>[8]</sup>,本文选取指示标志出现后的1.0~3.5 s数据段进行分析,设置时间窗口为0.5 s、步长为0.5 s进行时序扫描,通过子频带滤波及空时频能量特征提取生成尺寸为 $5 \times 34$ 的原始特征矩阵,LASSO回归正则化系数 $\varphi$ 设置为0.08,使用140个样本的训练集进行MVDF模型训练,并使用140个样本的测试集进行分类识别准确率计算。

为了有效评估MVDF算法的性能,针对性地选取应用于该数据集几种代表性的CSP方法、深度学习算法以及竞赛优胜者进行比较。对比算法包括CSP、FBCSP和SFBCSP,文献[24]中的CNN、堆叠自编码器(Stacked Auto Encoder, SAE)和CNN-SAE,第II届BCI竞赛第1名以及文献[25]中的卷积深度信念网络(Convolutional Deep Belief Network, CDBN)。CSP方法中将C3、Cz和C4导联的原始信号进行4~40 Hz的带通滤波处理然后提取CSP特征进行分类,FBCSP方法使用与本文相同的子频段提取C3、Cz和C4导联的CSP特征并挑选互信息最高的16个特征进行分类,SFBCSP方法中同样使用与本文相同的子频段提取C3、Cz和C4导联特征,然后使用正则化系数 $\varphi$ 为0.01的LASSO模型提取特征进行分类。可以看到,MVDF算法的分类准确率达到91.4%,高于传统的CSP、FBCSP和SFBCSP方法,并且高于CNN(89.3%)、SAE(60%)、CNN-SAE(90%)及CDBN(88.2%)等4种深度神经网络算法以及第II届BCI竞赛第1名(89.3%),验证了本文算法的有效性。

本文进一步根据该数据集进行模型可解释性分析,具体根据扫描模块中的RF模型进行空频特征重要性评估。RF使用有放回抽样,任意样本被选中 $t$ 次的概率服从 $\lambda = 1$ 的泊松分布,计算公式为:

$$P(X = t) = \frac{\lambda^t}{t!} e^{-\lambda}, \quad t = 0, 1, 2, \dots \quad (8)$$

其中, $t$ 为一次实验内样本被抽中的次数, $1 - (1/e) \approx 0.632$ 为1次实验内样本被抽中的平均发生率。根据上式,任一样本至少被选中1次的概率为 $1 - (1/e) \approx 0.632$ 。因此,在对随机森林的基分类器决策

树进行训练时,约有36.8%的原始样本未被使用。

图5是RF某棵决策树的可视化结果,实验中RF的输入示例数为700( $5 \times 140$ ),140为训练样本数,5为时间窗口数,图中决策树的训练使用了434个不重复示例,约38%的示例未被使用。图中的samples代表该节点包含的不重复的示例数,gini代表该节点的基尼不纯度,value是该节点对应类别的示例数,class为节点对应的类别标签。从图中可以观察到,该决策树的根节点利用C3电极导联的8~12 Hz频段内的能量特征作为分枝特征。根节点的左子树使用的分枝特征为C4电极导联的10~14 Hz频段内的能量特征,对应的阈值为-7.63,该节点包含235个不重复示例,类别1和2对应的示例数(含重复)分别为119和252,根据多数投票规则,该节点对应的类别为2。针对C4电极导联的10~14 Hz频段内的能量这一特征,根据式(5)、式(6)可计算出它在该决策树中的特征重要性为0.073。进一步根据式(5)~式(7)对C3和C4电极导联的17个子频段内的能量特征计算其在RF中的特征重要性,图6所示为重要性排名前20的特征。从图中可以看到,C3和C4导联处的8~12 Hz和10~14 Hz频段内的能量特征重要性较高,而8~14 Hz主要覆盖了与左右手运动想象任务紧密相关的运动感知 $\mu$ 节律<sup>[5,8]</sup>,一方面说明模型能自适应地选择重要特征,另一方面也表明模型的参数具有良好的神经生理学解释。

