

基于ICEEMDAN分解的SSVEP神经网络分类模型

李晓明, 郜东瑞, 陈俊

(成都信息工程大学 计算机学院, 四川 成都 610225)

摘要: 稳态视觉诱发电位因其高信噪比和高信息传输速率, 成为脑机接口最常用的控制信号之一。然而, 目前基于深度学习的方法过度依赖于个别被试者的校准资料, 在被试间的分类性能方面还存在较大改进空间。针对上述难题, 结合改进的自适应噪声完备集合经验模态分解、基于图卷积网络的空间特征提取器以及基于压缩激励的特征融合模块提出ICE-GSE算法。该算法利用改进的自适应噪声完备集合经验模态分解法将稳态视觉诱发电位信号分解成一组本征模态函数, 有效降低了噪声和伪影的影响。空间特征提取器的邻接矩阵能充分表达脑电信号的空间位置关系, 从而更好地学习空间域特征。为提升目标识别精度和算法鲁棒性, 进一步引入特征融合模块, 以便针对性选择与任务最相关的通道。在两个公开数据集上, 时间窗口长度设置为0.5~1.0 s, 对ICE-GSE与其他传统方法和深度学习方法进行全方面比较。实验结果表明, 在跨被试情况下, ICE-GSE的分类精度和信息传输速率相较于对照方法更加优异, 证明了其在分类任务中的可行性。

关键词: 稳态视觉诱发电位; 脑机接口; 自适应噪声完备集合经验模态分解; 本征模态函数; 图卷积; 压缩激励

DOI: 10.11907/rjtk.241159

开放科学(资源服务)标识码(OSID):

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2025)004-0048-08



SSVEP Neural Network Classification Model Based on ICEEMDAN Decomposition

LI Xiaoming, GAO Dongrui, CHEN Jun

(College of Computer Science, Chengdu University of Information Technology, Chengdu 610225, China)

Abstract: Steady state visual evoked potentials have become one of the most commonly used control signals in brain computer interfaces due to their high signal-to-noise ratio and high information transmission rate. However, current deep learning based methods overly rely on individual subject calibration data, and there is still significant room for improvement in inter subject classification performance. To address the above challenges, the ICE-GSE algorithm is proposed by combining an improved adaptive noise complete set empirical mode decomposition, a spatial feature extractor based on graph convolutional networks, and a feature fusion module based on compressive excitation. This algorithm utilizes an improved adaptive noise complete set empirical mode decomposition method to decompose steady-state visual evoked potential signals into a set of intrinsic mode functions, effectively reducing the influence of noise and artifacts. The adjacency matrix of the spatial feature extractor can fully express the spatial positional relationship of EEG signals, thereby better learning spatial domain features. To improve the accuracy of target recognition and algorithm robustness, a feature fusion module is further introduced to selectively select the most relevant channel for the task. On two publicly available datasets, the time window length was set to 0.5-1.0 s to comprehensively compare ICE-GSE with other traditional and deep learning methods. The experimental results show that in cross subject situations, the classification accuracy and information transmission rate of ICE-GSE are superior to the control method, demonstrating its feasibility in classification tasks.

Key Words: steady-state visual evoked potential; brain-computer interface; improved complete ensemble empirical mode decomposition with adaptive noise; intrinsic modal functions; graph convolution; squeeze-excitation

收稿日期: 2024-02-23

扫描二维码阅读全文:



基金项目: 国家自然科学基金青年科学基金项目(82102175)

作者简介: 李晓明(1998-), 男, 成都信息工程大学计算机学院硕士研究生, 研究方向为脑机接口与深度学习; 郜东瑞(1987-), 男, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为脑机接口; 陈俊(1971-), 男, 成都信息工程大学计算机学院副教授、硕士生导师, 研究方向为密码硬件的侧信道分析、密码算法的快速实现、机器学习。本文通讯作者: 陈俊。

0 引言

脑机接口(Brain-Computer Interface, BCI)为人的大脑与外部设备提供了可直接沟通的渠道,是目前热门研究方向。在医疗健康方面,BCI可以帮助患有严重运动障碍的病人恢复部分日常生活功能^[1-2]。BCI系统依赖于多种模式的神经成像,例如脑电图、脑磁图、功能性近红外光谱等^[3-5]。由于具有便携性、低成本和高时间分辨率等优势,脑电图成为最主要的神经成像方式^[6-7]。脑电信号的典型范式包括P300、混合BCI、运动想象和稳态视觉诱发电位(Steady State Visual Evoked Potential, SSVEP)^[8-11]。在以往研究中,SSVEP因具有高信噪比和高通信速率的优势而受到广泛关注^[12]。SSVEP是指当被试者注视不同频率闪烁的目标块时,会产生与目标块频率相近的脑电信号。基于SSVEP的BCI系统性能在很大程度上受限于识别算法的准确性和鲁棒性。

