

重叠时间切片改进深度神经网络的运动想象 EEG 模式识别^①



郑成杰¹, 肖国宝², 罗天健^{1,3}

¹(福建师范大学 计算机与网络空间安全学院, 福州 350117)

²(闽江学院 计算机与控制工程学院, 福州 350108)

³(福建师范大学 数字福建环境监测物联网实验室, 福州 350117)

通信作者: 罗天健, E-mail: createopenbci@fjnu.edu.cn

摘要: 运动想象脑电信号 (EEG) 的模式识别方法, 一直是无创脑机接口领域的重要研究方向之一. 近年来, 深度学习进一步提升了运动想象 EEG 信号的识别准确率, 但面对 EEG 信号较强的时变性, 依然存在训练样本不足和特征维度太高等问题. 针对上述问题, 本文提出了一种新型的重叠时间切片训练策略, 在现有的时间切片策略基础上 (cropped), 采用重叠的时间切片策略 (overlapped), 并基于重叠时间切片集合构建了全新的损失函数计算和标签预测方法. 采用重叠时间切片策略, 不但能够进一步提升训练样本数量, 还可以降低单个样本特征空间, 从而提升深度神经网络在 EEG 信号识别中的性能. 为了验证 overlapped 策略的可行性与有效性, 本文选择了 BCI Competition IV dataset 1, 2a 和 2b 三个开源 EEG 信号数据集, 在数据集上分别建立 5 种深度神经网络模型, 并对比 cropped 策略与 overlapped 策略的运动想象识别性能与效率. 实验结果表明, overlapped 策略较 cropped 策略拥有更好的识别性能. 最后, 通过调整重叠时间切片策略的参数值, 设计了 9 组不同参数组合的对比实验, 实验结果表明不同的参数组合会影响最终的性能, 且分类性能的好坏并不与效率的高低呈线性关系. 本文提出的 overlapped 策略在 Competition IV dataset 1, 2a 和 2b 数据集上的识别准确率分别达到了 92.3%、77.8% 和 86.3%, 较传统策略有明显的性能提升, 效率却不一定降低.

关键词: 运动想象; 脑电信号; 卷积神经网络; 重叠时间切片策略; 模式识别; 深度学习

引用格式: 郑成杰, 肖国宝, 罗天健. 重叠时间切片改进深度神经网络的运动想象 EEG 模式识别. 计算机系统应用, 2022, 31(5): 52-64. <http://www.c-s-a.org.cn/1003-3254/8459.html>

Improved Deep Neural Network with Overlapped Time Slice for Pattern Recognition of Motor Imagery EEG

ZHENG Cheng-Jie¹, XIAO Guo-Bao², LUO Tian-Jian^{1,3}

¹(College of Computer and Cyber Security, Fujian Normal University, Fuzhou 350117, China)

²(College of Computer and Control Engineering, Minjiang University, Fuzhou 350108, China)

³(Digital Fujian Internet-of-Thing Laboratory of Environmental Monitoring, Fujian Normal University, Fuzhou 350117, China)

Abstract: Pattern recognition of electroencephalogram (EEG) signals during motor imagery (MI) has been one of the most important research directions in the field of non-invasive brain-computer interface (BCI). In recent years, deep learning has further improved the recognition accuracy of EEG signals during MI. However, given the strong time variability of EEG signals, there are still some problems such as insufficient training samples and too high feature dimensions. To solve the above problems, this study proposes a new training strategy called “overlapped time slice”. Based on the existing cropped time slice strategy, this study adopts a novel overlapped time slice strategy and constructs a

① 基金项目: 闽江学院计算机科学与技术应用型学科 2020 年开放基金 (MJUKF-JK202005)

收稿时间: 2021-06-23; 修改时间: 2021-08-24; 采用时间: 2021-08-31; csa 在线出版时间: 2022-04-11

new loss function calculation and label prediction method with the overlapped time slice set. The overlapped time slice strategy can not only further increase the number of training samples but also reduce the feature space of a single sample to improve the performance of the deep neural network in EEG signal recognition. For the verification of the feasibility and effectiveness of the proposed overlapped strategy, three open-source EEG signal datasets, namely the BCI Competition IV datasets 1, 2a, and 2b, are selected in this study, and five kinds of deep neural network models are built on these three datasets. During experiments, the performance and efficiency of MI recognition are compared between the cropped strategy and the overlapped strategy. Experimental results show that the overlapped strategy has better recognition performance than that of the cropped strategy. Finally, nine groups of experiments are designed with different parameter combinations by adjusting the parameters of the overlapped time slice strategy. The experimental results demonstrate that parameter combination affects the final classification performance and that the classification performance is not in a linear relationship with the efficiency. The recognition accuracy of the proposed overlapped strategy on dataset 1, 2a, and 2b is 92.3%, 77.8%, and 86.3% respectively. Compared with the conventional cropped strategy, the proposed overlapped strategy has improved the performance significantly without necessarily reducing the efficiency.

Key words: motor imagery; electroencephalogram (EEG) signal; convolutional neural network (CNN); overlapped time slice strategy; pattern recognition; deep learning

1 引言

脑机接口 (brain computer interface, BCI) 技术是一种建立在大脑和外部设备之间、且不依赖于外围神经系统与肌肉组织的新型人机交互方式^[1]. BCI 技术可以实现大脑与外部电子设备的直接通信与控制, 主要涉及认知神经科学、信号处理和模式识别等多学科交叉. 常见的 BCI 技术包括无创 BCI^[2] 和有创 BCI, 其中无创 BCI 可应用于常人, 不用面对伦理道德问题. 脑电信号是常用的无创 BCI 技术手段之一, 基于脑电信号 (electroencephalogram, EEG) 的 BCI 主要包含 P300^[3], 稳态视觉电位^[4] 和运动想象^[5] 3 个类别.

运动想象 (motor imagery, MI) 是指人在进行运动想象 (如想象左手、右手、舌、双脚的运动) 时所产生的大脑运动感知节律变化, 主要由 mu 节律和 beta 节律组成^[6]. 如人在进行单侧肢体的想象运动时, 大脑皮层同侧感觉区中的 mu 和 beta 节律幅值会增加, 发生事件相关同步 (event-related synchronization, ERS) 现象; 同时, 大脑皮层对侧运动感觉区中的 mu 和 beta 节律幅值会减少, 发生事件相关去同步 (event-related desynchronization, ERD) 现象^[7]. 基于 EEG 的运动想象脑机接口 (motor imagery brain computer interface, MI-BCI) 系统可以对这些不同的 ERD/ERS 模式进行分类, 其目的在于准确的辨认出受试者的肢体运动意图^[8]. 但

由于 MI-BCI 过程中采集到的 EEG 信号信噪比低、空间分辨率低、非线性、非平稳性和随机性强等特点, 导致现有的脑电识别技术对 EEG 信号的解码正确率较低.

