

基于注意力机制的双通道多特征卷积脑电信号分类

张学军^{1,2}, 刘济玮¹, 李夏芸¹

(1. 南京邮电大学电子与光学工程学院、柔性电子(未来技术)学院, 南京 210023; 2. 南京邮电大学射频集成与微组装技术国家地方联合工程实验室, 南京 210023)

摘要: 基于稳态视觉诱发电位(Steady-state visual evoked potential, SSVEP)的脑机接口正在人机交互系统中快速发展, 但短时间窗下的SSVEP信号分类依然存在精度低、特征提取不充分等问题。针对以上问题, 本文提出了一种基于注意力机制的双通道多特征卷积神经网络(Attention enhancement-dual channel multi-feature convolutional neural network, AE-dCNN)。该网络首先利用通道注意力机制对不同通道的特征进行加权来增强有用信息的表示, 然后通过两个并行的通道分别提取信号的时域和频域特征, 最后将特征融合后进行分类。在公共和自建数据集上进行了跨被试和受试者独立实验, 结果表明, 本文提出的AE-dCNN模型在跨被试实验中达到了最高94.38%的准确率, 在受试者独立实验中达到92.36%的准确率。同时, 本文还探究了KAN(Kolmogorov-Arnold network)结构在脑电信息处理领域的应用, 结果表明KAN模型比多层感知机(Multilayer perceptron, MLP)模型在多数时间窗下有更高的准确率。

关键词: 稳态视觉诱发电位; 脑机接口; 卷积神经网络; KAN; 注意力机制

中图分类号: TP391 **文献标志码:** A

引用格式: 张学军, 刘济玮, 李夏芸. 基于注意力机制的双通道多特征卷积脑电信号分类[J]. 数据采集与处理, 2026, 41(5): 1421-1434. ZHANG Xuejun, LIU Jiwei, LI Xiayun. Dual-channel multi-feature convolutional EEG signal classification based on attention mechanism[J]. Journal of Data Acquisition and Processing, 2026, 41(5): 1421-1434.

引言

近年来, 脑机接口(Brain-computer interface, BCI)技术已成为医疗康复和信息科学的重要研究方向^[1]。BCI技术手段不依赖肢体活动的参与, 通过外连设备获取大脑活动的相关信息, 将电信号从神经元直接传递到外部系统^[2-4], 有效地促进了人脑与计算机之间的高效交互。BCI技术的出现为医疗科技的发展带来了显著的推动作用。

BCI技术通过采集脑电信号从而实现各种功能。脑电信号是从头皮表面记录到的大脑神经元活动产生的信号^[5], 目前, 其采集技术分为侵入式、半侵入式和非侵入式3种。侵入式方法是将电极直接移入大脑组织或颅内^[6], 由于侵入式方法对人体造成的创伤较大, 因此很少在健康人群中进行试验; 半侵入式方法是把电极植入到头皮和大脑皮层之间, 既降低了手术风险, 也提升了信号质量, 获得的信号比侵入式方法更为精确; 非侵入式方法则通过专业的传感器接收电信号, 具有操作方便和安全性更高的特点。在非侵入式BCI系统中, 常用的脑电信号包括稳态视觉诱发电位(Steady-state visual evoked potential, SSVEP)^[7-8]、感觉运动节律(Sensorimotor rhythm, SMR)^[9]、事件相关电位(Event-related poten-

tial, ERP)^[10]、运动想象信号^[11]和慢皮质电位(Scalp-recorded potential, SCP)^[12]等。其中,由于SSVEP信号具有高信噪比、易诱发,高信息传输速率及用户友好性等优点^[13],成为研究BCI系统的典型之一。

稳态视觉诱发电位最初由Adrian和Matthews于1934年提出^[14],它是指大脑受恒定频率外界视觉刺激时,大脑皮层自动产生与刺激频率及其谐波频率同频率的响应。对于SSVEP-BCI系统而言,充分提取SSVEP特征并准确识别刺激频率非常重要^[15],为此,研究者提出了多种SSVEP信号分类方法,如典型相关分析(Common component analysis, CCA)、任务相关成分分析(Task-related component analysis, TRCA)、功率谱密度分析(Power spectral density analysis, PSDA)。其中,CCA引入了相关系数,利用正余弦波作为参考信号,由此来找到两组变量间的线性对应关系^[16],具有较高的效率和信息传输速率^[17],并在在线脑电信号识别中表现出色^[18]。然而,CCA方法在特征信息提取方面存在不足,未能充分考虑脑电(Electroencephalogram, EEG)信号在时域中的传播特性,其性能易受到自发脑电活动的干扰的影响。为此Nakanishi等^[19]提出了TRCA方法来提高SSVEP信号的信噪比,抑制自发脑电活动。TRCA方法利用受试者在试验中产生的脑电信号,通过空间滤波器提取出与任务高度相关的成分,充分利用了信号的相位信息,削弱了脑电自发活动的干扰,从而提高SSVEP信号的识别性能^[19-20]。但TRCA存在对于训练数据过度依赖、计算复杂度高以及实时处理能力较弱等缺点。这些典型的传统方法只能提取线性信息,而不能充分利用动态非平稳脑电信号的非线性信息。