目前,相关研究人员已提出一系列优秀的特征提取方案,主要分为传统方法与深度学习方法两大类。在传统特征提取方法中,一些研究人员开发了基于多通道的先验频率算法,例如典型相关分析(Canonical Correlation Analysis, CCA)和功率谱密度分析(Power Spectral Density Analysis, PSDA)^[13-14]。CCA相较PSDA在滤除脑电信号伪影方面性能更加出色,因此成为主流的SSVEP分类算法,并出现了多种改进算法。例如,文献[15]提出的MwayCCA算法通过最大化脑电信号张量和预构建信号矩阵优化参考信号;文献[16]认为预构建信号矩阵缺乏脑电数据的真实信息,提出多集典型相关分析方法MsetCCA;鉴于SSVEP是由基频和基频倍数的谐波构成,文献[17]引入滤波器组技术对原始CCA方法进行拓展。然而,脑电图信号会受到自发或干扰噪声的影响,使得SSVEP数据受到污染^[18]。文献[19]提出基于个体模板的IT-CCA,该方法将现有信号经过多次训练后得到的平均值作为单个被试的参考信号,在后续算法中得到广泛应用。尽管传统方法在分类性能方面表现出色,但往往高度依赖于手动特征提取和数据校准,这限制了其在实际应用中的灵活性与泛化能力^[20]。此外,SSVEP数据收集需要耗费大量时间和精力,如何将当前训练的被试跨越到另一个被试是一个具有挑战性的难题。

近年来,深度学习模型凭借其强大的特征提取能力在脑电领域的多个分类任务中得到了广泛应用。例如,文献[20]充分利用原始信号中的频谱和相位信息,使用快速傅里叶变换将SSVEP信号转换到频域,然后使用CNN对输入信号进行特征提取;文献[21]提出的EEGNet利用卷积神经网络(Convolutional Neural Network, CNN)对原始信号的时间和空间信息进行特征提取;文献[22]针对目标块的实时响应需求,提出增强现实的多目标快速分类深度学习

方法。由于SSVEP信号具有非平稳性,导致不同被试间的目标识别性能存在显著差异,即使是同一被试在不同时间段的数据分布也会有所不同^[23]。因此,如何从不同被试的训练数据中提取更合适的共同特征,并将其应用到新的被试身上,从而缩短校准数据过程,这成为需要解决的一个难题。在跨被试领域下,传统机器学习方法的分类性能明显下降,远不及其在被试内的表现。虽然深度学习方法在单个被试内取得了优异的分类效果,但在跨被试场景下,其泛化性能仍有提升空间。

针对上述问题,本文结合改进的自适应噪声完备集合经验模态分解(Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, ICEEMDAN)、基于图卷积网络(Graph-CNN)的空间特征提取器和基于压缩激励(Squeeze-Excitation, SE)特征融合模块的优点提出了ICE-GSE网络^[24-25]。在该网络中,首先,ICEEMDAN将非平稳信号模态分解成一组本征模态函数(Intrinsic Modal Functions, IMFs),从而有效利用不同振动模态信息,并减少噪声和伪影的影响;其次,每个IMF经过时间维度信息上的卷积,目的在于对时域特征进行提取,将数据输入到已初始化邻接矩阵的空间特征提取器中;再次,基于Graph-CNN的空间特征提取器描述脑电信号中不同节点的内在关系,并利用动态Graph-CNN学习节点边之间的权重,使网络能自适应调整不同节点间的关系;最后,采用基于SE的特征融合模块选择与分类任务相关的通道^[26]。为了验证所提算法的有效性,本研究分别在两个公开数据集和时间窗口长度(0.5~1.0 s)上对被试进行评估。实验结果表明,所提算法在分类精度和信息传输速率方面均优于对照模型。此外,本文还引入t-随机领域嵌入(t-Distributed Stochastic Neighbor Embedding, t-SNE)可视化技术和消融实验进一步使算法具有可解释性与合理性。