近年来, 深度学习方法在图像识别^[9]、语音识别^[10] 等领域体现出其巨大的优势. 目前, 众多研究者已经将深度神经网络 (deep neural network, DNN) 应用到 MI-BCI 过程中 EEG 信号的模式识别中. 胡章芳等人^[11] 提出了一种短时傅里叶变换 (short-time Fourier transform, STFT) 和卷积神经网络 (convolutional neural network, ConvNet) 相结合的方法进行 MI-BCI 过程中 EEG 信号的识别分类, 该方法在 BCI 竞赛数据集上获得了 86.5% 的平均分类正确率, 优于其他传统识别分类方法. Tabar 等人^[12] 结合卷积神经网络与堆叠自动编码器 (stacked autoencoder, SAE) 对 MI-BCI 过程中 EEG 信号进行模式识别研究, 该方法首先采用短时傅里叶变换进行 EEG 信号的时频域特征预提取, 接着通过 SAE 对 ConvNet 提取到的特征进行最终分类. 该方法在 2008 年 BCI 竞赛数据集 2b 上获得了不错的分类性能, Kappa 值达到 0.547, 比竞赛第一名的算法高出 9%. 褚亚奇等人^[13] 提出一种基于时空特征学习卷积神经网络 (TSCNN) 的运动想象脑电解码方法, 该方法对公共数据集的平均解码精度达到 80.09%, 显著提升了运动想象脑电解码

的可靠性. Dai 等人^[14]提出一种将卷积神经网络 (CNN) 结构与变分自编码器 (VAE) 相结合的 MI-BCI 过程中 EEG 信号分类框架, 该框架平均 Kappa 值为 0.564, 优于文献中最好的 BCI 竞赛 IV 数据集 2b 的分类方法, 提高了 3% 的识别准确率. Dai 等人^[15]提出了一种混合尺度 CNN 架构和数据增强方法 (HS-CNN) 用于脑电运动图像分类, 该方法在两个常用数据集上的平均分类准确率分别达到 91.57% 和 87.6%, 优于几种最新的脑电运动图像分类方法.

在采用深度神经网络进行 MI-BCI 过程中 EEG 信号的模式识别中, 传统的训练方法是使用 trial-wise 方法: 即将整个试验 (trial) 信号作为输入样本, 以每个 trial 的标签作为目标的训练策略. 但传统的 trial-wise 策略具有两大不足之处: 一是样本量太少, 不适合用于深度神经网络; 二是单个 trial 的时间域过长, 特征维度太高, 导致分类效果不好. 为此, Schirmer 等人^[16]设计了一种 cropped 训练策略, 该策略通过滑动时间窗口 (sliding time windows) 对每个 trial 进行裁剪, 既增加了训练样本量, 又避免了数据特征维度太高对结果的影响. 但是由于单纯的 cropped 训练策略未考虑到 EEG 信号具有时变性, 单纯的 cropped 训练策略无法提取和学习到各个切分后 crops 之间的关联性特征, 导致效果不佳. Schirmer 等人^[16]设计的 cropped 训练策略采用的是非重叠时间的 cropped 切分方式, 即各个 crops 之间没有重叠部分, 并且原文中并未进行 trial-wise 和 cropped 的方式对比. 对此, 本文提出一种新型的重叠时间切片的训练策略, 并且详细对比了几种划分方式的结果. 重叠时间切片的训练策略采用带有重叠时间的滑动时间窗口对原始输入进行切分, 并在计算最后的分类标签时, 采用多数投票制确定样本的预测标签. 带有重叠的时间滑动窗口可保证切分后的样本之间保留其重叠部分的信息, 可通过神经网络提取和学习到切分后样本之间的关联性特征. 除此之外, 保留样本间重叠信息可以使可学习到的特征更加丰富, 可以更加适应较深层的网络.

本文的其余部分结构如下: 第 2 节介绍基于深度神经网络模型的运动想象 EEG 模式识别中常见的 5 种模型. 第 3 节首先介绍用于运动想象 EEG 信号的 trial-wise 和 cropped 训练策略, 以及本文提出的重叠时间切片的训练策略. 第 4 节为实验的结果与分析, 包括实验框架、3 种开源 MI 实验数据集, 以及各种策略在

各种模型的对比结果.

本文的主要贡献:

(1) 提出了一种改进的重叠时间切片的训练策略, 该训练策略可有效弥补一般训练策略带来的训练样本不足、特征维度太高和未能解决 EEG 信号具有时变性的缺陷, 有效提升了 EEG 信号的分类准确率.

(2) 在 3 种不同公共数据集上对比了 3 种不同训练策略的性能和效率. 本文提出的重叠时间切片训练策略对公共数据集的分类准确率相比于先前两种训练策略有较显著的提升.

2 基于深度神经网络模型的运动想象 EEG 模式识别

2.1 Deep ConvNet

Deep ConvNet 架构的灵感来自于 Krizhevsky 等人^[17]提出的且在计算机视觉领域取得成功的一种架构. 该架构的出发点是想要找到一个能够提取广泛特征并且不限于特定特征类型的神经网络模型^[18]. 设计这种通用体系的目的是揭露这种通用的 ConvNet 是否可以仅靠少量的专业知识就可以取得具有竞争力的准确率.

Deep ConvNet 具有 4 个卷积最大池化块 (convolution-max-pooling blocks), 其中第 1 个特殊的块用于处理输入的 EEG 信号, 然后是 3 个标准的卷积最大池化块和一个 Softmax 分类层. Deep ConvNet 的体系结构如图 1.

Deep ConvNet 的一些设计策略:

(1) 为了更好的处理大量输入通道, 第 1 个卷积块采取分步卷积, 分为两层: 在第 1 层中, 每个滤波器随时间进行卷积. 在第 2 层中, 每个滤波器对先前进行时间卷积后的电极对执行权重的空间滤波.

(2) 使用指数线性单元 (exponential linear units, ELU)^[19] 作为激活函数. 公式为:

$$f(x) = \begin{cases} x, & x > 0 \\ e^x - 1, & x \leq 0 \end{cases} \quad (1)$$

(3) 在每个卷积层的输出使用批标准化和归一化. 对每一批训练样本, 将网络的中间输出标准化为零均值和单位方差, 这可以使在训练过程中的层间的输入保持近似的正态分布, 有助于优化.

(4) 在训练更新中采用 dropout. 除第一个卷积层外, 以 0.5 的概率随机地将之后的卷积层的输入设置为零.




图1 Deep ConvNet 体系结构

2.2 Shallow ConvNet

Shallow ConvNet 是一种比较浅的神经网络结构,其受到滤波器组共空间模式 (filter bank common spatial patterns, FBCSP) 的启发,是专门为解码频带功率特征而量身定制的.这里首先介绍 FBCSP 解码试验标签的一些步骤:

(1) 带通滤波: 应用不同的带通滤波器将原始 EEG 信号分离为不同的频带.

(2) 划分时间: 将连续的 EEG 信号分为 3 部分.

(3) CSP 特征计算: 在每个频带上,将 CSP 算法应用于提取空间滤波器. CSP 的目的是提取空间滤波器,并通过空间滤波后的试验信号的功率来区分试验.

(4) 空间滤波: 将步骤 (3) 中计算出的空间滤波器应用于 EEG 信号.

(5) 特征构造: 特征向量由滤波后的信号构成,具体来说,特征向量是试验信号的每个频带使用不同空间滤波器空间滤波后的对数方差.

(6) 分类: 基于特征向量训练一个分类器以预测每个试验标签.

Shallow ConvNet 的前两层执行时间卷积和空间滤波.这类似于 FBCSP 中的带通滤波和 CSP 空间滤波步骤.与 Deep ConvNet 相比,Shallow ConvNet 的时间卷积具有更大的卷积核 (25 vs. 10),从而允许在该层进行更大范围的转换.在 Shallow ConvNet 的时间卷积和空间滤波后,使用了平方非线性函数 (square)、均值池化层和对数激活函数 (log),这些步骤组合在一起类似于 FBCSP 中的试验的对数方差计算.与 FBCSP 相比,Shallow ConvNet 将所有计算步骤嵌入到单个网络中,因此可以共同优化所有步骤. Shallow ConvNet 的体系结构如图 2 所示.