随着深度学习的不断发展,卷积神经网络(Convolutional neural network, CNN)逐渐被广泛应用于脑电信号研究领域^[21]。卷积神经网络具有强大的数据特征表达和学习能力,可以自动提取SSVEP时域或频域信息的内在特征并进行分类^[22-23]。在SSVEP-BCI系统信号分类识别中,CNN展现出自学能力强、高包容性和高适应性等优势。相比传统的学习方法,经过训练的CNN能够从脑电数据中提取更多特征,在相同的数据长度下表现出更优的性能^[24]。近年来,卷积神经网络在SSVEP领域应用发展快速。2008年Cecotti等^[25]提出了嵌入傅里叶变换的卷积神经网络,通过在两个隐藏层之间引入傅里叶变换,将时域分析转化为频域分析,从而提升了SSVEP信号的识别性能。2018年,Waytowich等^[26]提出了一种紧凑型卷积神经网络(Compact-CNN)结构,该网络能够识别任意时间和任意刺激下的SSVEP信号,其识别准确率明显优于CCA方法及拓展CCA组方法。2021年Ding等^[27]提出了一种结合滤波器组和时域卷积神经网络的FB-tCNN方法,使网络架构能够在短时间窗口内更有效地提取与任务相关的特征。2022年Pan等^[28]设计出一种卷积神经网络-长短期记忆(CNN-LSTM)网络,将长短期记忆模块与频谱归一化和标签平滑技术相结合,用于识别SSVEP频率。同年,Peraiyantika等^[29]提出了多重2D-CNN方法来处理脑卒中患者的脑电信号,解决了多通道数据处理的难题。Chaudhary等^[30]提出了一种基于2D-CNN标尺图的方法来对心理任务进行分类,将一维脑电信号数据转换为二维图像,从而充分利用了时间和频率系数之间的信息。2023年Chen等^[31]提出了一种基于注意力机制的多模式tCNN结构,将其用于稳态视觉诱发电位分类并实现了人脑对仿生手的控制,在医疗领域具有重要贡献。但是上述研究只关注了时域或者频域的特征,对通道信息一般采用卷积进行特征提取,提取的信息不够充分,从而会对后续的信号分类产生一定影响。

针对以上问题,本文结合SSVEP信号的时域和频域特征,提出了一种基于注意力机制的双通道多特征卷积神经网络(Attention enhancement-dual channel multi-feature CNN, AE-dCNN)方法。该方法首先利用注意力机制为不同脑电通道分配权重,从而提升整体分类效果。随后,通过两个独立的卷积通道分别处理SSVEP信号的时域和频域信息,最终将两种特征进行融合,实现对SSVEP信号的端到端分类。综合使用两域(时域和频域)信息可以有效地通过多角度来分析SSVEP信号的特征,有效解决了传统单一信息域分析所涵盖信息不足的问题。在数据集和公共数据集的短时间窗口内测试中,AE-dCNN方法展示了优异的性能。此外,本文还将KAN(Kolmogorov-Arnold network)结构与多层感

知机(Multilayer perceptron, MLP)结构进行对比,探讨了KAN结构在脑电信号处理领域的应用潜力。

1 相关算法概述

1.1 TRCA 算法

任务相关组件分析是一种空间滤波加权的方法,它可以从独立的受试者训练数据集中提取任务相关成分,通过最大化训练数据集中所有脑电信号的相似性来计算权重。假设多通道脑电信号为 $x \in \mathbf{R}^{N_f \times N_c \times N_s \times N_t}$, 其中 N_f 表示指定刺激频率的数量, N_c 表示通道数, N_s 表示采样点数, N_t 表示重复次数。待识别的 SSVEP 信号可线性表示为

$$x_c(t) = a_{1,j}s(t) + a_{2,j}n(t) \quad j = 1, 2, \dots, N_c \quad (1)$$

式中: $s(t)$ 表示任务相关分量, $n(t)$ 表示任务无关分量, $a_{1,j}$ 和 $a_{2,j}$ 表示任务相关成分的混合系数。对多通道的 SSVEP 信号进行加权求和, 得到任务相关成分信号 $y(t)$ 为

$$y(t) = \sum_{j=1}^{N_c} \omega_j x_j(t) = \sum_{j=1}^{N_c} \omega_j (a_{1,j}s(t) + a_{2,j}n(t)) \quad (2)$$

TRCA 方法是求解权重系数 ω_c , 从而估算各通道信号线性加权结果, 得到任务相关成分 $y(t)$, $s(t)$ 可以通过在空间滤波后最大化试验间协方差来估计, 假设 h_1 和 h_2 是相同任务下的不同试验, 则所有试验组合的协方差可表示为

$$\omega^T S \omega = \sum_{\substack{h_1, h_2 = 1 \\ h_1 \neq h_2}}^{N_t} \sum_{j_1, j_2 = 1}^{N_c} \omega_{j_1} \omega_{j_2} \text{Cov}(x_{j_1}^{h_1}(t), x_{j_2}^{h_2}(t)) \quad (3)$$

为得到有效解, 对 $x(t)$ 进行归一化约束, 即

$$\omega^T Q \omega = \sum_{j_1, j_2 = 1}^{N_c} \omega_{j_1} \omega_{j_2} \text{Cov}(x_{j_1}^{h_1}(t), x_{j_2}^{h_2}(t)) = 1 \quad (4)$$

式中 $Q = \text{Cov}(x_{j_1}^{h_1}(t), x_{j_2}^{h_2}(t))$, 空间滤波器可以由 Rayleigh-Ritz 推导出, 即

$$\hat{\omega} = \arg\max \frac{\omega^T S \omega}{\omega^T Q \omega} \quad (5)$$

由矩阵 $Q^{-1}S$ 求解特征向量得到的空间滤波器 $\hat{\omega}_n$, 对测试信号和训练信号进行空间滤波, 最后, 计算两者的皮尔森相关系数, 相关系数最大值对应的刺激频率即为目标刺激频率。