1 ICE-GSE网络构建

ICE-GSE网络主要由ICEEMDAN预处理、时间特征提取器、空间特征提取器以及特征融合模块构成。总体框架如图1所示。首先,数据经过ICEEMDAN处理,从非平稳脑电信号中找到一组IMFs,目的是从不同局部振动函数进行数据分析;其次,分解完成的数据输入到时间特征提取器中,对时间维度信息进行特征提取;再次,数据进入空间特征提取器,通过初始化邻接矩阵动态学习节点之间的关系,自适应调整节点间的关联程度,从而更好地捕捉到图结构间的空间域信息。由于原始信号被分为不同子带,网络产生了多个分支。为了更好地得到有价值的信息,本文在进行数据融合时选择基于SE的特征融合模块,使得模型能自适应学习每个通道的权重。

1.1 ICEEMDAN模块

经验模态分解(Empirical Mode Decomposition, EMD)




Fig. 1 Overall structure of ICE-GSE

图1 ICE-GSE 总体框架

是一种非线性和非平稳数据的分解方法,可以将复杂的信号分解成有限个IMF,具有自适应性,因此其效率很高,对脑电类信号也十分适用^[27]。基于所有复杂信号均可由简单的IMF组合表示的原理,EMD将输入信号分解为多个IMF和残差。在分解过程中,IMF容易受到模态混合的干扰,严重情况下会出现错误的时频分布现象,进而使其失去物理意义。针对这一问题,许多研究者对EMD算法进行了改进。例如,文献[28]在原始信号中添加合理的白噪声信号,提出集成经验模态分解(Integrated Empirical Mode Decomposition, EEMD)方法,然而其仍存在明显的重构误差问题;为解决这一问题,文献[29]进一步提出自适应噪声完备集合经验模态分解(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, CEEMDAN)算法;为降低信号噪声,文献[30]提出ICEEMDAN算法,克服了残差影响、重构误差、杂散模态等问题,可有效分解得到不同尺度的IMF,确保其均具有物理意义的窄带分量。

本文使用ICEEMDAN算法对SSVEP信号进行分解。令待分解SSVEP信号的某通道为 x ,向信号 x 中加入 k 组高斯白噪声,令序列 x^k 为:

$$x^k = x + \beta_1 E_1(\omega^k) \quad (1)$$

式中: β_1 为常数,用于确保所添加的白噪声与待分解信号间达到期望的信噪比; E_1 表示EMD计算后得到的IMF算子; $\omega^k (k = 1, \dots)$ 中的 k 表示所添加的第 k 组高斯白噪声。由此得到第一个IMF。表示为:

$$c_1^k = x - M(x^k) \quad (2)$$

$$C_1 = \frac{1}{K} \sum_{k=1}^K c_1^k \quad (3)$$

式中: M 为局部算子; c_1^k 为 x^k 的第1个IMF; C_1 为输入信号 x 的第1个IMF。由此得到第一残数 R_1 。表示为:

$$R_1 = x - C_1 \quad (4)$$

不断对 R_1 加入白噪声后,得到第二残数 R_2 和第2个IMF C_2 。表示为:

$$R_2 = \frac{1}{K} \sum_{k=1}^K M(R_1 + \beta_2 E_2(\omega^k)) \quad (5)$$

$$C_2 = R_1 - R_2 \quad (6)$$

式中: β_2 、 E_2 与式(1)同理。由此可推断出第 n 个残差 R_n 和IMF C_n 。表示为:

$$R_n = \frac{1}{K} \sum_{k=1}^K M(R_{n-1} + \beta_n E_n(\omega^k)) \quad (7)$$

$$C_n = R_{n-1} - R_n \quad (8)$$

式中: n 表示分解子带数。

最后,将分解得到的 n 个子带输入到ICE-GSE网络进行特征提取。

1.2 时间特征提取器

经过ICEEMDAN的分解,从原始数据中得到 k 个子带,每个子带的尺寸为 $N_{ch} \times N_{fc}$,其中 N_{ch} 表示通道数量, N_{fc} 表示时间长度,将其输入到时间特征提取器中。该提取器在时间维度 N_{fc} 上进行卷积,其内核维度为 1×10 。经过时间上的卷积,特征图尺寸大小变为 $N_{ch} \times (N_{fc} - 10 + 1)$ 。为减少样本的单位方差问题,该提取器进行批量归一化BatchNorm处理。此外,为使网络能学习和表达更复杂的函数关系,该提取器还引入PReLU激活函数进行处理。