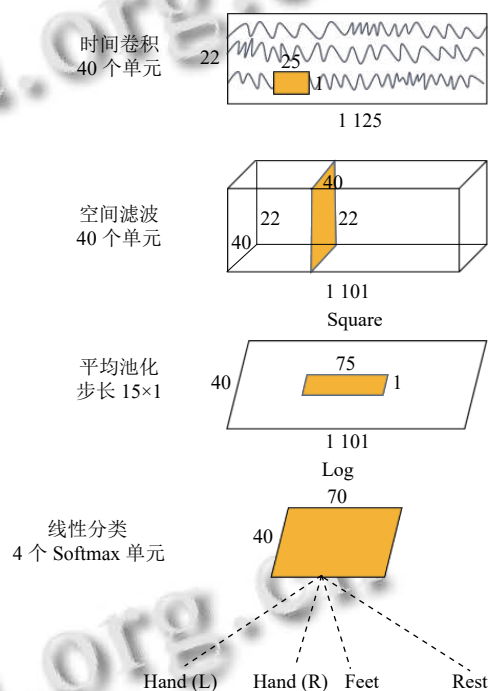


图2 Shallow ConvNet 体系结构

2.3 Hybrid ConvNet

Hybrid ConvNet 是一种融合 Deep ConvNet 和 Shallow ConvNet 的混合 ConvNet 模型. Hybrid ConvNet 希望从 Shallow ConvNet 中提取到更具体特征,以及从 Deep ConvNet 中提取到更通用的特征. Hybrid ConvNet 用 Deep ConvNet 和 Shallow ConvNet 的 60 个和 40 个滤波器 ELU 层替换了两个 ConvNet 的 4 个滤波器 Softmax 分类层.将生成的 100 个特征图连接起来,并用作新的 Softmax 分类层的输入. Hybrid ConvNet 不使用任何 Deep 或 Shallow ConvNet 预先训练好的参数,而是对整个 Hybrid ConvNet 进行重新训练.

2.4 EEGNet

EEGNet 是由 Lawhern 等人^[20]提出的基于 CNN

的模型,是一种紧凑的脑电分析卷积神经网络,专为常规 EEG 信号识别任务而设计. EEGNet 可以应用于多种不同的 BCI 范式,不但可采用非常有限的数据进行训练,而且可以产生神经生理学上可解释的特征.

EEGNet 保留了 Shallow ConvNet 中的时间和空间卷积层. EEGNet 引入了深度卷积和可分离卷积,来代替 Shallow ConvNet 中的简单卷积,以减少训练参数的数量. EEGNet 还使用了 ELU 激活函数代替 Shallow ConvNet 的平方激活函数. EEGNet 的总体结构如图 3 所示,对于一个 22×1125 的输入样本,在 Conv2D 层使用 8 个大小为 $(1, 64)$ 的卷积核,使用线性激活函数,输出大小为 $(8, 22, 1125)$,在 DepthwiseConv2D 层使用 16 个大小为 $(22, 1)$ 的卷积核,使用 ELU 激活函数,输出大小为 $(16, 1, 1125)$,接着是一个平均池化层 AveragePool2D,卷积核为 $(1, 4)$,输出大小为 $(16, 1, 281)$,在 SeparableConv2D 层,使用 16 个大小为 $(1, 16)$ 的卷积核,使用 ELU 激活函数,输出大小为 $(16, 1, 281)$,接着

一个 AveragePool2D 层,卷积核为 $(1, 4)$,输出大小为 $(16, 1, 35)$,然后展平成大小为 560 的一维数组,最后一个全连接层有 2 240 卷积核,使用 Softmax 激活函数,输出大小为 4 的一维数组.

2.5 EEGResNet

残差网络 (residual network, ResNet) 是由 He 等人^[21]提出的一种卷积神经网络结构,获得了 2015 年 ImageNet 大规模视觉识别竞赛的第一名. ResNet 通常具有大量的层数,将 ResNet 应用于 EEG 解码旨在研究这种具有更多层数的网络是否也能在 EEG 解码中获得良好的性能. 在 ResNet 的一个残差块结构中,记输入为 x ,其期望学习到的潜在映射记为 $H(x)$,学习到的残差为 $F(x) = H(x) - x$. 当残差为 $F(x) = 0$ 时,此时残差块可以实现恒等映射. 残差块的设计如图 4.

EEGResNet 模型在第 1 块仍然是先进行时间卷积和空间滤波,接着是 14 个残差块,平均池化和最后的 Softmax 分类层. EEGResNet 的体系结构如表 1.

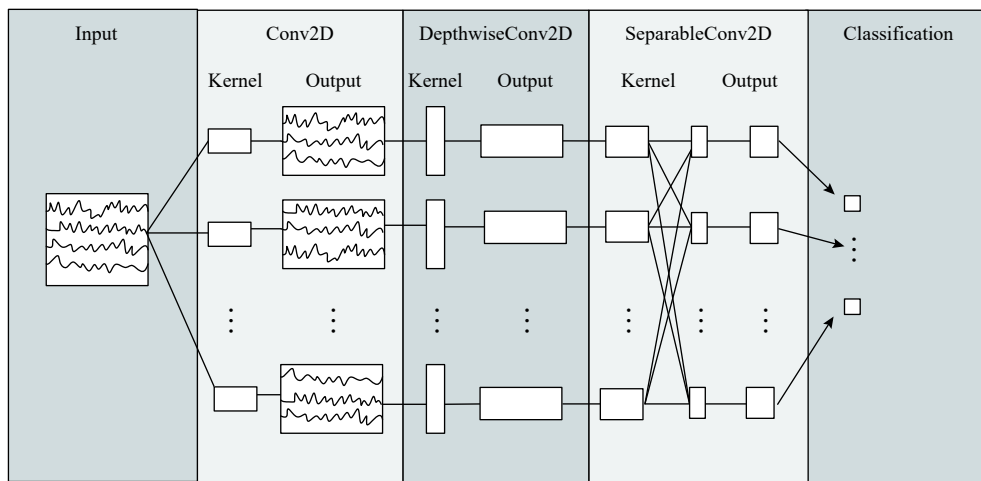


图 3 EEGNet 总体结构

3 运动想象 EEG 信号单个 trial 重叠时间切片策略

3.1 Trial-wise 策略的训练方法

通常,为了训练一个 ConvNet 模型,需要对 ConvNet 模型中所有参数 (包括所有权重和偏置) 进行联合训练. 在有监督分类问题中,构建 ConvNet 模型的目的是计算从输入数据到其对应的真实类别标签的一个函数:

$$f(X^i; \theta) : R^{E \cdot T} \rightarrow R^K \quad (2)$$

其中, X^i 表示输入的试验样本, θ 是整个 ConvNet 所要计算的参数, E 是电极数, T 是时间长度, K 是可能的分类标签数. 为了使用 ConvNet 模型进行分类,通常使用 Softmax 函数在给定输入 X^i 的情况下将输出转换为标签 k 的条件概率:

$$p(k|f(X^i; \theta)) = \frac{\exp(f_k(X^i; \theta))}{\sum_{m=1}^K \exp(f_m(X^i; \theta))} \quad (3)$$

其中, f_k 表示通过最小化每个样本的损失值总和以求得

该样本对于每个可能的分类标签的条件概率, 该样本的最终分类标签即为其中的最高概率对应的标签, 即可用式 (4) 表示:

$$\theta = \arg \min_{\theta} \sum_{i=1}^N \text{loss}(y^i, p(l_k|f_k(X^i; \theta))) \quad (4)$$

其中, N 表示输入样本总数, y^i 表示输入 X^i 对应的预测标签. 损失函数 loss 可用式 (5) 表示:

$$\text{loss}(y^i, p(l_k|f_k(X^i; \theta))) = \sum_{k=1}^K -\log(p(l_k|f_k(X^i; \theta))) \cdot \delta(y^i = l_k) \quad (5)$$

其中, $\delta(y^i = l_k)$ 表示预测标签 y^i 与实际标签 l_k 相同的概率, loss 函数是标签的负对数似然. 接着通过小批量随机梯度下降法和反向传播算法来优化参数 θ , 后续采用最优的参数进行 EEG 信号识别. Trial-wise 训练策略就是将整个试验信号作为输入, 每个试验标签作为分类目标, 其与 FBCSP 算法的训练过程类似.

