

DOI:10.19651/j.cnki.emt.2416722

基于全局注意力的 Gam-EEGNet 在 SSVEP 分类中的应用*

刘俊杰 谢俊 王虎 胡博
(新疆大学机械工程学院 乌鲁木齐 830017)

摘要: 稳态视觉诱发电位(SSVEP)作为脑机接口(BCI)系统中的重要信号类型,因其高稳定性和易操作性而广泛应用于BCI研究。在过去的研究中,已有许多方法在SSVEP信号分类中取得了显著进展,但依然面临着信噪比低、信号非平稳性和个体差异大的挑战。为进一步提升SSVEP分类的准确性和实用性,本文提出了一种结合全局注意力机制与紧凑脑电网络(EEGNet)的新型神经网络架构——Gam-EEGNet。EEGNet作为一种紧凑、高效且适应性强的基础模型,在SSVEP信号处理中具有重要作用。通过在EEGNet中引入全局注意力机制,Gam-EEGNet能够更精确地提取和表征SSVEP信号特征,从而有效降低个体差异和噪声的影响。实验采用了涵盖12种不同频率的SSVEP脑电数据,并将Gam-EEGNet与典型卷积神经网络(CCNN)、滤波器组-时间卷积神经网络(FB-tCNN)和滤波器组-时间卷积神经网络(SSVEPNet)等主流深度学习方法进行了分类性能对比。结果表明,Gam-EEGNet在不同时间窗口下的分类准确率和信息传输率(ITR)均优于其他方法,特别是在0.7 s的短时间窗口内,分类精度达到86.58%;在1 s时间窗口内,多名被试者的平均识别准确率超过95%,ITR超过189 bits/min。此外,Gam-EEGNet在训练过程中表现出更好的收敛性和稳定性,具有更快的收敛速度和更低的训练误差。这些结果表明,Gam-EEGNet在SSVEP信号分类中展现出显著的性能提升,尤其适用于实时BCI系统中的快速响应场景,具有广泛的应用潜力。

关键词: 深度学习;脑-机接口;稳态视觉诱发电位;全局注意力机制;Gam-EEGNet模型

中图分类号: TN911.73;TP183 **文献标识码:** A **国家标准学科分类代码:** 310.6130;510.99

The application of Gam-EEGNet with global attention mechanism in SSVEP classification

Liu Junjie Xie Jun Wang Hu Hu Bo

(School of Mechanical Engineering, Xinjiang University, Urumqi 830017, China)

Abstract: Steady-state visual evoked potential (SSVEP) is an essential signal type in brain-computer interface (BCI) systems, widely utilized in BCI research due to its high stability and ease of operation. While previous studies have achieved significant progress in SSVEP signal classification, challenges such as low signal-to-noise ratio, non-stationarity, and individual variability still persist. To further enhance the accuracy and practicality of SSVEP classification, this paper proposes a novel neural network architecture—Gam-EEGNet—that combines a global attention mechanism with EEGNet. EEGNet, known for its compact, efficient, and adaptive structure, plays a critical role in SSVEP signal processing. By incorporating a global attention mechanism into EEGNet, Gam-EEGNet can more accurately extract and represent SSVEP signal features, effectively reducing individual variability and noise interference. Experiments were conducted using SSVEP EEG data encompassing 12 different frequencies, and the performance of Gam-EEGNet was compared with that of other mainstream deep learning methods, including CCNN, FB-tCNN, and SSVEPNet. The results demonstrate that Gam-EEGNet outperforms these methods in terms of classification accuracy and information transfer rate (ITR) across different time windows, particularly achieving a classification accuracy of 86.58% within a short 0.7 s time window. In a 1 s time window, the average recognition accuracy across multiple subjects exceeded 95%, with an ITR above 189 bits/min. Moreover, Gam-EEGNet showed better convergence and stability during training, with faster convergence and lower training errors. These results indicate that Gam-EEGNet offers significant performance improvements in SSVEP signal classification, making it especially suitable for real-time BCI systems requiring rapid response, with broad application potential.

Keywords: deep learning; brain-computer interface; steady-state visual evoked potentials; global attention mechanism; Gam-EEGNet

0 引言

脑机接口(brain-computer interface, BCI)是一种新型

人-机交互系统,通过直接连接人脑与外部世界,实现信息传递与互动,无需依赖肢体、肌肉和神经^[1-4]。这项技术使用户能够通过大脑活动与外界交流,表达其意图,特别为严

收稿日期:2024-08-22

* 基金项目:国家自然科学基金(52365040)项目资助

重瘫痪患者提供了全新的沟通和控制途径,例如通过思维指令驱动轮椅^[5]。此外,BCI 技术已扩展至虚拟现实、军事^[6]和航空航天等多个领域^[7]。在 BCI 系统中,稳态视觉诱发电位(steady-state visual evoked potential, SSVEP)作为大脑对周期性视觉刺激的反应,因其稳定性和易操作性,成为一种广泛应用的 EEG 信号类型^[8-9]。然而,由于 SSVEP 信号强度较低,容易受到肌电信号、自发脑电等环境噪声的干扰,其识别过程面临诸多挑战。因此,开发有效的 SSVEP 信号分类与识别技术成为 BCI 系统应用中的关键问题。

当前 SSVEP 信号处理方法面临信号非平稳性、噪声干扰,以及用户间和用户内生理、心理状态变化导致的信号差异,这些问题极大地限制了信息的准确保存和有效利用^[10-11]。在多通道 EEG 信号分析中,维度间的互动对特征的抽象和识别至关重要,但传统方法往往忽视通道间的复杂相互作用和空间模式的全局协调性,导致重要信息的丢失和分类性能的下降。此外,现有方法在捕捉细微但关键的时变信号特征方面存在不足,这些细微特征常常是区分不同 SSVEP 任务的决定性因素。