1.3 空间特征提取器

基于Graph-CNN的空间特征提取器利用初始化的邻接矩阵和切比雪夫多项式自适应学习节点间的关系,能更好地处理空间结构类数据。邻接矩阵通常用于描述图卷积中节点间的关系,记录其位置信息,确定矩阵值的常用方法为距离函数和 k 近邻法^[31-32]。在邻接矩阵中,节点表示数据样本,边表示样本间的关系。图2为电极间空间位置与邻接矩阵的关系,其中图2(a)为脑通道分布,图2(b)为数据采集,图2(c)为通道映射矩阵,图2(d)为矩阵特征点。

邻接矩阵 A 的公式为:

$$A_{ij} = \begin{cases} \exp\left(-\frac{\text{dist}_{(i,j)}^2}{2\theta^2}\right), & \text{if } \text{dist}_{(i,j)} \leq \gamma \\ 0 & \text{otherwise} \end{cases} \quad (9)$$

式中: θ 和 γ 为确定的参数; $\text{dist}_{(i,j)}$ 表示两个节点的距离; i 和 j 分别表示节点的行列。

图卷积也称为谱图滤波,其对数据进行基于频率或幅度的滤波,常用于数字信号处理领域。图 $\mathcal{G}$ 的拉普拉斯矩阵 L 表示为:

$$L = D - A \quad (10)$$

式中: D 表示对角矩阵,其对角值 D_{ii} 为 A 第 i 行的所




Fig. 2 The relationship between the spatial position between electrodes and the adjacency matrix

图2 电极间空间位置与邻接矩阵的关系

有值之和。 U 可由 L 的特征分解得到。计算公式为:

$$L = U\Lambda U^T \quad (11)$$

式中: $U = [u_0, u_1, \dots, u_{n-1}] \in \mathbb{R}^{n \times n}$, 表示特征值方阵; $\Lambda = \text{diag}(\lambda_0, \lambda_1, \dots, \lambda_{n-1}) \in \mathbb{R}^{n \times n}$, 表示对角矩阵。令 U 为分解函数傅里叶基, 则图傅里叶变换公式为:

$$\tilde{x} = U^T x \quad (12)$$

由此得到 x 为:

$$x = U\tilde{x} \quad (13)$$

信号 x 和信号 y 在图 $\mathcal{G}$ 的卷积公式为:

$$x * \mathcal{G} y = U((U^T x) \odot (U^T y)) \quad (14)$$

式中: $\odot$ 表示逐元素相乘。令 $g_\theta(\cdot)$ 代表滤波器, 则图中信号 x 经过滤波 $g_\theta(L)$ 的处理公式为:

$$g_\theta * \mathcal{G} x = g_\theta(L)x = g_\theta(U\Lambda U^T)x = U g_\theta(\Lambda) U^T x \quad (15)$$

然而, 使用式(15)需要进行 $O(n^2)$ 次计算, 成本较高。为提高计算速度, 空间特征提取器采用 K 阶切比雪夫多项式代替图滤波器 $g_\theta(\cdot)^{[33]}$ 。表示为:

$$g'_\theta(\Lambda) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\Lambda}) \quad (16)$$

式中: K 表示切比雪夫多项式参数; $\theta_0, \theta_1, \dots, \theta_{K-1}$ 为多项式系数; $\tilde{\Lambda} = 2\Lambda / \lambda_{\max} - I_n$, $\lambda_{\max}$ 为 Λ 对角元素中的最大值; I_n 为单位矩阵。

$T_k(x)$ 由以下公式递归获得:

$$\begin{cases} T_0(x) = 1, T_1(x) = x, \\ T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x), k \geq 2 \end{cases} \quad (17)$$

综上所述, 空间特征提取器的运算公式表示为:

$$\begin{aligned} y &= g'_\theta * \mathcal{G} x \\ &= g'_\theta(L)x \end{aligned}$$

$$\begin{aligned} &= \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\Lambda})x \\ &= \sum_{k=0}^{K-1} \theta_k \tilde{x}_k \end{aligned} \quad (18)$$

1.4 特征融合模块

为解决网络在处理不同通道特征的均衡问题, 文献[26]提出SE模块。在传统网络结构中, 每个通道的特征被平等对待, 但是通道间的信息贡献却是不同的。SE模块允许自适应学习每个通道的权重, 通过学习通道间标量值的依赖关系, 从而更能强调输入数据的关键通道特征。SE可被分为压缩和激励两部分。压缩通过全局池化操作进行, 将全局空间信息压缩为通道描述符。压缩得到的特征 Z 可由输入特征维度为 $H \times W$ 的信号 U 生成。具体公式为:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) \quad (19)$$