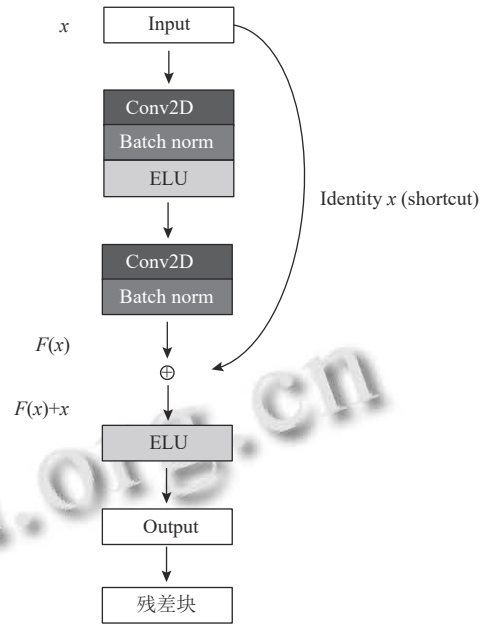


图 4 残差块

表 1 EEGResNet 体系结构

Layer/Block	Kernels	Kernel size	Output
Input	—	—	(1 125, 22, 1)
Convolution (linear)	48	(3, 1)	(1 125, 22, 48)
Convolution (ELU)	48	(1, 22)	(1 125, 1, 48)
ResBlock (ELU)	48	(3, 1)	(1 125, 1, 48)
ResBlock (ELU)	48	(3, 1)	(1 125, 1, 48)
ResBlock (ELU)	96	(3, 1)(Stride (2, 1))	(561, 1, 96)
ResBlock (ELU)	96	(3, 1)	(561, 1, 96)
ResBlock (ELU)	144	(3, 1)(Stride (2, 1))	(281, 1, 144)
ResBlock (ELU)	144	(3, 1)	(281, 1, 144)
ResBlock (ELU)	144	(3, 1)(Stride (2, 1))	(141, 1, 144)
ResBlock (ELU)	144	(3, 1)	(141, 1, 144)
ResBlock (ELU)	144	(3, 1)(Stride (2, 1))	(71, 1, 144)
ResBlock (ELU)	144	(3, 1)	(71, 1, 144)
ResBlock (ELU)	144	(3, 1)(Stride (2, 1))	(36, 1, 144)
ResBlock (ELU)	144	(3, 1)	(36, 1, 144)
ResBlock (ELU)	144	(3, 1)(Stride (2, 1))	(18, 1, 144)
ResBlock (ELU)	144	(3, 1)	(18, 1, 144)
Mean pooling	—	(10, 1)	(9, 1, 144)
Convolution+Softmax	4	(1, 1)	(9, 1, 4)

3.2 Cropped 策略的训练方法

Cropped 策略的训练使用裁剪方法, 即在原始输入试验中使用滑动窗口, 使输入深度学习模型中的训练样本比 trail-wise 策略更多, 更适合于深度学习模型的训练. 对于原始输入试验样本 $X^i \in R^{E \times T}$, 采用 T' 作为裁剪长度, 通过裁剪可得到一个裁剪样本集合

(crops):

$$C^i = \{X_{1, \dots, E, t, \dots, t+T'}^i | t \in 1, \dots, T - T'\} \quad (6)$$

其中, $X_{1, \dots, E}$ 表示来自 E 个电极的输入矩阵, 所有 $T - T'$ 个裁剪后的数据都作为输入深度学习模型的训练数据, 而且这些裁剪后的数据标签与其原始输入试验

标签一致,即为 y^i .

Cropped 策略通过裁剪增加了训练集的大小,为了减少其带来的计算负担,将相邻的 crops 解码在一起,并重用网络中的中间卷积输出.该方法同时输入多个 crops 并在深度神经网络模型的一次正向传播过程中计算所有 crops 的预测值.该方法会导致一个新的超参数:同时处理的 crops 数量.同时处理的 crops 越多,网络获得的加速效果就越大.

在 cropped 训练策略中使用了新的损失函数,其在 trial-wise 的损失函数的基础上添加了两个相邻 crop 的预测的交叉熵.对于每个 crop: $X_{t, \dots, t+T}^i$, 采用式 (7) 计算误差:

$$\begin{aligned} \text{loss}(y^i, p(l_k|f_k(X_{t, \dots, t+T}^i; \theta))) \\ = \sum_{k=1}^K -\log(p(l_k|f_k(X_{t, \dots, t+T}^i; \theta))) \cdot \delta(y^i = l_k) \\ + \sum_{k=1}^K -\log(p(l_k|f_k(X_{t+1, \dots, t+T+1}^i; \theta))) \\ \cdot p(l_k|f_k(X_{t+1, \dots, t+T+1}^i; \theta)) \end{aligned} \quad (7)$$

3.3 重叠时间切片策略的训练方法

运动想象属于长时间、持续的过程,根据经典运动想象刺激范式,在整个 4 s 的信号采集过程中,受试者都将持续保持运动想象.虽然反映运动想象数据可能集中在部分采样区间中,但由于不同受试者对于运动想象的反应时间、持续时间不同,这样的区间却因为个体差异性而各不相同.因此,无法使用统一的方式从不同被试者的运动想象集中区间中提取有效特征.实际上,由于卷积神经网络的特性,误差反向传播将会对不同区间的权重进行调整,随着训练的进行那些蕴含运动想象特征的权重越来越高,而不蕴含运动想象特征的权重将越来越低.因此,本文选择采用重叠切片的方式,让蕴含和不蕴含运动想象特征的区间进行组合,保证蕴含运动想象部分以更多样性的组合形式输入至卷积神经网络中,从而保证了采用卷积神经网络进行运动想象分类时的鲁棒性.

重叠时间切片 (overlapped) 策略同样使用滑动窗口对原始试验进行切分.与 cropped 策略不同的是,重叠时间切片策略通过 α, β 两个参数控制时间切片的长度和重叠的时间长度.对于原始输入试验 X^i ,在给定 α, β 参数值的情况下,通过重叠时间切片可将原始输入试验切分为:

$$O_{\alpha, \beta}^i = \{X_{1, \dots, E, t, \dots, t+\alpha}^i | t = 1, 1+\beta, \dots, 1+n\beta\} \quad (8)$$

其中, $n = 1 + \frac{T-\alpha}{\beta}$, 表示将原始输入试验切分为 n 份.

对于每个切分后的 $O_{\alpha, \beta}^i$, 其标签与其原始输入标签一致,即为 y^i .原始试验切分后的数据堆叠成为 n 个试验作为输入数据.重叠时间切片的切分方法如图 5 所示.