#### 3.2 第IV届BCI竞赛数据集2b结果分析

针对该数据集,采用每名被试者的 $10 \times 10$ 折交叉验证的平均分类准确率评估算法性能。选取C3和C4导联处3.5~7.0 s内的信号作为实验数据,按照时间间隔1 s、步长0.5 s划分得到6个时间段进行空时频能量特征提取,并进行零均值规范化处理生成尺寸为 $6 \times 34$ 的原始特征矩阵,LASSO回归正则化系数设置为0.01。使用两种单视角特征对比,验证多视角特征的有效性,分别为:(1)先验类别特征+级联森林;(2)浅层能量特征+级联森林。此外,对比算法还包括3.1节相同的CSP、FBCSP和SFBCSP方法,CNN和SAE两种典型的深度神经网络算法,具体比较结果如表3所示。从表3中可以观察到,MVDF算法在4名被试者上取得了最优的分类识别结果,相较于先验类别及浅层能量等单视角特征,平均分类准确率分别提升了1.2%和0.4%,说明多视角特征能增加特征多样性并提高分类准确率。此外,相较于CNN和SAE这两种典型的深度神经网络模型,MVDF的平均分类准确率分别提升了0.4%和17.5%。因此,相比于单一的深度神经网络模型,本文算法能取得持平甚至更优的分类效果。



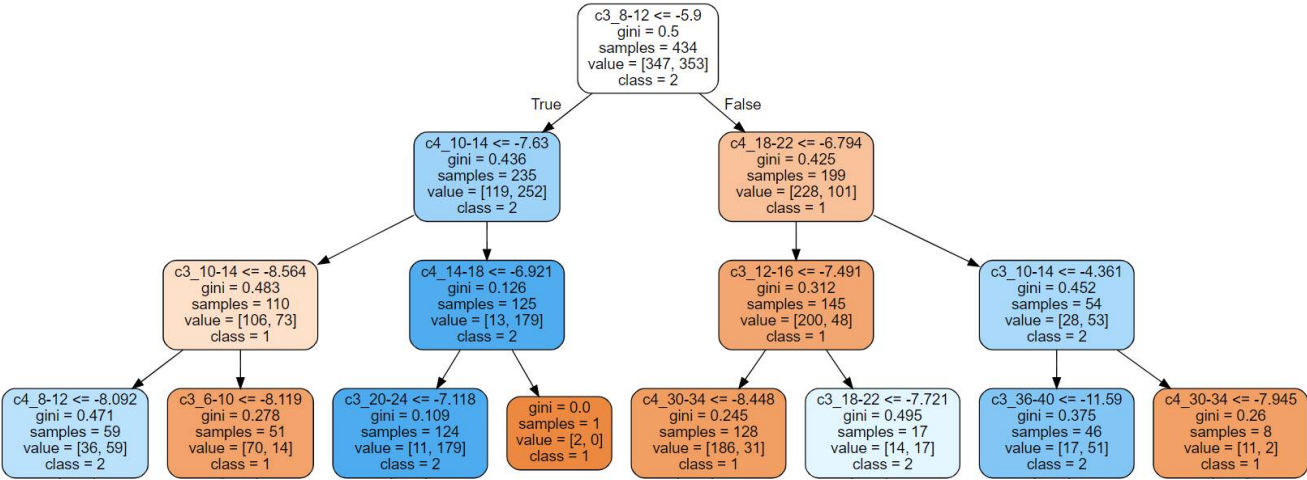


图5 决策树可视化图

Figure 5 Visualization of decision tree




图6 特征重要性分布图

Figure 6 Distribution of feature importance

3.3 实际采集数据集结果分析

针对该数据集,同样采用每名被试者的10×10折交叉验证的平均分类准确率评估算法性能。选取C3和C4导联处5.5~9.0 s内的信号作为实验数据,按照时间间隔1 s、步长0.5 s划分得到6个时间段进行空时频能量特征提取,并进行零均值规范化处理,生成尺寸为6×34的原始特征矩阵,LASSO回归正则化系数 $\varphi$ 设置为0.01。对比算法同样包括了与3.1节相同的CSP、FBCSP和SFBCSP方法,先验类别特征+级联森林、浅层能量特征+级联森林、CNN和SAE,具体比较结果如表4所示。从表4中可以看到,MVDF算法相较于先验类别及浅层能量等单视角特征,平均分

表3 不同被试者和不同方法下的准确率(%)

Table 3 Accuracy rates of different methods for different subjects (%)