为了解决上述问题并有效利用 SSVEP 信号的丰富信息,本文提出了 Gam-EEGNet 这一新型深度学习框架。该框架在 EEGNet 基础上,融入全局注意力机制(global attention mechanism, Gam)^[12],精准捕捉和放大电极通道间的相互关系及时空特征,对 SSVEP 信号处理尤为关键。通过 Gam 模块,模型能更有效地从多通道 EEG 数据中学习各频率成分的相互作用,实现信号特征的全局优化。

在具体应用中,Gam-EEGNet 模型表现出高准确率和快速响应性,特别适用于实时 BCI 系统。实验结果显示,Gam-EEGNet 在 0.7 s 的短时间窗口内即可达到 86.58% 的分类精度,提高了用户的交互体验和系统的整体性能。Gam-EEGNet 不仅在分类准确性上优于传统方法,还通过全局注意力机制增强了对复杂信号特征的捕捉和识别能力,展现出在实际应用中的巨大潜力和广阔前景。

1 相关工作

1.1 深度学习在脑电解码中的应用

近年来,端到端深度学习方法已被广泛用于处理 EEG 信号,并显示出良好的泛化能力。

1) 紧凑脑电网络方法(electroencephalography network, EEGNet)^[13]。EEGNet 是一个紧凑型卷积神经网络架构,专为脑电信号处理和 BCI 系统设计。其结构紧凑、高效,能够在数据稀缺的训练环境中表现出色,适应多种 BCI 任务。第二章节将详细介绍 EEGNet 的具体结构及其在不同应用场景中的表现。

2) 典型卷积神经网络方法(canonical convolutional neural network, CCNN)^[14]。CCNN 也是一个卷积神经网络模型。不同的是,C-CNN 使用富含振幅和相位信息的频

域数据作为网络输入。CCNN 网络结构由两个卷积层和一个完全连接层组成。第一卷积层是空间滤波层,第二卷积层是时间滤波层,全连接层用于分类。

3) 滤波器组-时间卷积神经网络方法(filter bank time-convolutional neural network, FB-tCNN)^[15]。对于 SSVEP 频率识别过程中,在频域输入的范式下,短期窗口下的特征可能不明显,每个通道的时间差异可能被忽略。FB-tCNN 使用时域信号作为网络输入,并使用滤波器组融合来自不同频带的特征信息,以提高网络的分类性能。

4) 滤波器组-时间卷积神经网络方法(steady-state visual evoked potential network, SSVEPNet)^[16]。SSVEPNet 是卷积神经网络和长短期记忆网络的混合网络模型,接受时域数据作为网络输入。SSVEPNet 由 3 部分组成:卷积神经网络、长短期记忆网络 and 全连接网络。此外,为了抑制网络训练过程中可能出现的过拟合,在网络实现过程中结合了频谱归一化和标签平滑技术,进一步提高了模型的泛化能力。即使只有少量的校准数据,SSVEPNet 仍然可以实现非常好的分类性能,并且这一特性已经在 4 类、12 类和 40 类数据集上得到了验证。

1.2 注意力机制在脑电解码中的应用

基于注意力机制的 Transformer 模型起源于机器翻译领域,并迅速在广泛的应用中引起了关注^[17-18]。注意力机制的核心优势在于其评估长序列全局依赖性的能力,这对于许多任务尤为关键。在任务相关的 EEG 试验中,全局交互作用不可忽视,因此,Transformer 模型被引入 EEG 信号处理领域。

Kostas 等^[19]设计了一种使用 Transformer 进行 EEG 分类任务的预训练和微调方法,以优化分类效果。Song 等^[20]进一步研究了从空间和时间域学习特征的方法,具体而言,他们将 EEG 信号沿时间维度切片处理,以捕捉更为细致的特征。Liu 等^[21]提出了一个处理 EEG 微分熵特征的类似框架,显示了 Transformer 在多样化 EEG 信号处理中的潜力。Bagchi 等^[22]则将 EEG 转换为多帧活动图,结合 CNN 模块和 Transformer 模块以捕获有用信息。然而,这些方法在特征提取时可能会减少原始数据中的信息量,并且往往依赖于特定任务。

先前的研究在提高脑电信号(EEG)解码精度方面取得了显著进展,许多方法通过优化算法和模型架构,实现了对脑电数据的更精确分类。然而,这些研究大多集中于局部特征的提取与分析,往往忽略了在时空维度上具有长期依赖性的全局特征的利用。全局特征在复杂信号分类中具有关键作用,特别是在处理像稳态视觉诱发电位(SSVEP)这样依赖于特定频率和时序模式的信号时,这些全局特征的有效捕捉显得尤为重要。因此,受上述工作的启发,本文提出了一种新型的神经网络架构——Gam-EEGNet,该架构将 EEGNet 与全局注意力机制相结合。通过这一创新设计,Gam-EEGNet 不仅继承了 EEGNet 在

处理脑电信号时的高效性和可靠性,还通过引入注意力机制,进一步强化了对全局依赖性和关键时空特征的识别和提取能力。特别是在 SSVEP 信号分类中,Gam-EEGNet 展现出了明显的优势。这种全局与局部特征相结合的方式,使得 Gam-EEGNet 在提高分类精度的同时,还显著加快了模型的训练速度。此外,尽管增强了特征提取的复杂性,该模型依然保持了轻量级的特性,为实时脑机接口(BCI)系统的开发和应用提供了强有力的技术支持。这一架构的提出,不仅填补了现有方法在全局特征利用方面的不足,也为未来的 BCI 系统设计指明了新的方向。