1.2 KAN 模型

MLP 是当今深度学习模型的基础构建块, 是机器学习中用于逼近非线性函数的默认方法。近期 KAN 的出现为传统的 MLP 提供了一种有前途的替代方案, 其结构的设计思路源于 Kolmogorov-Arnold 定理, 权重上采用了可学习的激活函数, 这些激活函数由 B 样条函数通过可训练的加权组合生成。而 MLP 节点上的激活函数是固定的且结构较为简单, 理论上 KAN 对函数的逼近能力比 MLP 结构更强^[32]。在数据拟合和偏微分方程求解等任务中, KAN 网络展现出了比传统 MLP 更高的准确性。同时, KAN 模型的内部结构可以通过可视化技术直观展示, 从而使模型的决策过程更加透明和易于解释。在参数效率方面, KAN 在参数数量较少的情况下能够达到与大型 MLP 相当的性能, 提高了模型的效率。然而, 在训练速度和算法效率方面, KAN 网络在需要快速迭代的场景中存在一定的限制和瓶颈。

为了探究 MLP 和 KAN 网络结构在脑电信号处理领域应用的差别, 本文分别使用 MLP 和 KAN 结构进行实验。首先, 采用快速傅里叶变换(Fast Fourier transform, FFT)对脑电信号进行特征提取, 随后利用两个模型进行分类识别。分类准确率如图 1 所示。在 0.2 s 的时间窗下, MLP 模型的准确率高于

KAN模型,而在其余时间窗内,KAN模型的准确率均优于MLP模型。这表明,KAN模型不仅在拟合函数方面具有优势,在类似于脑电信号的非线性信号的频域特征分类中,相较于MLP模型也展现出一定的优势。

1.3 基于CNN的相关模型

CNN主要由两部分组成:一是特征提取结构,包括卷积层和池化层;二是分类器结构,由全连接层和输出层构成。通过增加卷积层和池化层,可以加深网络的层次。在脑电信号处理领域,许多经典的CNN网络结构,如tCNN^[27]、Shallow-CNN^[33]和Compact-CNN^[26]等,已经成功应用于稳态视觉诱发电位的分类识别。本文将这些传统的CNN网络作为对比算法,应用于相同数据集的分类任务。

1.3.1 tCNN

在tCNN结构中,输入数据的维度为通道数 $\times$ 数据长度,因此输入数据同时包含脑电数据的通道和时间信息。本文中,通道数为9,1 s时间窗下的数据长度为250帧。第1个卷积核的大小为 9×1 ,用于对9个电极通道进行卷积特征提取,输出为 1×250 的矩阵;第2个卷积核的大小为 1×250 ,用于提取时间信息特征;第3和第4个卷积核进一步提取时间信息。最后,通过flatten层将特征展平,并通过全连接层进行分类。

1.3.2 Shallow-CNN

在Shallow-CNN网络中,第1层卷积核的大小为 1×250 ,用于提取脑电信号的时间信息;第2层卷积核的大小为 9×1 ,用于提取通道信息。经过两层卷积后,数据通过批归一化层、激活函数层和全局池化层处理。随后,使用flatten层将特征展平,并通过全连接层进行分类。由于Shallow-CNN减少了池化层的数量,其网络学习参数减少,从而使得网络的优化和训练过程更加高效。同时,Shallow-CNN能够有效学习实验中的时间信息变化。

1.3.3 EEGnet

EEGnet是一个经典的脑电数据分析网络,适用于多种脑电信号分类任务,并且在不同数据集的分类任务中表现良好^[34]。对于SSVEP信号,EEGnet网络由深度卷积层、可分离卷积、批归一化层、池化层和全连接层等组成。其中,深度卷积层使得网络更加紧凑和高效。

1.3.4 Compact-CNN

Compact-CNN是一种紧凑型CNN网络结构,能够在数据集较小的情况下仍保持较高的准确率。该网络基于EEGnet框架,采用深度卷积和可分离卷积进行卷积操作。其前两层在卷积后使用了批归一化层、平均池化层和dropout层;第3层使用flatten层将数据展平,最终通过全连接层和Softmax激活函数进行分类。Compact-CNN能够有效提取信号的相位信息和幅度信息,从而提高模型的分类准确率。

2 AE-dCNN

2.1 网络结构

上述网络均基于SSVEP信号的时间信息和通道信息进行信号分类。然而,由于SSVEP信号是由大脑产生的固定频率信号,其频域特征同样至关重要。为此,本文设计了AE-dCNN新型结构。该




图1 MLP与KAN算法比较

Fig.1 Comparison between MLP and KAN algorithms

网络在利用信号时域信息的基础上,引入了频域信息,从两个方面对 SSVEP 信号的特征进行分析与优化。

网络模型如图 2 所示,本文所采用的数据集均使用四分类来验证模型的准确率。首先,脑电信号通过输入层进入网络,输入信号为一个大小为电极通道数 $\times 1 \times$ 时间采样点数的三维矩阵。接下来,通道注意力机制对不同通道的权重进行分配。输入的 9 个通道分别代表 SSVEP 信号的 9 个不同电极通道。注意力机制会为质量较好的通道分配较高的权重,从而有效提升模型的性能^[35]。输入矩阵在通道注意力模块前后大小不变,经过注意力机制后,信号被传递到两个并行的通道进行进一步处理。