算法	MVDF	先验类别特征+ 级联森林	浅层能量特征+ 级联森林	CNN	SAE	CSP			FBCSP			SFBCSP		
						SVM	RF	LDA	SVM	RF	LDA	SVM	RF	LDA
B01	78.8	76.4	78.9	74.5	61.0	70.4	68.0	71.1	80.0	77.9	80.1	81.1	77.9	81.0
B02	57.4	56.4	55.6	64.3	47.5	53.0	51.7	55.2	56.1	55.8	56.8	56.4	56.1	58.6
B03	56.3	55.8	55.9	71.8	45.0	53.6	51.0	55.3	50.6	51.9	51.5	51.3	52.6	55.0
B04	94.5	94.1	94.0	94.5	81.3	90.1	89.1	90.5	89.4	89.7	90.6	89.5	88.5	89.5
B05	86.9	85.9	86.0	79.5	62.8	71.7	69.4	68.7	85.1	83.9	83.8	85.9	84.1	85.0
B06	79.1	77.6	80.0	75.0	47.8	72.0	67.7	72.2	74.8	72.9	77.0	74.6	73.8	76.1
B07	74.8	73.5	74.8	70.5	53.8	60.4	58.5	61.0	72.1	72.2	74.1	74.2	73.3	74.5
B08	73.8	72.4	73.6	71.8	63.8	70.2	67.3	70.8	70.2	69.5	72.1	69.9	70.6	72.5
B09	75.6	74.6	74.6	71.0	56.5	70.5	68.9	72.1	74.1	73.6	73.9	75.1	74.4	76.3
均值	75.2	74.0	74.8	74.8	57.7	67.9	65.7	68.5	72.4	71.9	73.3	73.1	72.3	74.2

类准确率分别提升了1.3%和0.3%,说明使用具有互补性的多视角特征能有效增强分类性能。此外,相较于CNN和SAE两种典型的深度神经网络模型,

MVDF的平均分类准确率分别提升了4%和14.5%,在该数据集上所提算法优势较为明显。除了分类准确率,模型的计算开销是评估模型性能的另外一个

重要指标,基于该数据集的一次验证过程进行了程序耗时统计。MVDF算法主要包含3个计算单元,即原始特征矩阵扫描(0.094 s)、原始特征矩阵LASSO选择(0.002 s)和级联森林训练(0.880 s),级联森林训练所占的时间最长,3部分的总耗时仅为0.976 s,因此MVDF算法适用于实时计算。

表 4 不同被试者和方法下的准确率(%) (实际采集数据集)  
Table 4 Accuracy rates of different methods for different subjects (%) (pratical dataset)

算法	MVDF	先验类别特征+	浅层能量特征+	CNN	SAE	CSP			FBCSP			SFBCSP		
		级联森林	级联森林			SVM	RF	LDA	SVM	RF	LDA	SVM	RF	LDA
S01	75.7	73.4	74.6	74.6	64.1	66.3	60.3	66.8	71.3	72.7	72.9	76.0	76.6	74.9
S02	70.1	69.6	68.7	58.3	53.8	59.3	56.0	57.7	67.1	67.3	64.3	66.0	66.0	64.5
S03	59	58.6	60.3	59.6	59.4	61.0	58.5	62.2	63.6	61.5	60.6	64.2	63.0	61.1
S04	76.7	74.5	79.6	75.9	52.6	65.1	63.1	64.1	68.0	69.6	68.8	65.6	67.4	66.4
S05	71.8	70.7	69	65.3	51.1	74.5	69.3	70.9	74.2	73.5	73.0	76.3	75.3	74.8
均值	70.7	69.4	70.4	66.7	56.2	65.2	61.4	64.3	68.8	68.9	67.9	69.6	69.6	68.3

4 结 论

本文提出的MVDF运动想象EEG解码算法,通过融合多示例先验类别知识和重要的空时频浅层能量特征构建EEG多视角特征集,并采用深度级联森林进行逐层变换挖掘深层次的抽象特征进行分类,为运动想象EEG信号识别提供了一个新方向。多个数据集的实验结果表明,多视角特征能有效增强表示学习能力,相较于几种典型的CSP、FBCSP和SFBCSP方法以及深度神经网络算法,MVDF能取得持平甚至更优的分类效果且计算效率更高、可解释性更强。

【参考文献】

[1] 李红利,丁满,张荣华,等. 基于特征融合神经网络的运动想象脑电分类算法[J]. 中国医学物理学杂志, 2022, 39(1): 69-75.  
Li HL, Ding M, Zhang RH, et al. Motor imagery EEG classification algorithm based on feature fusion neural network[J]. Chinese Journal of Medical Physics, 2022, 39(1): 69-75.

[2] 赵紫宁,李智,张绍荣. 运动想象脑机接口中两种改进的脑电共空域模式特征提取方法[J]. 电子测量与仪器学报, 2019, 33(12): 64-70.  
Zhao ZN, Li Z, Zhang SR. Two improved methods for EEG common spatial pattern feature extraction in motor imagery based brain-computer interface [J]. Journal of Electronic Measurement and Instrument, 2019, 33(12): 64-70.

[3] Miao MM, Zhang WB, Hu WJ, et al. An adaptive multi-domain feature joint optimization framework based on composite kernels and ant colony optimization for motor imagery EEG classification[J]. Biomed Signal Process Control, 2020, 61: 101994.