2 模型设计

2.1 网络全局模型

Gam-EEGNet 模型的具体结构如图 1 所示,其设计理念是在不增加额外计算负担的前提下,提升特征的全局交互表现和分类准确性。首先,模型通过一维时间卷积层及批量归一化层处理多通道 EEG 信号,提取时序特征并提高模型稳定性。接着,深度卷积层通过增加卷积核的深度来捕捉更复杂和细粒度的特征表示,平均池化层则负责下采样以防止过拟合。随后,深度可分离卷积层对通道和空间

信息进行融合,通过将传统卷积分解为深度卷积和点卷积,既减少了模型参数和计算量,又增强了特征提取效果。在此基础上,引入 Gam 模块,包含通道注意力模块(channel attention module, CAM)和空间注意力模块(spatial attention module, SAM)。CAM 通过 3D 置换操作和多层感知器(multilayer perceptron, MLP)来优化通道间特征,增强通道间的相关性。SAM 通过卷积操作突出与分类任务紧密相关的空间维度特征。经过 Gam 模块处理后的特征进一步通过激活函数和池化层进行优化和降维,以增强非线性表达能力。最终,经过优化的特征输入到全连接层和 Softmax 层,实现精确的类别分类。全连接层综合了前层的高维特征,为分类器提供强大的判别能力,而 Softmax 层则将输出转化为概率分布,完成 SSVEP 信号的最终分类。Gam-EEGNet 的创新在于结合了全局注意力机制,使其能够更好地从原始 EEG 信号中学习时空特征。实验结果表明,该模型在多个标准 EEG 数据集上的表现优于传统分类方法,显示出其优秀的性能和应用潜力。通过融合全局注意力机制,Gam-EEGNet 不仅提高了分类准确性,还增强了对复杂信号特征的捕捉和识别能力,展现了其在实际应用中的巨大潜力和广阔前景。

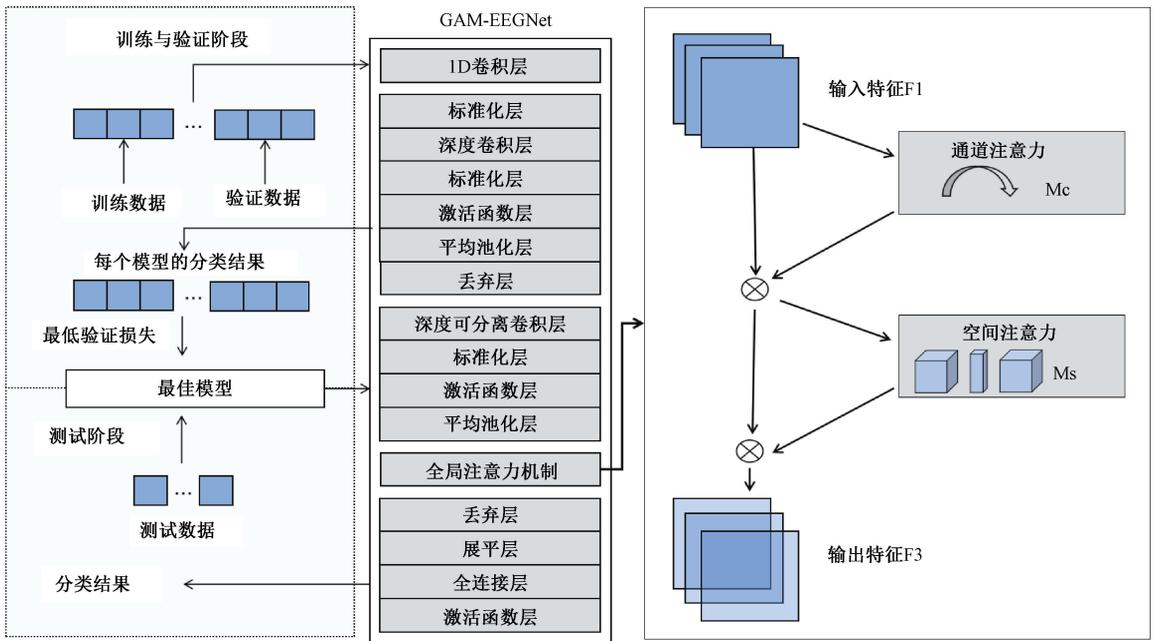


图 1 全局模型图

Fig.1 Overall model diagram

2.2 基准方法 EEGNet

EEGNet 的结构如图 2 所示,包含 3 个关键的网络构件:标准卷积层、深度卷积层以及分离卷积层,这些组件共同工作,以抓取和细化用于复杂神经信号分类的关键特征。神经网络的输入层接收的脑电信号数据格式为通道数乘以样本数。其后是中间层,起始层为一个二维的卷积层。

此层的卷积核大小与脑电信号的采样率相关,设定 L 等于脑电信号采样频率的一半(记为 0.5 fs),因此卷积核的尺度便是 $L \times 1$ 。在这个卷积层中,卷积运算按行对脑电信号进行处理,其主要功能是按通道进行滤波处理,并通过激活函数来输出特征图。此过程的数学表达可以表示如下:

$$y_j = f((X * w_j) + b_j) \tag{1}$$

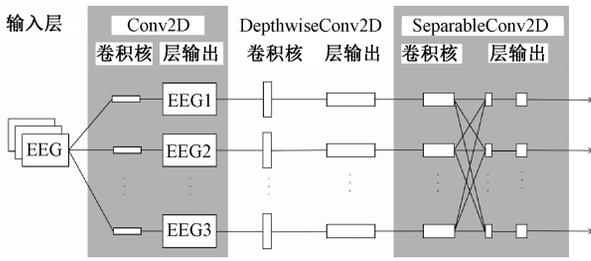


图 2 EEGNet 模型

Fig. 2 EEGNet model

式中: $*$ 代表卷积; y_i 表示第 j 个特征图; X 表示该层的输入信号; w_j 表示第 j 个卷积核的权重矩阵; b_j 表示第 j 个卷积的偏差值; j 表示激活函数。