式中: u_c 为输入 U 的第 c 个通道; F_{sq} 为压缩操作。

激励操作的设计类似于循环神经网络中的门控机制, 通过参数 W 学习每个通道的权重, 从而捕捉通道间的关系。计算公式为:

$$s = F_{ex}(z, W) = \sigma(W_2 \delta(W_1 z)) \quad (20)$$

式中: F_{ex} 表示提取操作; σ 为激活函数; $W_1 \in \mathbb{R}^{\frac{C}{r} \times C}$, $W_2 \in \mathbb{R}^{\frac{C}{r} \times C}$ 。其分别涉及降维层和增维层, 以及中间一次ReLU激活函数 δ ; 变换维度参数为 r 。最终输出为:

$$\tilde{x}_c = F_{scale}(u_c, s_c) = u_c \cdot s_c \quad (21)$$

式中: F_{scale} 表示通道逐元素相乘。

2 实验方法与结果分析

2.1 实验环境与参数设置

本文实验基于Windows 10操作系统, 数据预处理使用Matlab R2021b版本完成操作, 深度学习网络相关操作在Pycharm 2022编辑器下的Pytorch 1.13.0下完成。GPU采用NVIDIA GeForce GTX 1660 SUPER (6 GB内存), CPU采用AMD锐龙 3700X的8核处理器。

对于深度学习网络, 时间特征提取器中卷积核维度为 1×10 , 输出通道为输入的两倍, 并依次经过PReLU激活函数与Dropout(0.5)。对于空间特征提取器, 研究最终将其最大阶数设为3, 输出通道与输入相同。对于特征融合模块, 输入与输出通道相同, 缩减比率设置为8, 然后进行全连接分类。整个训练的学习率lr设置为0.007, 批量大小batchsize设置为32, 利用Adam(beta1 = 0.9, beta2 = 0.999)优化器更新计算参数。

2.2 数据集

在两个公开SSVEP数据上进行实验。公开数据集A由12个目标刺激块构成, 分别以 4×3 的顺序依次排列, 每个目标块以1次/s的频率更新在27英寸的外接显示器上,

其中目标块设计为频率(9.25 Hz:0.5 Hz:14.75 Hz)和相位(0.0 π :0.5 π :1.5 π)^[34]。相关工作人员使用 BioSemi ActiveTwo EEG 系统对 10 名健康被试者收集脑电数据,采样频率为 2 048 Hz,枕区布置了 8 个电极,具体位置遵循 10-20 BCI 系统的 CMS 电极布局。每位受试者需要完成 15 个实验块,而每个实验块包括 12 个目标刺激实验。实验完成后,对每位被试者的脑电数据进行下采样,将采样率降至 256 Hz。每个实验的前 135 ms 被作为视觉延迟数据,而训练数据则是从视觉延迟之后的时间点开始获取。整个数据集包含 180 个实验。

公开数据集 B 由 40 个目标刺激块构成,分别以 5 × 8 的顺序依次排列,每个目标块以 1 次/s 的频率刷新在界面上,其中目标块设计为(8 Hz:0.2 Hz:15.8 Hz)和相位(0.0 π :0.5 π :1.5 π)^[35]。相关工作人员使用 Synamps2 EEG 系统对 35 名健康被试者采集脑电数据,采样频率为 1 000 Hz,64 个通道的排列采用国际 10-20 电极位置系统。每位被试者参与 6 个实验块,每个块包含 40 个目标,共有 240 个实验。完成数据采集后,对每个被试者的脑电数据进行下采样,将采样率降低至 250 Hz。选取 PO3、POz、PO4、O1、Oz、O2、Pz、PO5 和 PO6 共 9 个电极作为输入通道。

两个公开数据集均采用留一法(left-One-Subject Out, LOSO)交叉验证策略。具体来说,在进行模型评估时将数据集中的某个被试数据作为测试集,其余被试数据作为训练集。这一过程循环执行,直至每个被试都成为测试对象为止。

2.3 基线方法

为评估所提方法的性能,在公开数据集 A 和公开数据集 B 上与以下方法进行比较:①TRCA^[12]。该方法属于空间过滤技术,通过优化现有数据间的可重复性来学习空间过滤器,从而提取数据中的有价值成分,并采用现有数据的平均值作为参考信号。采用空间过滤器计算被试者测试数据的投影特征与参考信号间的相关系数,从而生成分类结果;②C-CNN^[20]。该方法首先使用傅里叶变换将数据从时域转换到频域,利用变换后数据的实数、复数模拟频域和相位信息,然后输入到网络中进行特征提取。该网络结构简单,由两次卷积和一次全连接构成,其中卷积层负责学习频域和相位信息,全连接层负责对提取后的特征进行汇总,由此得到分类结果;③FB-EEGNet^[36]。该方法是针对脑电信号提出的深度学习模型。EEGNet 主要由 4 层网络组成,分别为对各通道进行滤波操作的卷积层、对通道加权的深度卷积层、提取特征的可分离卷积层和全连接层,而 FB-EEGNet 则是使用 EEGNet 对多个不同谐波信号分别进行特征提取;④FB-CNN^[37]。该方法是在 C-CNN 基础上提出的一种基于谐波分析思想的改进方法。其首先采用滤波器组将原始信号分解为多个谐波信号;然后将这些信号分别输入到多个分支网络进行独立的特征提取;