图2 AE-dCNN结构图

Fig.2 AE-dCNN structure diagram

第1个并行通道主要对时域信息进行处理。第1个卷积层的卷积核大小根据输入信号长度动态调整,随后信号经过批归一化层。第2个卷积层处理信号的通道信息,卷积核大小为 9×1 ,并在其后设置了批归一化层、激活函数层和平均池化层。第3个卷积层对上一层输出的信号进行时域特征提取,卷积核大小为 1×15 。经过卷积操作后,信号通过批归一化层和平均池化层处理,最后将数据展平并输入到全连接层,以生成第1个通道的输出。

在第2个并行通道中,输入信号与第1个通道相同。首先,信号经过大小为 9×1 的卷积核进行通道信息的特征提取,以优化后续的频域处理结果。然后经过 flatten 层,将信号变为一维数据,一维数据经过傅里叶变换后将时域信号转换成频域信息。根据变换的对称性,本文只采用单边频率特征。与传统频域信号相比,经过卷积提取和傅里叶变换后的信号有更加长的时间观测窗口,可以提高信号的时间分辨率。最终将经过变换后的信号经过4层KAN网络后得到第2个通道的输出。

将两个通道的数据拼接后经过全连接层,通过 Softmax 激活函数进行输出得到最后的分类结果。本文模型充分提取多种不同时间窗尺度样本的频率特征信息,并且与时域信息相结合,提高了 SSVEP 信号的识别准确率。

2.2 性能评估

在脑机接口系统中,通常采用两个指标来衡量模型性能:准确率和信息传输率(Information transfer rate, ITR)。准确率定义为正确样本数与总样本数的比值,反映了模型的分类性能。由于脑电数据集相较于其他深度学习数据集较小,因此本文采用交叉验证方法进行评估。

针对公共数据集,在跨被试实验中,总共有 35 个被试,所以选择 5 折交叉验证,每折有 7 个被试的数据集;在受试者独立实验中,由于公共数据集有 6 个 block,所以选择 6 折交叉验证进行分析。对于自建数据集,在跨被试实验中,共有 8 个被试,选择 4 折交叉验证,其中每折包含数据 2 个被试的数据;在受试者独立实验中,自建数据集有 5 个 block,因此进行五折交叉验证。交叉验证可以使训练得到的模型结果更加可靠,其准确率也能更准确地表示模型的性能。第 2 个指标为信息传输率,其结果受时间窗和准确率的共同影响,其表达式为^[36]

$$\text{ITR} = 60 \times \frac{\log_2 k + P \log_2 P + (1 - P) \log_2 \frac{1 - P}{N - 1}}{d} \quad (6)$$

式中: k 为分类目标的数量, p 为准确率, d 为时间窗的长度。

3 数据采集与处理

3.1 数据集

3.1.1 自建数据集

共 8 位受试者参与本次实验,受试者视力或矫正视力正常,身体健康,其中男女被试者各 4 位,年龄处于 22 至 25 岁之间。实验在光线均匀的房间中进行,受试者注视刺激位置始终与显示器保持 70 cm 距离。

本文设计了一种黑白块交替闪烁的刺激范式,如图 3(a)所示,其中包括准备界面和刺激界面,该范式呈现 4 种不同频率的刺激,分别为 7、7.5、8 和 9 Hz。刺激界面采用 E-Prime 2.0 软件制作,实验采用的 LED 显示器分辨率为 2 240 像素×1 400 像素。受试者按照屏幕所示的准备阶段的提示,依次注视显示器上出现的 4 个闪烁刺激方块,一组实验包括 4 次闪烁刺激,每次持续 5 s,准备时间 3 s,每次注视结束后显示屏白屏休息 4 s,共进行 5 组实验,因此收集的脑电数据共有 160 次试验(8 被试×4 类×5 组),实验场景如图 3(b)所示,刺激时序如图 4 所示^[37]。

实验采用 64 导联的 Neuroscan 脑电采集设备使用 Curry7 软件以 500 Hz 的采样率采集原始 EEG 数据。电极按照国际标准 10/20 系统法选择位于顶叶和枕叶区域的 9 个位置,分别为 Pz、PO5、PO3、Poz、PO4、PO6、O1、Oz 和 O2,同时采集了 M1、M2 乳突电极和 HEOL、HEOR 电极处的肌电及眼电信号。接地电极放置在前额的 Fpz 和 Fz 之间,参考电极放在头部顶点处,所有电极的阻抗均保持在 10 kΩ 以下^[37]。


3.1.2 公共数据集

本文采用清华大学脑机接口研究组公开的数据集^[38],该数据集共收集了 35 名健康受试者数据,包括从 8 Hz 到 15.8 Hz,间隔为 0.2 Hz 的 40 种频率。实验总共由 6 轮试次组成,每轮试次包含 40 组实验。



(a) 实验时序图

(a) Experimental timing diagram



(b) 实验场景图

(b) Experimental scene diagram

图 3 实验时序图和场景图

Fig.3 Experimental timing diagram and scene diagram




图 4 刺激序列图^[37]

Fig.4 Stimulus sequence diagram^[37]

在实验开始时,屏幕上会出现提示,要求受试者迅速将目光转移到目标上。随后,所有刺激将在屏幕上闪烁 5 s。在每组实验之间,屏幕会空白 0.5 s,以便受试者获得短暂的休息。整个实验过程采用 1 000 Hz 的频率来记录来自 64 个电极通道的数据。为了和自建数据集进行对比,本文在公共数据集中同样进行四分类实验。

为了消除工频噪声的干扰,实验过程中使用了 50 Hz 的滤波器,之后将连续的 EEG 数据分割成 6 s,其中包括刺激前的 0.5 s 和刺激后的 5.5 s,这样能够更精确地分析受试者在刺激前后的大脑活动变化。