神经网络中间层的次一层是深度卷积层,其使用的卷积核维度为通道总数乘以 1。与初层不同的是,深度卷积层在深度等于 1 时,执行卷积过程中一个卷积核仅对应一个输入的特征图。而在标准卷积层中,每一个卷积核都会和所有输入特征图进行卷积运算。深度卷积的运算逻辑公式如下:

$$y_{j,h} = f\left(\sum_j (X_j * w_{j,h}) + b_{j,h}\right) \quad (2)$$

式中: $*$ 代表卷积; h 表示深度卷积的深度; $y_{j,h}$ 表示第 j 个卷积核对应的深度为 h 的输出; X_j 表示第 j 个输入的特征图; $w_{j,h}$ 表示第 j 个深度为 h 的卷积核;

$b_{j,h}$ 表示第 j 个深度为 h 的偏差值。特征图从深度分离卷积层输出后,先是通过深度卷积步骤进行时域特征的提取,随后为点卷积步骤,具体的点卷积过程公式如下:

$$y_j = f\left(\sum_i (X_i * w_j) + b_j\right) \quad (3)$$

式中: $*$ 代表卷积; y_j 表示第 j 个特征图输出; X_i 表示第 i 个特征图输入; w_j 表示第 j 个点卷积核; b_j 表示卷积偏置。

2.3 全局注意力机制

在以往的研究中,特征通道间的关联性往往未被充分利用,这可能导致特征间的相互干扰,从而降低了算法效率。全局注意力机制可以解决以上问题,该机制借鉴了 Self-Transformer 模型的自注意力机制,主要通过点积操作对不同通道内的特征进行加权处理,以此强化通道间的相互作用和全局信息的整合。

1) 全局注意力机制的设计目的是为了减少信息损失并放大大局维度交互特征。该机制采用了 CBAM 模型中的序列通道-空间注意力机制^[23],并重新设计了子模块。整个过程可用式(4)和(5)表示。给定输入特征图,中间状态 F_2 和输出 F_3 定义为: $F_1 \in R^{C \times H} \times W$ 。

$$F_2 = M_c(F_1) \otimes F_1 \quad (4)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (5)$$

式中: M_c 和 M_s 分别是通道和空间注意力图, \otimes 代表逐元素乘法。

2) 通道注意力子模块利用 3D 置换在 3 个维度上维持

信息完整性。随后,通过双层的 MLP^[24] 增强了维度间的通道-空间关系。该 MLP 采用编码器-解码器架构,其缩减比例与 BAM 模型中的 MLP 一致。

3) 针对空间注意力子模块,为更好地融合空间信息,引入了双卷积层。该模块的缩减比例 r 与通道注意力子模块保持一致。同时,最大化池化操作会减少信息量,对特征图产生不利影响。避免使用池化操作有助于更好地保留特征图信息。因此,空间注意力模块可能会导致参数数量明显增加。为避免这一点,该机制采取了群卷积策略,其中包括通道随机置换。

3 实验研究

3.1 实验数据集

实验数据集采用了 Nakanishi 等^[25] 在 2015 年的研究,本数据集涵盖了 12 种不同频率的 SSVEP 信号,数据来源于 https://github.com/mnakanishi/12JFPM_SSVEP。该研究涉及 10 名被试者,包括 9 名男性和 1 名女性,平均年龄为 28 岁。实验的初始阶段包含 1 s 的目标刺激提示。实验过程中,被试者在一个灯光柔和的室内,坐在距离显示屏 60 cm 远的舒适椅子上。显示屏上的 12 个目标以 9.25~14.75 Hz 的频率进行闪烁。每位被试者需完成 15 组实验。

使用 BioSemi ActiveTwo EEG 系统以 2 048 Hz 采样率采集脑电信号。在后期的离线分析中,信号被降采样至 256 Hz。考虑到视觉系统的反应延迟,有效数据从刺激目标开始闪烁的 0.135 s 起至 $[0.135 + d]$ s 的区间内提取,其中 d 指的是分析窗口的时长。

3.2 实验方法

为了进一步验证本文所提出方法的有效性,本文采用了 CCNN、FBtcnn、SSVEPNet 等主流深度学习方法对相同的数据集进行分类作为对比。

此外,为评估脑机接口的性能,除了采用识别准确率外,还将信息传输率(ITR)作为评价指标。定义每分钟传输的平均信息量为:

$$ITR = \frac{60}{T} \times [\log_2 M + P \log_2 P + (1 - P) \log_2 \left(\frac{1 - P}{M - 1}\right)] \quad (6)$$

式中: T 表示平均判断时长; M 表示类别个数, P 表示识别正确率。ITR 的单位为 bits/min。

为了进一步分析各分类器在特征提取和数据分布方面的表现,还引入了 t-SNE (t-distributed stochastic neighbor embedding) 可视化结果。t-SNE 是一种非线性降维方法,主要用于高维数据的可视化,通过将数据嵌入到二维或三维空间中,使得相似的样本在嵌入空间中相互聚集而不同的样本相互远离,从而便于观察和分析高维数据的分布特征。