最后,网络对各个分支提取的特征进行拼接,并通过全连接层进行特征汇总,得到最终分类结果。

2.4 评价指标

采用分类准确率和信息传输速率(Information Translate Rate, ITR)评价各方法性能。分类准确率指分类正确的样本数量与总测试样本数量的比值。ITR 则反映了 BCI 系统在单位时间内传递的信息量,通常以 bit/min 为单位。计算公式为:

$$ITR = \frac{60}{T} \times \left[\log_2^N + P \log_2^P + (1 - P) \log_2^{\frac{1-P}{N-1}} \right] \quad (22)$$

式中: T 为平均选择时间, N 为当前数据集类别总数, P 为识别准确率。为了更好地模拟实际识别场景,向平均选择时间 T 中加入 0.5 s 的凝视目标块时间^[12,38]。

2.5 实验结果与分析

2.5.1 IMF 数量

为更好地选择 ICEEMDAN 分解后的 IMF,对公开数据集 A 中的被试 5 进行实验,并对该被试中 Oz 电极单通道进行分解和可视化显示。由图 3 可知,Oz 通道被分解为 6 个 IMF 和 1 个残余信号。根据图中频域信息,IMF 包含的信息为递增关系,研究设定从 IMF1 开始进行累加实验。单个 IMF1 累加到所有分解子带的 7 次实验中,在 1.0 s 窗口下的正确率分别为 85.51%、89.22%、93.06%、91.33%、90.27%、87.14% 和 86.11%,可以看出当选择 IMF1~IMF3 时分类性能最优。因此本文采用深度学习网络分别对前 3 个 IMF 子带进行特征提取。





Fig. 3 ICEEMDAN decomposition chart


图3 ICEEMDAN 分解图

2.5.2 数据集 A 实验结果

图 4 为各方法在公开数据集 A 上的实验结果,其中数据长度采集范围为 0.5~1.0 s,时间步长为 0.1 s。可以看出,在所有时间窗口长度中,分类性能从高到低依次为 ICE-GSE、FB-CNN、C-CNN、FB-EEGNet、TRCA。本文方法 ICE-GSE 在所选时间长度上的平均分类准确率和 ITR 均取得最好结果。



(a) Accuracy
(a) 准确率



(b) ITR
(b) 信息传输速率

Fig. 4 Experimental results of various methods on public dataset A

图4 各方法在公开数据集A上的实验结果

2.5.3 数据集B实验结果


图5为各方法在公开数据集B上的实验结果,其中时间窗口长度跨度为0.5~1.0 s,时间步长取0.1 s。可以看出,ICE-GSE网络在平均分类准确率和ITR方面均优于其他基线方法。

2.5.4 消融实验


为验证ICEEMDAN分解、空间特征提取器、特征融合模块对ICE-GSE算法性能的有效性,选择以下模块进行消融实验:①GSE。原始数据输入网络;②ICE-SE。不包含空间特征提取器;③ICE-G。不包含特征融合模块;④ICE-GSE。IMF输入,包含所有模块。在时间窗口1 s、公开数据集A上对被试7进行验证,结果见图6。可以看出,分别去掉ICEEMDAN分解、空间特征提取器、特征融合模块均会对整个算法性能产生影响,其中去掉ICEEMDAN分解对算法的影响最为显著,准确率下降至85.22%,表明ICEEMDAN分解得到的IMF对算法具有关键作用。

2.5.5 分类结果可视化

为充分探索所提算法优于其他深度学习算法的原因,本文引入t-SNE技术将深度学习网络中提取的高维度特



(a) Accuracy
(a) 准确率



(b) ITR
(b) 信息传输速率

Fig. 5 Experimental results of various methods on public dataset B

图5 各方法在公开数据集B上的实验结果




Fig. 6 Ablation experiment results

图6 消融实验结果

征投射到二维平面上,从而间接显示其高维空间的分布差异。图7为各算法在公开数据集A、时间窗口为1 s、被试5上的可视化结果。可以看出,与图7(a)FB-EEGNet、(b)C-CNN、(c)FB-CNN相比,图7(d)ICE-GSE算法分类目标内