3.2 实验预处理

本文使用 MATLAB 的 EEGLAB 工具箱对自建数据集进行预处理,利用 4.8~90 Hz 带通滤波器进行滤波,通过 50 Hz 陷波器去除工频干扰,然后使用 ICA 去除原始脑电信号中的眼电和肌电信号的伪迹干扰。由于视觉延迟效应的存在,在实验中截取刺激闪烁开始后 0.2 s 后的数据片段。

在公共数据集中,为了提高信号的信噪比,本文选取了与自建数据集相同位于顶叶和枕叶区域的电极通道,包括 PZ、POZ、PO3、PO4、PO5、PO6、O1、O2 和 OZ。电极通道的数据下采样到 250 Hz,从而减少计算量,同时使得网络在短时间窗下能更高效地学习相关内容。

4 实验结果与分析

本节主要采用传统算法 TRCA 和深度学习算法:tCNN、Compact-CNN 等算法作为对比算法,采用公共和自建两种数据集来作为算法的基础数据集。为了增加数据集采用滑动时间窗的方式对数据进行处理。通过对不同算法的比较显示本文网络具有较高的准确性和更强的泛化能力。

4.1 训练流程

实验在 Python 环境中进行,神经网络的训练基于 Pytorch 框架,并在 i7-12700H 处理器和 RTX 3050 显卡的硬件设备上完成。网络选择 Adam 优化器,并采用交叉熵作为损失函数。学习率设置为 0.001,批量大小为 64,迭代次数为 500 次。数据划分使用 2.2 节所述的交叉验证方法。由于 EEG 信号具有非线性和不平稳性,不同被试对视觉刺激的反应时间存在差异,因此本文对不同时间窗长度的信号进行 50% 重叠的数据分段处理,这也起到了扩充数据集的作用。在数据处理中,采用 0.2~1.0 s 的时间窗,并以 0.1 s 为步长进行划分,以观察模型在不同时间窗长度下的效果,从而找到最优的信息传输率。实验数据集和相关程序见网址 https://github.com/Liu-ji-wei/AE_dCNN/tree/code。

4.2 跨被试实验

跨被试实验是指使用多个受试者训练得到的模型用在未参与训练的被试数据集上来检测模型性能的实验。本文采用两个数据集来进行跨被试实验,结果如图 5 所示。在公共数据集中不同时间窗下不同算法的准确率和信息传输率分别如图 5(a)和(c)所示。结果表明,随着时间窗长度的增加,模型的准确率也逐渐增加。这是因为较长的时间窗包含的信息更加充分,能够提供更多的数据,有助于模型更好地捕捉数据的特征,同时减少噪声对信号质量的影响。

从图 5 可以看出,EEGnet 模型的性能明显低于其他模型,而 AE-dCNN 模型的准确率最高,紧随其后的是 Compact-CNN 和 tCNN。在 1 s 时间窗下,AE-dCNN 模型的最高准确率达到 94.38%。在自建数据集中,不同时间窗下不同算法的准确率和信息传输率分别如图 5(b)和(d)所示。值得注意的是,tCNN、EEGnet 和 Shallow-CNN 模型的准确率并未随着时间窗的增加而显著提升,而 AE-dCNN 和




图5 不同数据长度的准确性和信息传输率

Fig.5 Accuracy and ITR of data with different lengths

Compact-CNN的总体变化趋势与公共数据集相似,AE-dCNN在1 s时间窗下的准确率达到60.08%,与其他模型的准确率差距进一步拉大。

自建数据集的平均准确率比公共数据集低约30%,主要原因可能是被试之间的认知和行为特征存在差异,同时实验环境条件如温度、噪音等因素可能对实验结果产生影响。Shallow-CNN和EEGnet模型的准确率在25%左右,鉴于这是一个四分类问题,25%的准确率表明这些模型未能有效区分类别。在与公共数据集相同的参数条件下,传统卷积网络未能展现出较强的泛化能力,在不同数据集上仍需进行针对性的训练。AE-dCNN在自建数据集中的优异表现进一步证明了其泛化能力,能够在不同数据集中均展现出出色的性能。

为了进一步探讨所提出的方法相较于其他深度学习方法的优点,本文采用t分布随机邻域嵌入(t-distributed stochastic neighbor embedding, t-SNE)对每个模型的最终全连接层中学习到的特征进行可视化分析^[39],并选择4种深度学习方法进行比较,即EEGNet、Compact-CNN、tCNN和AE-dCNN。由于自建数据集的数据量较少,分类结果不够显著,因此本节仅展示在公共数据集上的实验结果。图6所示为公共数据集上使用4个模型的可视化结果,其中不同颜色的点表示不同的刺激频率。可以看出,AE-dCNN提取的特征表现出更小的类内距离和更大的类间距离。与EEGNet、tCNN和Compact-CNN相比,AE-dCNN在类别间的区分度上表现更佳,从而能够实现更好的分类效果。




图6 不同算法 t-SNE 图

Fig.6 t-SNE graphs of different algorithms

4.3 受试者独立实验

受试者独立实验是指将每个被试者的数据单独划分,确保不同被试者的数据相互独立。在这种实验中,相同的模型在不同被试者中的表现可能有所不同。本文在公共数据集和自建数据集上进行了受试者独立实验,并对每个数据集中的被试者的数据进行了分析,特别是针对1 s时间窗的数据进行了深入研究。