3.3 实验结果分析

神经网络训练使用 Pytorch 深度学习框架,所用计算机

CPU 为 Intel Core i7-8700K @ 3.20 GHz, 内存为 128 GB, GPU 为 NVIDIA GTX 1080 Ti。

1) 训练过程的稳定性分析

在进行脑电分类任务时, 分类模型训练过程的稳定性对于 BCI 应用至关重要。稳定的训练过程不仅能够确保模型在训练期间的高效收敛, 还能减少模型在实际应用中的不确定性。本节通过分析各模型在训练过程中的损失函数和准确率变化情况, 评估 Gam-EEGNet 在训练过程中的稳定性。如图 3 和 4 所示, 分别展示了五种不同分类器在 200 个训练轮次中的损失率和准确率变化情况。从图 3 可以看出, 所有模型在训练初期的损失率均呈现快速下降的趋势, 但在训练轮次达到 50 次后, 损失率趋于稳定。特别是 Gam-EEGNet 模型在整个训练过程中损失率保持在较低水平, 显示出较好的收敛性。图 4 展示了各模型在训练过程中的准确率变化情况。可以观察到, Gam-EEGNet 模型在初始训练阶段的准确率快速提升, 并在训练轮次达到 100 次后趋于稳定, 最终在接近 1.0 的准确率上保持稳定。相比之下, 其他模型如 CCNN 和 FB-tCNN 在训练初期的准确率提升较慢, 且在训练后期出现波动, 显示出训练过程中的不稳定性。通过对比各模型的训练损失率和准确率变化情况, 可以验证 Gam-EEGNet 方法在训练过程中的稳定性。正是通过引入全局注意力模块, 有效地提取和表征 SSVEP 信号的特征, 减少了个体差异和噪声的影响, 从而使得其在训练过程中表现出更快的收敛速度和更低的训练误差。具体而言, Gam-EEGNet 的全局注意力机制能够在通道和空间两个维度上强化特征提取, 优化特征交互。这些优点使得 Gam-EEGNet 在训练过程中不仅更稳定, 还能保持高准确率和高效性, 进一步证明了其在 SSVEP 信号分类中的有效性和可靠性。

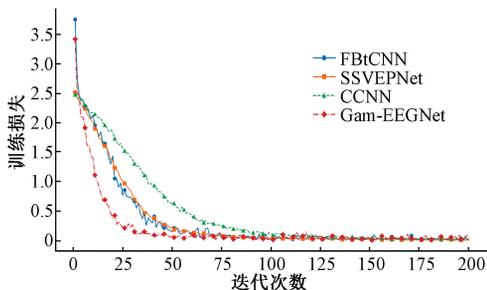


图 3 不同迭代次数训练损失对比图

Fig. 3 Comparison of training loss for different epochs

2) 分类性能分析

深度学习模型在特征提取和模式识别方面具有显著优势, 能够自动从 SSVEP 脑电数据中学习到复杂的特征表示, 而传统模型如 CCA 和 FBCCA 往往依赖于人工设计的特征, 容易受到人为因素的影响, 难以充分挖掘数据的潜在信息。故本文主要聚焦于深度学习模型的对比。较长的时间窗长能够提高识别的准确性, 但其信息传输率

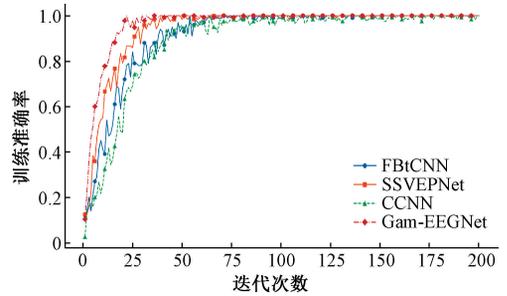


图 4 不同迭代次数训练准确率对比图

Fig. 4 Comparison of training accuracy for different epochs

(ITR) 较低, 不适合实际应用。ITR 是衡量脑-机接口系统性能的重要指标之一, 较低的 ITR 意味着系统在单位时间内传输的信息量较少, 影响实际应用中的实时性和用户体验。因此, 本实验选取了 1 s 的时间长度来评估模型的性能, 并将数据截取为前 0.3、0.5、0.7 和 1 s 的数据长度进行分析。所使用的分类器包括 CCNN、FB-tCNN、SSVEPNet 和 Gam-EEGNet。图 5 和 6 所显示为 10 名被试者在不同分类器的准确率和 ITR 的 15 组实验的平均结果。从图中可以看出, 随着时间窗口的增加, 各分类器的准确率均有提升。特别是 Gam-EEGNet 方法在各个时间点上均表现出最高的准确率, 尤其是在 0.7~1 s 的时间段, 准确率高达 90.87% 和 95.40%, 表明其特征提取和分类决策更加高效。在信息传输率 (ITR) 方面, 通过分析多个时间节点, 如 0.3、0.5、0.7 和 1 s, 可以看出基于 Gam-EEGNet 方法的 ITR 均优于其他方法。表 1 展示了不同被试者在 1 s 时间窗长度下的分类准确率和信息传输率。在 1 s 的时间窗口下, 对于被试者 S1、S2、S10, Gam-EEGNet 方法相较于其他方法, 识别准确率均提升 10% 以上。本文方法在所有受试者的平均准确率显著优于 FB-tCNN 的 83.00% 和 CCNN 的 82.70% ($p < 0.01$)。且本文方法在 1 s 时间窗长度时的平均信息传输率为 189.4 bits/min, 显著高于 SSVEPNet 的 160.34 bits/min 和 FBtCNN 的 140.35 bits/min ($p < 0.05$)。对于具有显著 SSVEP 响应特征的被试者 S6、S7、S8, 本方法对准确率和 ITR 的提升有限 ($p > 0.05$)。尽管如此, Gam-EEGNet 在这些被试者中的表现仍优于其他方法, 表明其在处理不同特征的脑电信号时具有较高的鲁棒性。总体来说, 本文提出的 Gam-EEGNet 在分类准确率和信息传输率方面均表现出优异性能。通过引入全局注意力机制, Gam-EEGNet 有效提升了 SSVEP 信号特征的提取和分类能力, 特别是在较短的时间窗口内表现尤为突出。实验结果表明, 本文方法在基于 SSVEP 脑-机接口系统的目标识别中具有更高的准确率和信息传输率, 增强了脑-机接口的应用潜力。