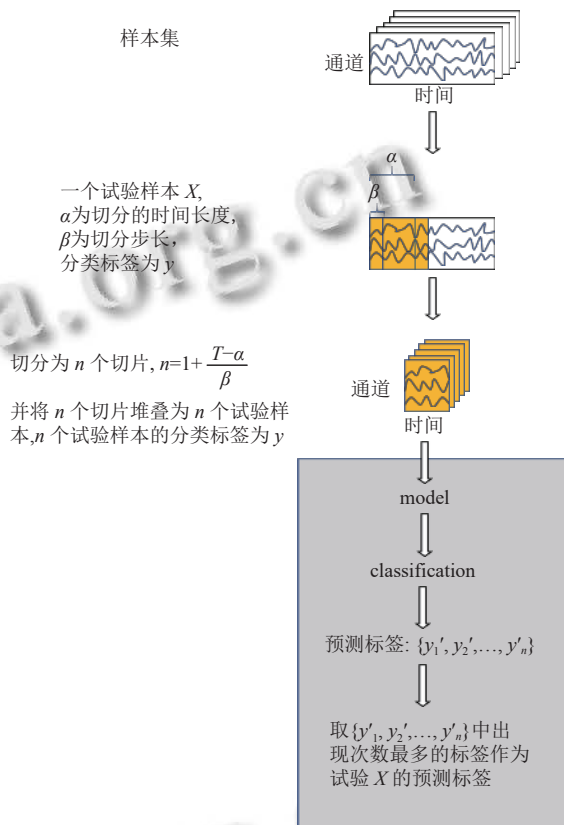


图 5 重叠时间切片切分策略

在重叠时间切片策略中,对于每个切片 $O_{\alpha, \beta}^i$,采用式 (9) 计算误差:

$$\begin{aligned} \text{loss}(y^i, p(l_k|f_k(O_{\alpha, \beta}^i; \theta))) \\ = \sum_{k=1}^K -\log(p(l_k|f_k(O_{\alpha, \beta}^i; \theta))) \cdot \delta(y^i = l_k) \end{aligned} \quad (9)$$

在预测样本标签时,采用多数投票制,即对于来自同一个原始试验的切片,统计这些切片的预测值,将这些切片中出现最多次数的预测标签作为这个样本本次预测的预测标签.该策略的其余超参数与 trial-wise 策略的超参数保持一致.

4 实验与结果分析

4.1 实验初始化

本文实验选用 2008 年 BCI Competition IV Dataset 1、2a 和 2b 三个公开数据集.

Dataset 1 数据集包含来自 7 位健康受试者执行运动想象的 EEG 数据. 标签类型为 2 种, 其中类别 1 表示受试者在执行左、右手或者脚的运动想象, 类别 0 表示受试者无控制意图. 该数据集测量了每个受试者的 59 个在感觉运动区域上最密集的通道信号. 信号以 1 000 Hz 为采样频率, 并在 0.05–200 Hz 之间进行带通滤波. Dataset 2a 数据集包含来自 9 个受试者执行运动想象的 EEG 数据. 运动想象类型为 4 种, 包括左手、右手、双脚和舌头. 信号以 250 Hz 为采样频率, 并在 0.5–100 Hz 之间进行带通滤波. 放大器的灵敏度设置为 100 μ V, 并使用了 50 Hz 陷波滤波器抑制线路噪声.

Dataset 2a 数据集的 EEG 信号采集过程如图 6 所示. 每个受试者坐在计算机屏幕前的舒适扶手椅上. 在实验开始时, 屏幕上出现十字注视叉, 并发出简短的提示音, 2 s 后, 屏幕上出现持续 1.25 s 的指向左、右、上或下 (分别对应于 4 种运动想象类别) 的箭头, 随后受试者执行箭头对应的运动想象并持续到实验开始后的第 6 s. 训练数据集包含每个受试者的 288 次试验样本, 测试数据集同样包含每个受试者的 288 次试验样本.




图 6 Dataset 2a 数据采集实验

Dataset 2b 数据集包含来自 9 个右利手的受试者执行运动想象的 EEG 数据. 运动想象类型为 2 种, 包括左手和右手. 信号以 250 Hz 为采样频率, 并在 0.5–100 Hz 之间进行带通滤波. 放大器的灵敏度设置为 100 μ V, 并使用了 50 Hz 陷波滤波器以抑制线路噪声. 每位受试者的脑电数据集都包括 5 个 Session, 前 2 个 Session 为无视觉反馈的脑电想象数据, 后 3 个 Session 为包含视觉反馈的脑电想象数据.

Dataset 2b 数据集的采集工作分为无视觉反馈和有视觉反馈实验. 无视觉反馈实验过程如图 7 所示, 在实验开始时, 屏幕上出现十字注视叉, 并发出简短的提示音, 2 s 后, 屏幕上出现持续 1.25 s 的指向左或右 (分别对应于左手或右手运动) 的箭头, 随后受试者执行箭头对应的运动想象并持续到实验开始后的第 6 s.

有视觉反馈实验过程如图 8 所示, 在实验开始时, 屏幕上显示灰色的笑脸, 2 s 后发出简短的提示音, 3 s 时屏幕上出现持续 1.25 s 的指向左或右 (分别对应于左手或右手运动) 的箭头, 随后受试者执行箭头对应的运动想象将笑脸向左或向右移动, 如果移动方向正确, 屏幕中的灰色笑脸就会变为笑脸, 反之, 变成哭脸.




图 7 Dataset 2b 无视觉反馈数据采集实验




图 8 Dataset 2b 有视觉反馈数据采集实验

本文实验的硬件配置为 CPU: Intel(R) Core(TM) i5-10210U 1.60 GHz, GPU: NVIDIA GeForce MX350.

本文采用开源的 ConvNet 模型 EEG 信号识别框架进行 EEG 信号识别 (<https://github.com/braindecode/braindecode>). 实验需安装 Python 第三方库 PyTorch. 数据预处理: 在读取原始数据后, 将数据在 3–38 Hz 之间进行带通滤波, 然后进行数据切分, 以 Dataset 2a 数据集为例, 切分的大小为 22×1125, 形成训练和测试样本, 最后将切分后的样本送入 braindecode 框架中进行处理. 实验参数设置: trial-wise 和 overlapped 训练策略的最大迭代次数设为 1 600, cropped 训练策略的最大迭代次数设为 800. 学习率为 0.001, 使用 early-stopping, 停止条件为达到最大迭代次数或者验证集上的误分类率没有下降. 优化器使用 torch.optim 中的 Adam 优化器, 损失函数使用 torch.nn.functional 中的 nll_loss 函数. 实验结果的图使用 echarts (一个基于 JavaScript 的开源可视化图表库) 画出.

4.2 Dataset 1 实验结果对比

基于本文介绍的 trial-wise、cropped 和设计的重叠时间切片 (overlapped) 策略, 将这 3 种训练方法应用

于本文介绍的5种深度神经网络模型: Deep ConvNet、Shallow ConvNet、Hybrid ConvNet、EEGNet和EEGResNet上。由于Dataset 1数据集的单个trial持续时间较短,在Dataset 1数据集上采用trial-wise、cropped和overlapped三种策略训练2种深度神经网络模型: Shallow ConvNet和EEGNet,得到所有受试者的测试集上的识别准确率如表2所示。其中,实验的overlapped

训练方法中的 α 、 β 参数值分为设置为100和20。

由表2可以看出,在Dataset 1数据集上,overlapped训练策略在Shallow ConvNet和EEGNet上的分类准确率均高于cropped训练策略的分类准确率,分别提升了5.4%和6.9%。在EEGNet模型上的分类准确率高出trial-wise训练策略的,在Shallow ConvNet模型上的分类准确率与trial-wise的相差不大。

表2 Trial-wise、cropped和overlapped (100, 20)方法在Dataset 1数据集上的识别准确率比较 (%)

Subject	Shallow ConvNet			EEGNet		
	Trial-wise	Cropped	Overlap	Trial-wise	Cropped	Overlapped
1	98	89.5	96.2	88.3	90.8	91
2	75.5	67.8	64	60	52.5	56.8
3	87.5	74	95.2	55	80.2	82.2
4	97.5	93	97.8	92.8	58.5	96.2
5	95.8	100	100	100	100	97.8
6	92.3	83	92.5	60	61.2	71
7	92.5	93	92.5	95.2	97.5	93.8
Average	91.3	85.8	91.2	78.8	77.2	84.1