在公共数据集中,所有被试者的平均准确率和信息传输率的实验结果如表1所示。结果显示,tCNN 模型表现较差,而 EEGNet 和 Shallow-CNN 表现较好,但仍不如 Compact-CNN 和 AE-dCNN。AE-dCNN 模型表现最佳,平均准确率超过 92%,其次是 Compact-CNN,平均准确率为 87.74%。总体来看,AE-dCNN 和 Compact-CNN 在受试者独立实验中的表现优于其他模型,其中 AE-dCNN 在准确率上比 Compact-CNN 高出约 5%,显示出明显的优势。

在自建数据集中,表2展示了全部被试平均准确率和 ITR,通过比较可以发现,整体数据的准确率比公共数据集要低,不同模型准确率排序与公共数据集相同,但是数据表明,AE-dCNN 模型相较于其他模型而言准确率要更高,平均准确率达到 66.99%,比准确率排名第 2 的 Compact-CNN 高出 17% 左右。总结来说,AE-dCNN 网络在受试者独立实验的不同数据集中准确率均优于其他模型,在模型的泛化能力和数据适应能力上要优于 Compact-CNN 等模型。

表1 公共数据集下不同算法的准确率和 ITR
Table 1 Accuracy and ITR of different algorithms on public dataset

方法	准确率/%	ITR/(bit·min ⁻¹)
TRCA	27.47	0.14
EEGnet	64.54	29.99
Shallow-CNN	61.20	25.29
Compact-CNN	87.74	76.13
tCNN	48.17	10.77
AE-dCNN(本文)	92.36	89.37

表2 自建数据集下不同算法的准确率和 ITR
Table 2 Accuracy and ITR of different algorithms on self-built dataset

方法	准确率/%	ITR/(bit·min ⁻¹)
TRCA	27.32	0.12
EEGnet	36.33	2.73
Shallow-CNN	32.22	1.14
Compact-CNN	50.00	12.45
tCNN	35.34	2.29
AE-dCNN(本文)	66.99	33.71

4.4 结果分析

为了探讨通道注意力机制压缩与激励(Squeeze and excitation, SE)模块在分类中的作用,本文进行了消融研究。实验使用清华大学公共数据集,分别在不同时间窗下去除SE模块,观察SE模块对分类准确率的影响,实验结果如图7所示。在公共数据集上,去除SE模块后,模型的准确率在不同时间窗下均有所下降。其中,在0.6 s的时间窗下,准确率下降幅度最大,达到了2.96%;而在0.2 s的时间窗下,准确率下降幅度最小,仅为0.46%。这些结果表明,SE模块在本模型中起到了显著作用,能够有效帮助网络学习不同通道的重要性,充分挖掘通道之间的有用信息。此外,这也表明SE模块具有较强的通用性,能够适用于不同的数据集,提升模型的整体表现。

为了探究MLP和KAN在整体模型中的影响,本文进行了两组实验进行分析,采用清华大学数据集作为待分类数据集,使用跨被试实验方式进行实验,将整体模型中的4层KAN模型替换成同样结构的MLP模型进行对比,如图8所示,KAN模型整体准确率相较于MLP模型有提高,在1 s时间窗下KAN准确率达到94.38%,比MLP模型提升了3.04%。同时也可以发现,KAN模型在0.2 s时间窗下的准确率较低,与前文中准确率变化趋势相同。

4.5 实验结论

在公共数据集的跨被试实验中,AE-dCNN、tCNN和Compact-CNN在1 s时间窗下均表现出较高的准确率,约为90%左右。然而,在自建数据集中,tCNN的表现与Shallow-CNN和EEGnet网络模型相似,效果较差。虽然Compact-CNN的准确率仍然位居第2,但与AE-dCNN的差距较大。在受试者独立实验中,AE-dCNN依旧保持了较高的准确率,尤其是在自建数据集中表现尤为明显。相比之下,尽管tCNN在公共数据集的跨被试实验中表现出色,但在受试者独立实验中表现不佳。




图7 消融实验结果

Fig.7 Ablation experimental results




图8 MLP与KAN在模型中的比较

Fig.8 Comparison of MLP and KAN in the model

综合两种数据集和两类实验的结果,AE-dCNN模型在各方面的表现均最佳,展现了其出色的泛化能力。虽然 Compact-CNN在公共数据集中表现优异,但在自建数据集中表现一般,表明其泛化能力较弱,仅在特定数据集中具有较明显的优势。tCNN虽然在跨被试实验中效果良好,但在受试者独立实验中,与AE-dCNN相比,表现并不理想。相比之下,EEGnet和Shallow-CNN虽然没有在实验中表现出特别突出的优势,但在准确率上相较于传统算法仍然占据一定的优势。

5 结束语

本文提出了一种基于注意力机制的双通道卷积神经网络(AE-dCNN),该网络融合了SSVEP信号的时间、通道和频率信息。采用两个数据集和两种不同的数据划分方式,并在不同时间窗下对不同模型进行了比较。实验结果表明,AE-dCNN模型在各种数据集上表现出优于其他深度学习模型的准确率和泛化能力。具体而言,在受试者独立实验中,模型的平均准确率明显高于跨被试实验。这是因为在跨被试实验中,模型难以学习到个体间的差异,同时不同个体之间的学习速度也有所不同。此外,实验还发现,随着时间窗长度的增加,准确率逐渐提高。这是由于较长的时间窗包含了更多的信号信息,同时时间窗长度也会影响ITR。本文还探讨了KAN结构在脑电信号处理中的应用。实验结果表明,KAN结构在多数情况下优于MLP结构,为KAN结构在脑电领域的进一步应用提供了新的可能性。