3) 消融实验

(1) 分类准确率定量分析

为验证全局注意力机制在 Gam-EEGNet 架构中的重

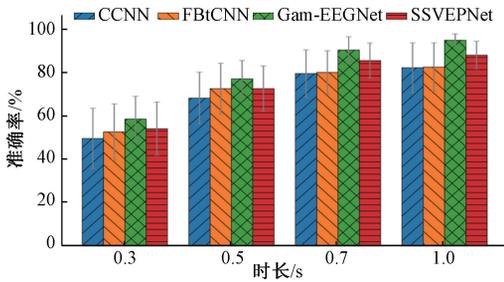


图 5 不同算法不同窗长下的准确率对比

Fig. 5 Comparison of accuracies for different algorithms and time window lengths

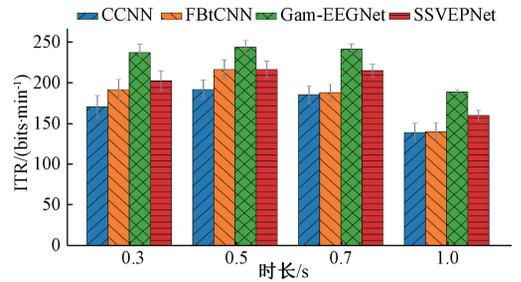


图 6 不同算法不同窗长下的 ITR 对比

Fig. 6 Comparison of ITRs for different algorithms and time window lengths

表 1 被试者在 1 s 时间窗长度时不同方法识别准确率

Table 1 Recognition accuracies and information transfer rates of subjects in a 1-second time window using different methods

被试者	识别准确率/%				信息传输率/(b·min ⁻¹)			
	Gam-EEGNet	SSVEPNet	FBtCNN	CCNN	Gam-EEGNet	SSVEPNet	FBtCNN	CCNN
S1	88.33±11.56	72.50±24.06	73.17±16.52	72.67±21.15	159.69±47.08	107.10±77.44	109.07±49.54	107.60±63.84
S2	81.06±10.64	50.83±16.72	68.00±23.56	67.00±19.34	133.77±35.99	53.05±35.20	94.41±66.11	91.71±52.84
S3	87.00±6.56	86.67±6.76	67.17±15.42	66.67±15.88	154.67±24.67	153.44±25.25	92.16±41.97	90.82±42.92
S4	98.44±0.57	100.00±0	85.00±6.52	84.67±9.37	204.90±3.24	215.10±0	147.37±23.51	146.20±33.87
S5	100.00±0	99.17±0.04	87.33±10.69	83.33±13.47	215.10±0	209.22±0.25	155.90±41.51	141.49±48.32
S6	100.00±0	95.00±4.83	94.33±2.84	93.33±6.03	215.10±0	187.54±23.39	184.48±12.92	180.04±27.32
S7	100.00±0	99.17±0.02	89.83±8.81	100.0±0	215.10±0	209.22±0.12	165.53±36.20	215.10±0
S8	100.00±0	100.00±0	93.33±4.30	93.33±5.47	215.10±0	215.10±0	180.04±19.04	180.04±24.54
S9	100.00±0	97.50±2.13	85.00±13.84	83.33±12.03	215.10±0	199.79±11.48	147.37±51.99	141.49±42.79
S10	99.17±0.05	84.17±4.52	86.83±9.81	82.67±12.72	209.22±0.31	144.43±15.97	154.04±37.33	139.21±44.77
平均值	95.40±2.94	88.50±6.43	83.00±11.23	82.70±11.55	189.40±14.02	160.34±25.02	140.35±39.52	139.32±40.45

要性,本文进行了详细的消融实验。实验中对测试了基准模型 EEGNet 和 Gam-EEGNet 在不同时间窗口下的分类性能。由图 7 可以看出, Gam-EEGNet 在各个被试者的分类准确率方面均优于 EEGNet。特别是在被试者 S1、S2 和 S3 中, Gam-EEGNet 的分类准确率分别提高了 15.00%、11.06% 和 15.00%。在被试者 S5~S8 中, Gam-EEGNet 与 EEGNet 的分类准确率均高达 1。这是因为这些受试者的 SSVEP 信号稳定性较高、噪声水平低, 信号特征较为简单和显著, 因此 EEGNet 也能取得较高的分类准确率。实验结果表明, 全局注意力机制在 Gam-EEGNet 中的引入有效提升了 SSVEP 信号的分类准确性和稳定性。通过更好地捕捉和放大电极通道间的相互关系, Gam-EEGNet 提高了模型对复杂信号特征的识别能力。

(2) t-SNE 可视化定性分析

图 8~10 展示了经过充分训练后, 被试者 S1 在不同处理方式下的 t-SNE 可视化结果。图中的散点代表脑电信号的读数, 每种颜色对应 12 种不同频率信号之一。颜色从深蓝到深红, 经过浅蓝、绿色、黄色和橙色逐渐过渡, 频率指数从 0~11。每一个频率信号代表 SSVEP 范式中的潜在目标频率, t-SNE 图对它们进行了聚类, 显示了分类器在分析脑电模式时区分这些不同频率的能力。右侧的颜