的特征点距离更近,分类目标之间的间隔更明显,分类性能优于其他深度学习算法。




Fig. 7 Visualization of classification results

图7 分类结果可视化

3 结语

采集 SSVEP 数据是一个耗时耗力的过程,并且需要对大量被试数据进行校准,这不符合基于 SSVEP 的 BCI 实际应用需求。因此,在被试间的情境下提升分类性能成为一个具有重要价值的研究方向。本文提出基于 ICEEMDAN 分解的深度学习算法 ICE-GSE,通过分解减小噪声影响,各分支在时间和空间进行充分的特征提取以及多分支的通道权重选择。为验证所提算法的性能,首先探索适合的分解数量,然后在两个公开数据集上与其他基线方法进行比较。实验结果表明,所提算法的平均分类准确率和 ITR 均具有明显优势。

尽管 ICE-GSE 在跨被试情境中表现出良好的性能,但其仍然存在一些局限性。例如,在更短的时间窗口场景中,深度学习仅依靠简短的信息,分类性能会受到较大影响。脑电数据质量决定分类性能,如何更有效地预处理脑电信号成为关键。此外,模型训练过程需要大量数据,这可能会限制其在实际应用中的可行性。因此,提高预处理算法性能以及进一步减少训练数据量是未来研究的方向之一。

参考文献:

- [1] CHAUDHARY U, BIRBAUMER N, RAMOS-MURGUIALDAY A. Brain - computer interfaces for communication and rehabilitation [J]. Nature Reviews Neurology, 2016, 12(9): 513-525.
- [2] YANG C, WU H, LI Z, et al. Mind control of a robotic arm with visual fusion technology [J]. IEEE Transactions on Industrial Informatics, 2017, 14(9): 3822-3830.
- [3] LOTTE F, BOUGRAIN L, CICHOCKI A, et al. A review of classification algorithms for EEG-based brain-computer interfaces: a 10 year update [J]. Journal of Neural Engineering, 2018, 15(3): 031005.
- [4] CHEN Y H, SABA J, KUSCHNER E, et al. Magnetoencephalography and the infant brain [J]. NeuroImage, 2019, 189: 445-458.
- [5] NASEER N, HONG K S. fNIRS-based brain-computer interfaces: a review [J]. Frontiers in Human Neuroscience, 2015, 9:3.
- [6] LIU T, PELOWSKI M, PANG C, et al. Near-infrared spectroscopy as a tool for driving research [J]. Ergonomics, 2016, 59(3): 368-379.
- [7] SAWANGJAI P, HOMPOONSUP S, LEELAARPORN P, et al. Consumer grade EEG measuring sensors as research tools: a review [J]. IEEE Sensors Journal, 2019, 20(8): 3996-4024.
- [8] HALDER S, HAMMER E M, KLEIH S C, et al. Prediction of auditory and visual p300 brain-computer interface aptitude [J]. PLoS One, 2013, 8 (2): e53513.
- [9] YIN E, ZHOU Z, JIANG J, et al. A speedy hybrid BCI spelling approach combining P300 and SSVEP [J]. IEEE Transactions on Biomedical Engineering, 2013, 61(2): 473-483.
- [10] LI C, YANG H, CHENG L. Fugl-Meyer hand motor imagination recognition for brain-computer interfaces using only fNIRS [J]. Complex & Intelligent Systems, 2022, 8: 731-741.
- [11] CHABUDA A, DURKA P, ŻYGIEREWICZ J. High frequency SSVEP-BCI with hardware stimuli control and phase-synchronized comb filter [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2017, 26(2): 344-352.