后续研究主要围绕被试者之间差异和短时间窗下准确率这两个问题进行工作,同时融入新的信号特征如相位特征等。在实验中发现,低频的刺激信号会使人体产生一定的不适感,中高频的刺激信号可以有效地减少人体的不适但得到的SSVEP信号的信噪比会降低,未来工作可尝试针对高频刺激下信号特征不明显、准确率不高的问题进行解决,从而增加脑机接口系统的使用体验。

参考文献:

- [1] WOLPAW J R, BIRBAUMER N, HEETDERKS W J, et al. Brain-computer interface technology: A review of the first international meeting[J]. IEEE Transactions on Rehabilitation Engineering, 2000, 8(2): 164-173.
- [2] MATTIA D, ASTOLFI L, TOPPI J, et al. Interfacing brain and computer in neurorehabilitation[C]//Proceedings of 2016 4th International Winter Conference on Brain-Computer Interface (BCI). [S.l.]: IEEE, 2016: 1-2.
- [3] DORNHEGE G, MILLÁN J R, HINTERBERGER T, et al. Towards brain-computer interfacing[M]. Cambridge, USA: MIT Press, 2007: 65-84.
- [4] WAN X, ZHANG K, RAMKUMAR S, et al. A review on electroencephalogram based brain computer interface for elderly disabled[J]. IEEE Access, 2019, 7: 36380-36387.
- [5] WOLPAW J R, BIRBAUMER N, MCFARLAND D J, et al. Brain-computer interfaces for communication and control[J]. Clinical Neurophysiology, 2002, 113(6): 767-791.
- [6] PATIL P G, CARMENA J M, NICOLELIS M A L, et al. Ensemble recordings of human subcortical neurons as a source of motor control signals for a brain-machine interface[J]. Neurosurgery, 2004, 55(1): 27-38.
- [7] MÜLLER M M, TEDER W, HILLYARD S A. Magnetoencephalographic recording of steady state visual evoked cortical activity[J]. Brain Topography, 1997, 9(3): 163-168.
- [8] MIDDENDORF M, MCMILLAN G, CALHOUN G, et al. Brain-computer interfaces based on the steady-state visual-evoked response[J]. IEEE Transactions on Rehabilitation Engineering, 2000, 8(2): 211-214.
- [9] TODD N P, LEE C S. The sensory-motor theory of rhythm and beat induction 20 years on: A new synthesis and future perspectives[J]. Frontiers in Human Neuroscience, 2015, 9: 105736.
- [10] AGHILI S N, KILANI S, KHUSHABA R N, et al. A spatial-temporal linear feature learning algorithm for P300-based brain-computer interfaces[J]. Heliyon, 2023, 9(4): e15380.

- [11] HOSSAIN M Y, DOULAH A B M S U. Detection of motor imagery (MI) event in electroencephalogram (EEG) signals using artificial intelligence technique[C]//Proceedings of 2020 IEEE East-West Design & Test Symposium (EWDTS). [S.l.]: IEEE, 2020: 1-6.
- [12] HINTERBERGER T, SCHMIDT S, NEUMANN N, et al. Brain-computer communication and slow cortical potentials[J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51(6): 1011-1018.
- [13] 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.
- [14] ADRIAN E D, MATTHEWS B H C. The Berger rhythm: Potential changes from the occipital lobes in man[J]. *Brain*, 1934, 57(4): 355-385.
- [15] WU Z H, YAO D Z. A study on SSVEP-based BCI[J]. *Journal of Electronic Science and Technology*, 2009, 7(1): 7-11.
- [16] 张莉,何传红,何为,等.基于典型相关分析与低通滤波的肌电伪迹去除[J].*数据采集与处理*, 2010, 25(2): 255-258.
ZHANG Li, HE Chuanhong, HE Wei, et al. Method for removing EMG artifacts based on CCA and low-pass filtering[J]. *Journal of Data Acquisition and Processing*, 2010, 25(2): 255-258.
- [17] 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.
- [18] YONG Y, ZANG B, YANG J, et al. The study on online SSVEP based BCI system using CCA method[C]//Proceedings of 2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC). [S.l.]: IEEE, 2021: 1942-1946.
- [19] 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.
- [20] ZHANG Y, GUO D, LI F, et al. Correlated component analysis for enhancing the performance of SSVEP-based brain-computer interface[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2018, 26(5): 948-956.
- [21] AKROUT A, ECHTIOUI A, KHEMAKHEM R, et al. Artificial and convolutional neural network of EEG-based motor imagery classification: A comparative study[C]//Proceedings of 2020 20th International Conference on Sciences and Techniques of Automatic Control and Computer Engineering (STA). [S.l.]: IEEE, 2020: 46-50.
- [22] KWAK N S, MÜLLER K R, LEE S W. A convolutional neural network for steady state visual evoked potential classification under ambulatory environment[J]. *PloS ONE*, 2017, 12(2): e0172578.
- [23] AZNAN N K N, BONNER S, CONNOLLY J, et al. On the classification of SSVEP-based dry-EEG signals via convolutional neural networks[C]//Proceedings of 2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC). [S.l.]: IEEE, 2018: 3726-3731.
- [24] XING J, QIU S, WU C, et al. A comparing network for the classification of steady-state visual evoked potential responses based on convolutional neural network[C]//Proceedings of 2019 IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA). [S.l.]: IEEE, 2019: 1-6.
- [25] CECOTTI H, GRAESER A. Convolutional neural network with embedded Fourier transform for EEG classification[C]//Proceedings of 2008 19th International Conference on Pattern Recognition. [S.l.]: IEEE, 2008: 1-4.
- [26] WAYTOWICH N, ET AL. Compact convolutional neural networks for classification of asynchronous steady-state visual evoked potentials[J]. *Journal of Neural Engineering*, 2018, 15(6): 066031.
- [27] DING W, SHAN J, FANG B, et al. Filter bank convolutional neural network for short time-window steady-state visual evoked potential classification[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 2615-2624.
- [28] PAN Y, CHEN J, ZHANG Y, et al. An efficient CNN-LSTM network with spectral normalization and label smoothing technologies for SSVEP frequency recognition[J]. *Journal of Neural Engineering*, 2022, 19(5): 056014.
- [29] PERAIYANTIKA A, DJAMAL E C, KASYIDI F. Identification of post-stroke patients from significant variable electroencephalogram signals using multiple 2D-convolutional neural networks[C]//Proceedings of 2022 International Conference on Information Technology Research and Innovation (ICITRI). [S.l.]: IEEE, 2022: 112-116.
- [30] CHAUDHARY A, TYAGI A. A 2D-CNN-Scalogram based approach to classify the mental TASKS using EEG signals[C]//Proceedings of 2022 6th International Conference on Intelligent Computing and Control Systems (ICICCS). [S.l.]: IEEE, 2022:

106-112.

[31] CHEN J, SUN F, ZHANG W, et al. Attention-based multimodal tCNN for classification of steady-state visual evoked potentials and its application to gripper control[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(12): 18263-18271.

[32] LIU Z, WANG Y, VAIDYA S, et al. KAN: Kolmogorov-Arnold networks[J]. arXiv preprint arXiv: 2404.19756, 2024.

[33] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. Human Brain Mapping, 2017, 38(11): 5391-5420.

[34] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces[J]. Journal of Neural Engineering, 2018, 15(5): 056013.

[35] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Cham: Springer International Publishing, 2018: 3-19.

[36] 韩锦,董博文,刘邈,等. 基于 P300-SSVEP 的双人协同脑-控机械臂汉字书写系统[J]. 数据采集与处理, 2022, 37(6): 1401-1411.

HAN Jin, DONG Bowen, LIU Miao, et al. Two-person collaborative brain-controlled robotic arm system for writing Chinese character using P300 and SSVEP features[J]. Journal of Data Acquisition and Processing, 2022, 37(6): 1401-1411.

[37] 马洪远,张学军. 基于滤波器组典型相关分析的 SSVEP 信号分类方法[J]. 智能计算机与应用, 2024, 14(7): 29-36.

MA Hongyuan, ZHANG Xuejun. Classification method of SSVEP signals based on filter bank canonical correlation analysis[J]. Intelligent Computer and Applications, 2024, 14(7): 29-36.

[38] LIU B, HUANG X, WANG Y, et al. BETA: A large benchmark database toward SSVEP-BCI application[J]. Frontiers in Neuroscience, 2020, 14: 544547.

[39] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of Machine Learning Research, 2008, 9(11): 2579-2605.

作者简介:



张学军(1969-),通信作者,男,博士,教授,硕士生导师,研究方向:智能信息处理、深度学习、脑电信号处理与研究、脑机接口, E-mail: xjzhang@njupt.edu.cn。



刘济玮(2000-),男,硕士研究生,研究方向:脑机接口、深度学习。



李夏芸(2000-),女,硕士研究生,研究方向:脑机接口、神经电信号处理与分析。

(编辑:王静)

Dual-Channel Multi-feature Convolutional EEG Signal Classification Based on Attention Mechanism

ZHANG Xuejun^{1,2*}, LIU Jiwei¹, LI Xiayun¹

(1. College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China; 2. Nation-Local Joint Project Engineering Lab of RF Integration & Micropackage, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Brain-computer interfaces (BCIs) based on steady-state visual evoked potential (SSVEP) are rapidly advancing in human-computer interaction systems. However, the classification of SSVEP signals in short time windows still faces challenges such as low accuracy and insufficient feature extraction. In this paper, we propose an attention enhancement-dual channel multi-feature convolutional neural network (AE-dCNN). The network applies a channel attention mechanism to weight the features of different channels, enhancing the representation of useful information. Then, two parallel channels are employed to extract time and frequency domain features from the signals, and the extracted features are fused for classification. Cross-subject and subject-independent experiments are conducted on both public and self-built datasets. The results demonstrate that the proposed AE-dCNN model achieves the highest accuracies of 94.38% in cross-subject experiments among five algorithms and of 92.36% in subject-independent experiments among six algorithms. Additionally, we explore the application of the Kolmogorov-Arnold network (KAN) structure in EEG signal processing. The results indicate that the KAN model outperforms the multilayer perceptron (MLP) model in terms of accuracy across most time windows.

Highlights:

1. Propose an attention-enhanced dual-channel multi-feature convolutional neural network (AE-dCNN) for SSVEP signal classification, combining channel attention with parallel temporal- and frequency-domain feature extraction.
2. Assess the proposed AE-dCNN on public and self-built datasets through cross-subject and subject-independent experiments, showing its strong classification performance and generalization across different time windows and datasets.
3. Explore the application of Kolmogorov-Arnold network (KAN) in EEG signal processing and compare their classification performance with multilayer perceptrons (MLPs), revealing the potential of KAN for nonlinear frequency-domain feature learning.

Key words: steady-state visual evoked potential (SSVEP); brain-computer interface (BCI); convolutional neural network (CNN); Kolmogorov-Arnold network (KAN); attention mechanism

Foundation item: National Natural Science Foundation of China (No.61977039).

Received: 2024-09-08; **Revised:** 2024-12-20

***Corresponding author, E-mail:** xjzhang@njupt.edu.cn.