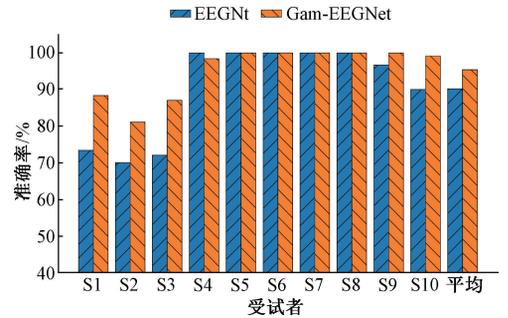


图 7 全局注意力机制模块消融实验

Fig. 7 Ablation study of global attention mechanism

色条作为图例, 将每种颜色映射到对应的频率信号, 便于理解在二维 t-SNE 空间中频率的分布和分离情况。图 8 展示了分类器在处理 EEG 数据的初始阶段, 经过 t-SNE 降维后的数据分布情况。图 9 和 10 分别展示了未引入和引入 Gam 后的 EEGNet 特征分布。引入 Gam 后, 可以观察到显著的聚类效果改进。应用 Gam 模块后的 t-SNE 可视化结果显示, 数据点之间的聚集程度明显提高, 类别间的分界线变得更加突出。这一结果表明, Gam 模块相比基准模型, 能够更有效地捕获到具有较高辨识度的特征, 从而增强分类辨别能力。此外, 引入 Gam 后, 同一类别内的

数据点呈现出更紧密的聚合状态,类内相似性得到加强,这可能是分类准确率提高的关键因素之一。同时,不同类别之间的间隔也变得更为清晰,减少了特征空间中的重叠,有助于提升分类器的泛化能力。通过与未加入 Gam 模块的特征空间对比,发现加入全局注意力机制后的特征表现出更高的类别聚合度和更清晰的类间分界,这进一步证实了文中提出的新模型的有效性。

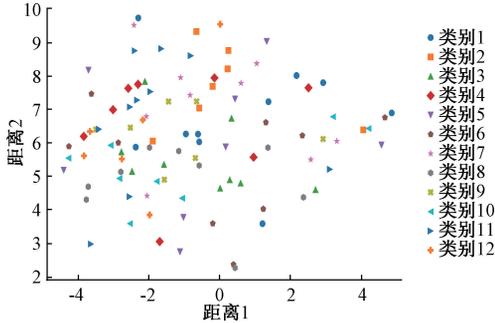


图 8 t-SNE 可视化初始阶段脑电数据

Fig. 8 t-SNE visualization of EEG data in the initial phase

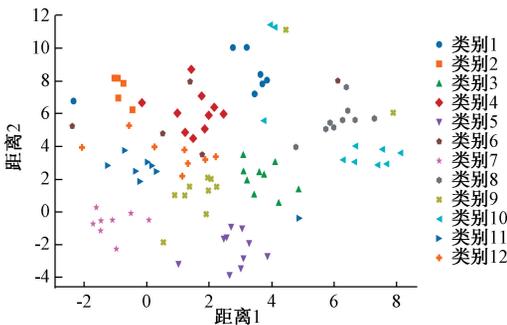


图 9 t-SNE 可视化 EEGNet 分类结果图

Fig. 9 t-SNE visualization of EEGNet classification results

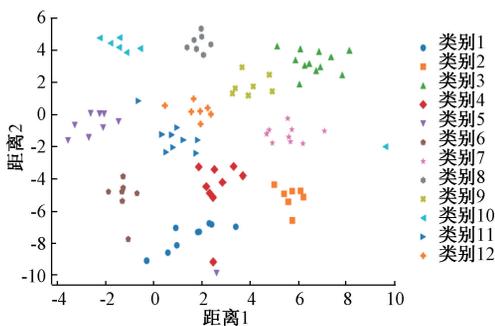


图 10 t-SNE 可视化 Gam-EEGNet 分类结果图

Fig. 10 t-SNE visualization of Gam-EEGNet classification results

4 结 论

为了克服脑电图信号在 SSVEP 分类中信噪比低、非平稳性强和个体差异大等问题,提出了一种结合全局注意力机制与 EEGNet 的新型神经网络架构—Gam-EEGNet。该架构通过引入全局注意力模块,更有效地提取和表征

SSVEP 信号特征,减少个体差异和噪声影响,从而提高分类准确率。如表 1 结果所示,在 1 s 时间窗内,不同被试者的识别准确率均在 95% 以上,ITR 在 180 bits/min 以上。实验结果表明,在多个时间窗口下,Gam-EEGNet 在 ITR 方面优于现有基准模型,尤其在较短时间窗口内展现出高效率和高准确性。此外,还评估了各模型在训练过程中的稳定性。结果显示,Gam-EEGNet 在整个训练过程中表现出较好的收敛性和稳定性,其较快的收敛速度和稳定的训练结果进一步验证了其在 SSVEP 信号分类中的有效性和可靠性。这些优势使得 Gam-EEGNet 在实际应用中,特别是在实时 BCI 系统中,具有更高的实用价值。然而,研究的局限性也值得关注。当前研究仅限于特定被试者群体,对模型泛化能力的评估尚不充分。同时,尽管引入 Gam 提升了性能,但也增加了计算复杂度,这在资源有限的实际部署环境中可能成为一个挑战。未来的研究将聚焦于扩大样本规模和多样化被试者特征,以全面评估新模型的泛化能力。在计算效率方面,将探索算法优化,进一步压缩和简化模型,以适应低资源消耗的需求,并减少实际 BCI 系统中的响应时间。此外,还计划在更多类型的 EEG 数据集上应用 Gam-EEGNet,验证其在不同场景下的鲁棒性和适应性。通过综合考虑精确度、实时性和泛化能力,期望能为 SSVEP-BCI 领域带来新的洞见,并应用于在线目标识别,提高其工程实用价值。