[4] Miao YY, Chen SG, Zhang XR, et al. BCI-based rehabilitation on the stroke in sequela stage[J]. Neural Plasticity, 2020, 2020: 8882764.

[5] Bahador N, Jokelainen J, Mustola S, et al. Multimodal spatio-temporal-spectral fusion for deep learning applications in physiological time series processing: a case study in monitoring the depth of anesthesia [J]. Inform Fusion, 2021, 73: 125-143.

[6] Li M, Chen W. FFT-based deep feature learning method for EEG classification [J]. Biomed Signal Process Control, 2021, 66(1): 102492.

[7] Zhang R, Zong Q, Dou L, et al. Hybrid deep neural network using transfer learning for EEG motor imagery decoding[J]. Biomed Signal Process Control, 2021, 63: 102144.

[8] Miao MM, Wang AM, Liu FX. Application of artificial bee colony algorithm in feature optimization for motor imagery EEG classification [J]. Neural Comput Appl, 2018, 30(12): 3677-3691.

[9] Blankertz B, Tomioka R, Lemm S, et al. Optimizing spatial filters for

robust EEG single-trial analysis[J]. IEEE Signal Process Mag, 2007, 25(1): 41-56.

[10] Keng AK, Yang CZ, Wang C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b [J]. Front Neurosci, 2012, 6: 39.

[11] Zhang Y, Zhou GX, Jin J, et al. Optimizing spatial patterns with sparse filter bands for motor-imagery based brain-computer interface[J]. J Neurosci Methods, 2015, 255: 85-91.

[12] Zeng H, Song AG. Optimizing single-trial EEG classification by stationary matrix logistic regression in brain-computer interface[J]. IEEE Trans Neural Netw Learning Syst, 2016, 27(11): 2301-2313.

[13] Li Y, Zhang XR, Zhang B, et al. A channel-projection mixed-scale convolutional neural network for motor imagery EEG decoding[J]. IEEE Trans Neural Syst Rehabil Eng, 2019, 27(6): 1170-1180.

[14] Zhao DY, Tang FZ, Si BL, et al. Learning joint space-time-frequency features for EEG decoding on small labeled data[J]. Neural Networks, 2019, 114: 67-77.

[15] Zhao XQ, Zhang HM, Zhu GL, et al. A multi-branch 3D convolutional neural network for EEG-based motor imagery classification[J]. IEEE Trans Neural Syst Rehabil Eng, 2019, 27(10): 2164-2177.

[16] Chen JJ, Yu ZL, Gu ZH, et al. Deep temporal-spatial feature learning for motor imagery-based brain-computer interfaces[J]. IEEE Trans Neural Syst Rehabil Eng, 2020, 28(11): 2356-2366.

[17] Zhou ZH, Feng J. Deep forest: towards an alternative to deep neural networks [C]//Twenty-Sixth International Joint Conference on Artificial Intelligence. 2017: 3553-3559.

[18] 丁家满,吴晔辉,罗青波,等. 基于深度森林的轴承故障诊断方法[J]. 振动与冲击, 2021, 40(12): 107-113.  
Ding JM, Wu YH, Luo QB, et al. A fault diagnosis method of mechanical bearing based on the deep forest[J]. Journal of Vibration and Shock, 2021, 40(12): 107-113.

[19] Tian XB, Deng ZH, Ying WH, et al. Deep multi-view feature learning for EEG-based epileptic seizure detection[J]. IEEE Trans Neural Syst Rehabil Eng, 2019, 27(10): 1962-1972.

[20] Fang YF, Yang HY, Zhang XG, et al. Multi-feature input deep forest for EEG-based emotion recognition[J]. Front Neurobotics, 2021, 14: 617531.

[21] Chen J, Chen MY, Li C, et al. Emotion recognition from multi-channel EEG via deep forest[J]. IEEE J Biomed Health Inform, 2020, 25(2): 453-464.

[22] Tao XW, Yi WB, Wang K, et al. Inter-stimulus phase coherence in steady-state somatosensory evoked potentials and its application in improving the performance of single-channel MI-BCI[J]. J Neural Eng, 2021, 18(4): 046088.

[23] Wang XS, Gong GH, Li N, et al. Detection analysis of epileptic EEG using a novel random forest model combined with grid search optimization[J]. Front Human Neurosci, 2019, 13: 52.

[24] Tabar YR, Halici U. A novel deep learning approach for classification of EEG motor imagery signals[J]. J Neural Eng, 2017, 14(1): 016003.

[25] Ren YF, Wu Y. Convolutional deep belief networks for feature extraction of EEG signal[C]//2014 International Joint Conference on Neural Networks. 2014: 2851-2854.

(编辑:黄开颜)