- [12] NAKANISHI M, WANG Y, CHEN X, et al. Enhancing detection of SSVEPs for a high-speed brain speller using task-related component analysis[J]. *IEEE Transactions on Biomedical Engineering*, 2017, 65(1): 104–112.
- [13] LIN Z, ZHANG C, WU W, et al. Frequency recognition based on canonical correlation analysis for SSVEP-based BCIs[J]. *IEEE Transactions on Biomedical Engineering*, 2006, 53(12): 2610–2614.
- [14] WU Z, YAO D. Frequency detection with stability coefficient for steady-state visual evoked potential (SSVEP)-based BCIs[J]. *Journal of Neural Engineering*, 2007, 5(1): 36.
- [15] ZHANG Y, ZHOU G, JIN J, et al. L1-regularized multiway canonical correlation analysis for SSVEP-based BCI[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2013, 21(6): 887–896.
- [16] ZHANG Y U, ZHOU G, JIN J, et al. Frequency recognition in SSVEP-based BCI using multiset canonical correlation analysis[J]. *International Journal of Neural Systems*, 2014, 24(4): 1450013.
- [17] CHEN X, WANG Y, GAO S, et al. Filter bank canonical correlation analysis for implementing a high-speed SSVEP-based brain-computer interface[J]. *Journal of Neural Engineering*, 2015, 12(4): 046008.
- [18] HSU H T, LEE I H, TSAI H T, et al. Evaluate the feasibility of using frontal SSVEP to implement an SSVEP-based BCI in young, elderly and ALS groups[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2015, 24(5): 603–615.
- [19] BIN G, GAO X, WANG Y, et al. A high-speed BCI based on code modulation VEP[J]. *Journal of Neural Engineering*, 2011, 8(2): 025015.
- [20] RAVI A, BENI N H, MANUEL J, et al. Comparing user-dependent and user-independent training of CNN for SSVEP BCI[J]. *Journal of Neural Engineering*, 2020, 17(2): 026028.
- [21] WAYTOWICH N, LAWHERN V J, GARCIA J O, et al. Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials[J]. *Journal of Neural Engineering*, 2018, 15(6): 066031.
- [22] ZHAO X, DU Y, ZHANG R. A CNN-based multi-target fast classification method for AR-SSVEP[J]. *Computers in Biology and Medicine*, 2022, 141: 105042.
- [23] IBANEZ-SORIA D, SORIA-FRISCH A, GARCIA-OJALVO J, et al. Characterization of the non-stationary nature of steady-state visual evoked potentials using echo state networks[J]. *PloS One*, 2019, 14(7): e0218771.
- [24] RONG H, GAO Y, GUAN L, et al. GAM-based mooring alignment for SINS based on an improved CEEMD denoising method[J]. *Sensors*, 2019, 19(16): 3564.
- [25] SUCH F P, SAH S, DOMINGUEZ M A, et al. Robust spatial filtering with graph convolutional neural networks[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2017, 11(6): 884–896.
- [26] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7132–7141.
- [27] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering sciences*, 1998, 454(1971): 903–995.
- [28] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method[J]. *Advances in Adaptive Data Analysis*, 2009, 1(1): 1–41.
- [29] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]//*IEEE International Conference on Acoustics, Speech and Signal Processing*, 2011: 4144–4147.
- [30] COLOMINAS M A, SCHLOTTHAUER G, TORRES M E. Improved complete ensemble EMD: a suitable tool for biomedical signal processing[J]. *Biomedical Signal Processing and Control*, 2014, 14: 19–29.
- [31] SHUMAN D I, NARANG S K, FROSSARD P, et al. The emerging field of signal processing on graphs: extending high-dimensional data analysis to networks and other irregular domains[J]. *IEEE Signal Processing Magazine*, 2013, 30(3): 83–98.
- [32] GRADY L J, POLIMENI J R. *Discrete calculus: applied analysis on graphs for computational science*[M]. London: Springer, 2010.
- [33] DEFFERRARD M, BRESSION X, VANDERGHEYNST P. Convolutional neural networks on graphs with fast localized spectral filtering[C]//*Proceedings of the 30th International Conference on Neural Information Processing Systems*, 2016: 3844–3852.
- [34] NAKANISHI M, WANG Y, WANG Y T, et al. A comparison study of canonical correlation analysis based methods for detecting steady-state visual evoked potentials[J]. *PloS One*, 2015, 10(10): e0140703.
- [35] WANG Y, CHEN X, GAO X, et al. A benchmark dataset for SSVEP-based brain-computer interfaces[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, 25(10): 1746–1752.
- [36] YAO H, LIU K, DENG X, et al. FB-EEGNet: a fusion neural network across multi-stimulus for SSVEP target detection[J]. *Journal of Neuroscience Methods*, 2022, 379: 109674.
- [37] ZHAO D, WANG T, TIAN Y, et al. Filter bank convolutional neural network for SSVEP classification[J]. *IEEE Access*, 2021, 9: 147129–147141.
- [38] CHEN X, WANG Y, NAKANISHI M, et al. High-speed spelling with a noninvasive brain-computer interface[J]. *Proceedings of the National Academy of Sciences*, 2015, 112(44): E6058–E6067.

(责任编辑:尹晨茹)