参 考 文 献

- [1] 李文平,徐光华,张凯,等.一种高效运动想象脑电信号浅层卷积解码网络[J].西安交通大学学报,2023,57(10):11-19.
LI W P, XU G H, ZHANG K, et al. An efficient shallow convolutional decoding network for motor imagery electroencephalography signals[J]. Journal of Xi'an Jiaotong University, 2023, 57(10): 11-19.
- [2] EISENSTEIN M. Seven technologies to watch in 2024[J]. Nature, 2024, 625(7996): 844-848.
- [3] 谢士通,汤佳贝,蔡雨,等.脑电 BCI 系统的软硬件开发平台发展现状[J].电子测量与仪器学报,2022,36(6):1-12.
XIE SH Y, TANG J B, CAI Y, et al. Current status of software and hardware development platforms for EEG-BCI systems[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(6): 1-12.
- [4] 陆竹风,张小栋,李睿,等.基于表情辅助的假手脑控方法[J].中国机械工程,2018,29(12):1454-1459.
LU ZH F, ZHANG X D, LI R, et al. A brain control method for prostheses based on facial expression[J]. China Mechanical Engineering, 2018, 29(12): 1454-1959.
- [5] 徐光华,张锋,王晶,等.面向智能轮椅脑机导航的高

- 频组合编码稳态视觉诱发电位技术研究[J]. 机械工程学报, 2013, 49(6): 21-29.
- XU G H, ZHANG F, WANG J, et al. Research on key technology on time series combination coding-based high-frequency SSVEP in intelligent wheelchair BCI navigation[J]. Journal of Mechanical Engineering, 2013, 49(6): 21-29.
- [6] KO L W, CHANG Y, WU P L, et al. Development of a smart helmet for strategical BCI applications[J]. Sensors, 2019, 19(8): 1867.
- [7] GATEAU T, AYAZ H, DEHAIS F. In silico versus over the clouds: On-the-fly mental state estimation of aircraft pilots, using a functional near infrared spectroscopy based passive-BCI [J]. Frontiers in Human Neuroscience, 2018, 12: 187.
- [8] 杨晨. 面向应用的稳态视觉诱发电位脑-机接口算法及系统研究[D]. 北京: 清华大学, 2018.
- YANG CH. Application-oriented steady-state visual evoked potential-based brain-computer interface algorithm and system research[D]. Beijing: Tsinghua University, 2018.
- [9] VIALATTE M M, DAUWELS J. Steady-state visually evoked potentials: Focus on essential paradigms and future perspectives [J]. Progress in Neurobiology, 2018, 90(4): 418-438.
- [10] BEVERINA F, PALMAS G, SILVONI S, et al. User adaptive BCIs: SSVEP and P300 based interfaces [J]. PsychNology, 2013, 1(4): 331-354.
- [11] 丛佩超, 陈熙来, 肖宜轩, 等. 基于 SSVEP 信号的相频特性分类算法研究[J]. 电子测量技术, 2024, 47(5): 188-198.
- CONG P CH, CHEN X L, XIAO Y X, et al. Research on phase-frequency characteristic classification algorithm based on SSVEP signals[J]. Electronic Measurement Technology, 2024, 47(5): 188-198.
- [12] LIU Y, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. ArXiv preprint arXiv: 2112.05561, 2021.
- [13] LAWHERN V, SOLON A, WAYTOWICH N. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces [J]. Journal of Neural Engineering, 2018, 15(5): 056013.
- [14] 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): 026-028.
- [15] 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.
- [16] BHATTACHARYYA A, TRIPATHY R K, GARG L, et al. A novel multivariate-multiscale approach for computing EEG spectral and temporal complexity for human emotion recognition [J]. IEEE Sensors Journal, 2021, 21(3): 3579-3591.
- [17] VASWANI A, SHAZEER N. Attention is all you need [J]. Neural Information Processing Systems, 2017, 30: 5998-6008.
- [18] 李兰亭, 苗敏敏. 基于多视图与注意力机制的睡眠脑电分期[J]. 国外电子测量技术, 2024, 43(1): 30-37.
- LI L T, MIAO M M. Sleep EEG staging based multi-view and attention mechanism [J]. Foreign Electronic Measurement Technology, 2024, 43(1): 30-37.
- [19] KOSTAS D, AROCA-OUELLETTE S, RUDZICZ F, et al. BENDR: Using transformers and a contrastive self-supervised learning task to learn from massive amounts of EEG data [J]. Frontiers in Human Neuroscience, 2021, 15: 253.
- [20] SONG Y, JIA X, YANG L, et al. Transformer-based spatial-temporal feature learning for EEG decoding [J]. ArXiv preprint arXiv: 2106.11170, 2021.
- [21] LIU J, ZAHGN L, WU H, et al. Transformers for EEG emotion recognition [J]. ArXiv preprint arXiv: 2110.06553, 2021.
- [22] BAGCHI S, BATHUL D. EEG-Conv transformer for single-trial EEG-based visual stimulus classification [J]. Pattern Recognition, 2022, 129: 108757.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]. European Conference on Computer Vision, 2018: 3-19.
- [24] TAUD H, MAS J F. Multilayer perceptron (MLP) [J]. Geomatic Approaches for Modeling Land Change Scenarios, 2018: 451-455, DOI: 10.1371/journal.pone.0140703.
- [25] 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): 0140703.

作者简介

刘俊杰, 硕士研究生, 主要研究方向为脑机接口与康复应用。

谢俊(通信作者), 教授, 博士生导师, 主要研究方向为脑电信号处理技术与脑控机器人与康复应用。