对于Dataset 1数据集,实验将 α 设置为100、150或200, β 设置为20、30或40,共产生9组参数组合。

9组不同参数组合的overlapped策略应用于2种不同模型的识别准确率的提升百分比如图9所示。

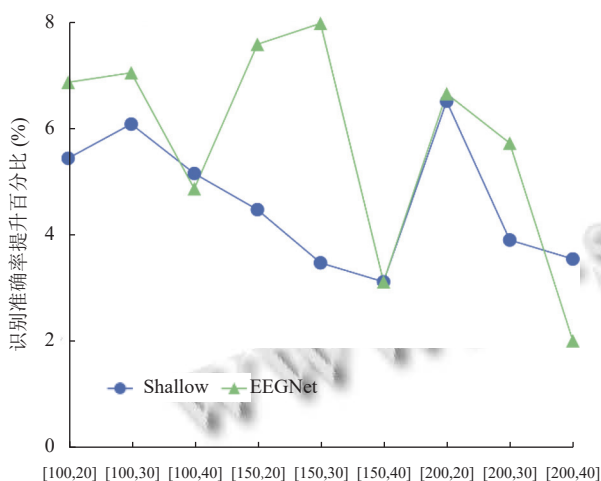


图9 在Dataset 1上9组参数组合的overlapped策略的识别准确率提升百分比的比较

从图9可以看出,overlapped训练策略的9种参数组合在Shallow ConvNet和EEGNet两种模型的识别准确率均有提升。Shallow ConvNet在 $\alpha = 200$, $\beta = 20$ 时,识别准确率提升百分比最大,达到了6.5%。EEGNet在 $\alpha = 150$, $\beta = 30$ 时,识别准确率提升百分比最大,达

到了7.964%。

4.3 Dataset 2a 实验结果对比

基于本文介绍的trial-wise、cropped和设计的重叠时间切片(overlapped)策略,将这3种训练方法应用于本文介绍的5种深度神经网络模型: Deep ConvNet、Shallow ConvNet、Hybrid ConvNet、EEGNet和EEGResNet上,并计算出其在Dataset 2a数据集所有受试者的测试集上的识别准确率如表3所示。其中,实验的overlapped训练方法中的 α 、 β 参数值分为设置为500和100。

由表3可以看出,在Dataset 2a数据集上,对于Shallow ConvNet和EEGNet这两种浅层模型,overlapped训练策略与trial-wise训练策略的分类准确率相差不大,但都优于cropped训练策略。对于Deep ConvNet、Hybrid ConvNet和EEGResNet 3种模型,overlapped训练策略的分类准确率均高于trial-wise和cropped训练策略的分类准确率。

本文还通过设置不同的 α 和 β 参数,以研究不同的 α 和 β 参数对overlapped训练策略的性能影响。实验将 α 设置为500、600或800, β 设置为100、150或200,共产生9组参数组合。

相比于cropped策略,9组不同参数组合的overlapped策略应用于5种不同模型的识别准确率的提升百分比如图10所示。

表3 Trial-wise、cropped 和 overlapped (500, 100) 方法在 Dataset 2a 数据集上的识别准确率比较 (%)

Network	Strategy	Subject									Average
		1	2	3	4	5	6	7	8	9	
Shallow ConvNet	Trial-wise	82.3	60.3	91.7	83.9	61	59.2	94	82.4	80.4	77.2
	Cropped	85.1	50.7	87.8	70.5	51	53.7	94.4	77.8	76.9	72
	Overlapped	89	55.1	92	77.3	62.5	56.6	95.4	84.5	83.3	77.3
Deep ConvNet	Trial-wise	68.7	30.9	78.3	49.5	31.4	32.8	73.7	77.4	80.2	58.1
	Cropped	49.2	33.7	72.6	34.8	25.7	25.2	31.9	52.2	66.3	43.5
	Overlapped	85	39.5	84.3	24.8	46.1	47.1	87.3	77.4	78.8	63.4
Hybrid ConvNet	Trial-wise	50.8	32.2	51.3	39.4	33.4	33.9	49.4	46.1	45	42.4
	Cropped	77.6	43.3	86.3	65.7	50.4	45.7	86.7	73.5	76.2	67.2
	Overlapped	80.9	44.8	81.5	59.8	45.5	39	86.5	79.1	73.5	65.6
EEGNet	Trial-wise	75.4	56.8	93.4	65.8	51.1	48.7	89.5	82.7	86.5	72.2
	Cropped	81.2	43.5	83.4	67.9	48.1	49.8	75.1	77.3	79	67.3
	Overlapped	85.2	53.5	89.6	68.8	57.6	51.3	90	79.8	79.4	72.8
EEGResNet	Trial-wise	66.2	38.1	69.2	41.1	34.5	35.8	59.1	65.9	60.7	52.3
	Cropped	75.5	38.2	79.4	44.6	38.7	48.8	75.4	75.2	65.9	60.2
	Overlapped	75.5	39.1	76.8	48.7	40.3	44.8	80.2	73.4	66.6	60.6




图10 在 Dataset 2a 上 9 组参数组合的 overlapped 策略的识别准确率提升百分比的比较

从图10可以看出,除 Hybrid ConvNet 和 EEGResNet 在 $\alpha = 500$, $\beta = 200$ 和 $\alpha = 600$, $\beta = 200$ 的参数设置之外, overlapped 的各组参数设置的识别准确率均较 cropped 的识别准确率有所提升. 由图10也可看出,随着 β 值的增加,即重叠的时间部分减少, overlapped 策略的识别准确率提升百分比也在降低. Shallow ConvNet 和 EEGResNet 在 $\alpha = 800$, $\beta = 100$ 时,识别准确率提升百分比最大,分别达到了 5.826% 和 2.65%. Deep ConvNet 和 EEGNet 在 $\alpha = 600$, $\beta = 100$ 时,识别准确率提升百分比最大,分别达到了 23.461% 和 5.887%. 由此可见,可根据应用的不同模型,通过不断调整,可得到最适合该模型的 α 和 β 参数值,进而得到较高的识别准确率.

4.4 Dataset 2b 实验结果对比

同样,在 Dataset 2b 数据集上采用 cropped 和 overlapped 两种策略训练 5 种深度神经网络模型,得到所有受试者的测试集上的识别准确率如表4所示. 其中,实验的 overlapped 训练方法中的 α , β 参数值分为设置为 500 和 100.

由表4可以看出,在 Dataset 2b 数据集上, trial-wise 训练策略在 Shallow ConvNet、Deep ConvNet 和 EEGNet 3 种模型上取得更好的分类准确率, cropped 训练策略在 EEGResNet 模型上取得更好的分类准确率, overlapped 训练策略在 Hybrid ConvNet 模型上取得更好的分类准确率.

从表2、表3和表4中的实验结果可以看出,虽然 overlapped 方法不能同时比 trial-wise 和 cropped 方法显著提升识别准确率. 但是,采用 student-test 方式进行假设检验,在 Dataset 2a 和 Dataset 2b 数据集上的 5 种不同模型, overlapped 方法总能比 trial-wise 或 cropped 方法显著提升识别准确率 ($p < 0.05$ 或 $p < 0.01$). 实际上,针对 EEG 信号的预处理过程,在不同数据集和不同卷积神经网络模型下, trial-wise 方法由于样本量较少,更适合于简单模型或数据集(如 Dataset 1 数据集和 Shallow ConvNet 模型). Cropped 方法能够弥补样本不足和特征维度较高的缺点,因此更适合复杂的模型或数据量较大的情况(如 Dataset 2a/2b 数据集和 Hybrid ConvNet/EEGResNet 模型). 不同于二者都有适应自己情况的数据集和模型,通过实验结果可以看出, overlapped 方法能够同时满足数据量较小/较大、模型

较简单/复杂的情况, 其对于运动想象识别率的鲁棒性较高. 在实际基于运动想象的脑机接口应用中, 采用

overlapped 方法能够极大的降低对于数据集和模型的依赖性, 保证运动想象识别准确率的稳定性.

表4 Trial-wise、cropped 和 overlapped (500, 100) 方法在 Dataset 2b 数据集上的识别准确率比较 (%)

Network	Strategy	Subject									Average
		1	2	3	4	5	6	7	8	9	
Shallow ConvNet	Trial-wise	72.6	69.3	79.8	97.2	95.7	84.4	85.4	89.3	84.8	84.3
	Cropped	71	56	63.9	93.4	88.9	82.3	77.1	89.8	76.9	77.7
	Overlapped	76.2	65	72.5	96.8	95.1	87.6	83.9	90.7	78.8	83
Deep ConvNet	Trial-wise	71.1	78.8	85.1	97.5	97.6	84.2	90.2	93.5	82.6	85.6
	Cropped	61.6	54.9	64.3	93.8	58.8	52.3	50	73.4	68.8	64.2
	Overlapped	72.3	60.9	69.6	95.2	86.6	82.5	79.9	90	78.2	79.5
Hybrid ConvNet	Trial-wise	59.6	54.3	55.8	70.7	68.6	61	61.9	70.9	63.4	62.9
	Cropped	73.5	55.9	66.6	90.2	92.4	82.7	75.6	90	77.8	78.3
	Overlapped	72.4	61.2	70.7	95.1	92.6	82.4	74.1	88.1	77.3	79.3
EEGNet	Trial-wise	74.5	69.9	86.2	97.2	93.7	87.7	92	91.7	84.3	86.4
	Cropped	73.8	56.7	64.6	93.2	81.9	85.8	72.8	91.5	73	77
	Overlapped	77.7	62.8	75.9	97.1	97.1	85.9	86.9	90.7	82.8	84.1
EEGResNet	Trial-wise	73	57.5	66.8	94.4	93.1	75.8	76.2	85.8	75.5	77.6
	Cropped	74.4	63.8	72.5	96.5	93.2	78.7	78	90.4	77.1	80.5
	Overlapped	73.6	58.7	66.3	95.1	91.2	76.1	82.1	88.3	73.8	78.4

在 Dataset 2b 数据集上, 同样将 α 设置为 500、600 或 800, β 设置为 100、150 或 200, 共产生 9 组参数组合, 相比于 cropped 策略, 9 组不同参数组合的 overlapped 策略应用于 5 种不同模型的识别准确率的提升百分比如图 11 所示.

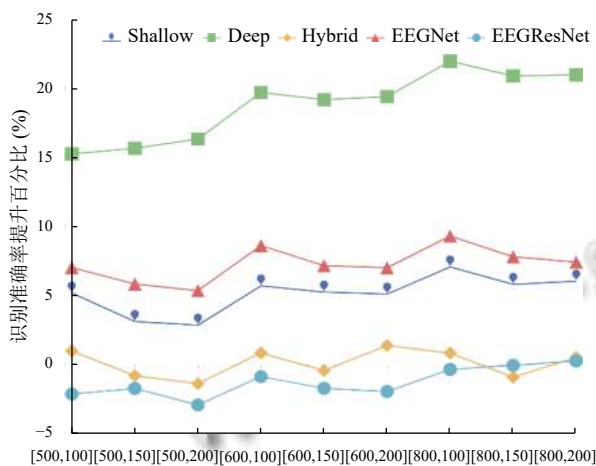


图 11 在 Dataset 2b 上 9 组参数组合的 overlapped 策略的识别准确率提升百分比的比较

从图 11 可以看出, overlapped 训练策略在 Shallow ConvNet、Deep ConvNet 和 EEGNet 3 种模型的识别准确率提升百分比比较高. 随着 β 值的增加, 即重叠的时间部分减少, overlapped 策略的识别准确率提升百分比也在降低. Shallow ConvNet、Deep ConvNet 和 EEGNet 在 $\alpha = 800, \beta = 100$ 时, 识别准确率提升百分比

最大, 分别达到了 7.101%、21.965% 和 9.335%. Hybrid ConvNet 在 $\alpha = 600, \beta = 200$ 时, 识别准确率提升百分比最大, 达到了 1.423%. 对于 EEGResNet, 9 种参数组合中, 仅有 $\alpha = 800, \beta = 200$ 时, overlapped 策略的识别准确率才有提升.

综合以上在 3 个数据集上应用 3 种不同训练策略的实验结果分析, 由于 Dataset 1、2a 和 2b 数据集中每个样本的电极数分别为 64、22 和 3, 在使用相同的采样率时, Dataset 2b 数据集的数据量要远小于 Dataset 1 和 2a 的, 因此, 对于 Dataset 1 和 2a 数据集, 在遇到简单模型 (如 Shallow ConvNet 模型) 时, trial-wise 和 overlapped 训练策略的识别性能相差不多, 当遇到更复杂的模型时, overlapped 训练策略可提供的大量样本量的优势得以体现出来. 对于 Dataset 2b 数据集, 其数据量本身不大, 所以在简单模型上应用 trial-wise 训练策略的效果更好, 对于复杂模型, 由于数据量的限制, overlapped 训练策略较 cropped 训练策略的优势不大.

实际上, 由于大数据时代的到来, 迁移学习形成的海量样本集, 促使我们使用更复杂的模型完成 MI 的分类工作, 如 Hybrid ConvNet 和 EEGResNet, 此时采用 overlapped 训练策略能够保证较高的鲁棒性, 并且避免 trial-wise 训练策略带来的过拟合问题.

4.5 时间复杂度对比

本文实验还记录了每个模型在应用不同训练策略时每次迭代所花费的时间, 以探究 overlapped 策略在

获得更好的分类性能的同时,其时间复杂度与 cropped 策略的时间复杂度的对比情况。

以 Dataset 2a 数据集的 Subject 1 的数据为例,5 种不同模型在应用 cropped 策略和应用 overlapped 的 9 种参数组合(与第 4.3 节中的参数组合相同)情况下,平均每轮训练迭代所花费的时间如表 5 所示。

由表 5 可以看出, α 和 β 值的增加都会导致平均训练迭代时间减少,根据 overlapped 的切分策略公式(8),切分的份数 $n = 1 + \frac{T - \alpha}{\beta}$ 会随着 α 和 β 值的增加而减小,

训练样本量变多,从而导致训练时间复杂度变高。从表 5 中还可发现,使用 overlapped 策略的 Shallow ConvNet 的平均训练迭代时间均少于 cropped 策略的,还有 Deep ConvNet 和 EEGNet,其 9 种参数组合 overlapped 策略的分类性能均高于 cropped 策略,而有些组合的平均训练迭代时间要少于 cropped 策略的。这可以说明, overlapped 策略的分类性能的好坏并不与时间复杂度的高低呈某种特定的线性关系,可通过实验以选取时间复杂度低且分类性能好的参数组合。

表 5 Cropped 与 overlapped 策略应用于 5 种模型的平均每轮训练迭代所花费的时间对比 (s)

Strategy	Shallow ConvNet	Deep ConvNet	Hybrid ConvNet	EEGNet	EEGResNet
Cropped	4.45	3.41	4.51	1.72	34.4
Overlapped [500, 100]	-1.34	+1.47	+3.49	+0.19	+16.61
Overlapped [500, 150]	-2.23	-0.04	+1.30	-0.40	+1.76
Overlapped [500, 200]	-2.66	-0.75	+0.21	-0.69	-4.83
Overlapped [600, 100]	-0.73	+1.26	+4.40	+0.10	+16.87
Overlapped [600, 150]	-1.96	-0.13	+1.57	-0.47	-0.38
Overlapped [600, 200]	-2.45	-0.81	+0.23	-0.77	-8.39
Overlapped [800, 100]	-1.12	+0.30	+3.99	-0.04	+8.88
Overlapped [800, 150]	-2.04	-1.65	+1.54	-0.46	-2.70
Overlapped [800, 200]	-2.98	-2.26	-0.52	-0.90	-12.10

5 结论与展望

本文提出了一种新型的重叠时间切片的训练策略以改进深度神经网络在运动想象 EEG 信号模式识别中的性能。

首先,本文设计了重叠时间切片的训练策略并设计了全新的损失函数和预测标签方法。其次,在 Competition IV Dataset 1、2a 和 2b 数据集上分别建立使用 trial-wise、cropped 和 overlapped 策略的 5 种深度神经网络模型,其实验结果表明, overlapped 策略较 cropped 策略拥有更好的识别性能。对于使用的 5 种模型,在 Dataset 1、2a 和 2b 数据集上最高分类准确率分别达到 91.3%、77.3% 和 86.4%。最后,通过调整 overlapped 策略的 α 和 β 值,设计了 9 组不同的参数组合做分类性能和时间复杂度的对比实验。实验表明,不同的 α 和 β 参数组合会影响最终的分类性能,且分类性能的好坏并不与时间复杂度的高低呈某种特定的线性关系,可根据不同数据集,通过不断调整 α 和 β 来达到时间复杂度低且分类性能好的参数组合。在实验中,对于使用 overlapped 策略的 5 种模型,在 Dataset 1、2a 和 2b 数据集上最高分类准确率分别达到了 92.3%、77.8% 和 86.3%。本文所做工作验证了重叠时间切片策略在 MI-

BCI 中 EEG 信号模式识别任务中的有效性,可为构建 MI-BCI 的应用提供方法和思路上的参考。

今后的工作要通过优化深度神经网络结构以提升训练效率,并将重叠时间切片策略与其他优化策略相结合,如随机选取重叠切片,将不同组合的重叠切片输入到网络中进行训练,进一步提升运动想象 EEG 信号识别性能。

参考文献

- 1 Wolpaw JR, Birbaumer N, Heetderks WJ, *et al.* Brain-computer interface technology: A review of the 1st international meeting. *IEEE Transactions on Rehabilitation Engineering*, 2000, 8(2): 164–173. [doi: 10.1109/TRE.2000.847807]
- 2 Shende PM, Jabade VS. Literature review of brain computer interface (BCI) using electroencephalogram signal. 2015 International Conference on Pervasive Computing (ICPC). Pune: IEEE, 2015. 1–5.
- 3 Oralhan Z. A new paradigm for region-based P300 speller in brain computer interface. *IEEE Access*, 2019, 7: 106618–106627. [doi: 10.1109/ACCESS.2019.2933049]
- 4 Wang M, Li RJ, Zhang RF, *et al.* A wearable SSVEP-based BCI system for quadcopter control using head-mounted

- device. *IEEE Access*, 2018, 6: 26789–26798. [doi: [10.1109/ACCESS.2018.2825378](https://doi.org/10.1109/ACCESS.2018.2825378)]
- 5 Shu XK, Chen SG, Meng JJ, *et al.* Tactile stimulation improves sensorimotor rhythm-based BCI performance in stroke patients. *IEEE Transactions on Biomedical Engineering*, 2019, 66(7): 1987–1995. [doi: [10.1109/TBME.2018.2882075](https://doi.org/10.1109/TBME.2018.2882075)]
- 6 Xiao D, Mu ZD, Hu JF. Classification of motor imagery EEG signals based on energy entropy. 2009 International Symposium on Intelligent Ubiquitous Computing and Education. Chengdu: IEEE, 2009. 61–64.
- 7 Huang DD, Qian K, Oxenham S, *et al.* Event-related desynchronization/synchronization-based brain-computer interface towards volitional cursor control in a 2D center-out paradigm. 2011 IEEE Symposium on Computational Intelligence, Cognitive Algorithms, Mind, and Brain (CCMB). Paris: IEEE, 2011. 1–8. [doi: [10.1109/CCMB.2011.5952122](https://doi.org/10.1109/CCMB.2011.5952122)]
- 8 Ang KK, Chin ZY, Wang CC, *et al.* Filter bank common spatial pattern algorithm on BCI Competition IV datasets 2a and 2b. *Frontiers in Neuroscience*, 2012, 6: 39.
- 9 张顺, 龚怡宏, 王进军. 深度卷积神经网络的发展及其在计算机视觉领域的应用. *计算机学报*, 2019, 42(3): 453–482.
- 10 韩文静, 李海峰, 阮华斌, 等. 语音情感识别研究进展综述. *软件学报*, 2014, 25(1): 37–50. [doi: [10.13328/j.cnki.jos.004497](https://doi.org/10.13328/j.cnki.jos.004497)]
- 11 胡章芳, 张力, 黄丽嘉, 等. 基于时频域的卷积神经网络运动想象脑电信号识别方法. *计算机应用*, 2019, 39(8): 2480–2483. [doi: [10.11772/j.issn.1001-9081.2018122553](https://doi.org/10.11772/j.issn.1001-9081.2018122553)]
- 12 Tabar YR, Halici U. A novel deep learning approach for classification of EEG motor imagery signals. *Journal of Neural Engineering*, 2017, 14(1): 016003. [doi: [10.1088/1741-2560/14/1/016003](https://doi.org/10.1088/1741-2560/14/1/016003)]
- 13 褚亚奇, 朱波, 赵新刚, 等. 基于时空特征学习卷积神经网络的运动想象脑电解码方法. *生物医学工程学杂志*, 2021, 38(1): 1–9.
- 14 Dai MX, Zheng DZ, Na R, *et al.* EEG classification of motor imagery using a novel deep learning framework. *Sensors*, 2019, 19(3): 551. [doi: [10.3390/s19030551](https://doi.org/10.3390/s19030551)]
- 15 Dai GH, Zhou J, Huang JH, *et al.* HS-CNN: A CNN with hybrid convolution scale for EEG motor imagery classification. *Journal of Neural Engineering*, 2020, 17(1): 016025. [doi: [10.1088/1741-2552/ab405f](https://doi.org/10.1088/1741-2552/ab405f)]
- 16 Schirrneister RT, Springenberg JT, Fiederer LDJ, *et al.* Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 2017, 38(11): 5391–5420. [doi: [10.1002/hbm.23730](https://doi.org/10.1002/hbm.23730)]
- 17 Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems*. Lake Tahoe: ACM, 2012. 1097–1105.
- 18 Hertel L, Barth E, Käster T, *et al.* Deep convolutional neural networks as generic feature extractors. 2015 International Joint Conference on Neural Networks. Killarney: IEEE, 2015. 1–4.
- 19 Clevert DA, Unterthiner T, Hochreiter S. Fast and accurate deep network learning by exponential linear units (ELUs). *arXiv: 1511.07289*, 2015.
- 20 Lawhern VJ, Solon AJ, Waytowich NR, *et al.* EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces. *Journal of Neural Engineering*, 2018, 15(5): 056013. [doi: [10.1088/1741-2552/aace8c](https://doi.org/10.1088/1741-2552/aace8c)]
- 21 He KM, Zhang XY, Ren SQ, *et al.* Deep residual learning for image recognition. *Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016. 770–778.