arXiv:2302.02520v1 [cs.HC] 6 Feb 2023

PGCN：用于脑电情绪识别的金字塔图卷积网络

Ming Jin、Enwei Zhu，*IEEE*会员，Changde Du、Huiguang He，*IEEE*高级会员，Jinpeng Li*，*IEEE*会员

摘要——**情绪识别对于多种精神疾病的诊断与康复至关重要。过去十年间，基于脑电图（EEG）的情绪识别因其突出的准确率和可靠性而受到广泛研究，图卷积网络（GCN）也已成为从脑电信号中解码情绪的主流模型。然而，GCN可能未能充分利用电极关系，尤其是头皮上远距离电极间的依赖关系，尽管已有研究证明这些关系对情绪识别十分重要。感受野较小，使浅层GCN只能聚合局部节点。另一方面，堆叠过多层会导致过平滑。为解决这些问题，我们提出金字塔图卷积网络（PGCN），在三个层次上聚合特征：局部、中观和全局。首先，我们基于电极的三维拓扑关系构建原始图卷积网络，用于整合二阶局部特征；其次，我们基于先验知识构建若干中观脑区，并采用中观注意力依次计算虚拟中观中心，以聚焦于中观脑区的功能连接；最后，我们融合节点特征及其三维位置，构建数值关系邻接矩阵，从全局角度整合结构与功能连接。在三个公开数据集上的实验结果表明，PGCN增强了对头皮上关系的建模能力，并在受试者依赖和受试者独立两种场景下均取得最先进性能。同时，PGCN在加深网络、扩大感受野与抑制随之而来的过平滑之间实现了有效权衡。我们的代码可通过https://github.com/Jinminbox/PGCN公开获取。**

索引词—**情绪识别、脑电图、图卷积网络、基于知识的建模**

I. 引言

情MOTION绪识别是人机交互中的重要模块，应用于 [1], 精神疾病诊断与康复 [2], [3], 交通运输 [4]以及安全领域 [5]。

现有的情绪识别研究可分为两类：第一类使用成本低、易于获取的行为信号，如语音 [6],手势 [7]和面部表达式 [8]。第二类使用生理信号，由于其具有抵抗伪迹和隐蔽性强的特点，因此可靠性和准确率更高 [9]。生理信号包括脑电图 [10], 、心电图（ECG）、肌电图（EMG）和皮肤电反应。

脑电图因其能够直接采集与情绪相关的脑信号，在生理信号中得到了长期应用。然而，脑电图采集过程极易受到人体其他生理信号和环境噪声的干扰。因此，需要进行预处理和特征提取，以呈现脑电信号中包含的情绪信息 [11],图 1 (a) 展示了脑电情绪识别的流程图。预处理包括去除噪声和干扰，例如眼电伪迹、肌电伪迹、心电伪迹、皮肤电信号以及工频干扰。特征提取有助于呈现脑电信号中的情绪相关信息，从而实现更准确的情绪识别。

借助头皮上不同节点的拓扑结构，图卷积模型能够利用脑电电极之间的连接，因此广受关注。作为图卷积网络在脑电情绪识别领域的开创性工作，DGCNN [10] 通过梯度反向传播动态更新脑电通道之间的连接，以获得更具判别性的脑电特征。GCB-net [12] 将图卷积网络与宽度学习系统相结合，在探索更深层脑电信息的同时，于宽阔的空间中搜索特征。RGNN [13] 提出了两种正则化器，以更好地处理跨被试脑电差异。V-IAG [14]旨在处理个体差异以及脑电区域之间动态且不确定的关系。

尽管以往的研究尝试将图卷积网络用于脑电情绪识别，但仍有许多有待探索的方向。

(1) 现有的图构建方法较为粗略：大多数邻接矩阵构建方法都基于头皮上部署的电极是否彼此相邻，而对更深层的结构连接和功能连接探索有限。

(2) 头皮上的情绪激活模式长期以来一直受到研究。然而，据我们所知，尚无先例将这些发现（例如电极功能簇）融入情绪识别的网络架构设计中。

（3）最重要的是，现有用于脑电图情绪识别的图卷积网络都是浅层网络（2–3 层），因为多层图卷积网络容易出现过平滑。然而，人脑具有长程连接，浅层网络无法学习此类长程依赖关系。

本研究部分得到了中国国家自然科学基金委员会（62106248）、中国浙江省自然科学基金（LQ20F030013）、中国宁波市公益性科技计划项目（202002N3181）以及浙江省医药卫生科技计划（2021431314）的资助。

Ming Jin、Enwei Zhu 和 Jinpeng Li 任职于中国科学院大学华美医院，地址为中国浙江省宁波市。他们还任职于中国科学院大学宁波生命与健康产业研究院，地址为中国浙江省宁波市。

Changde Du 就职于中国科学院自动化研究所脑启发智能研究中心，位于中国北京。

Huiguang He 任职于中国科学院自动化研究所模式识别国家重点实验室（中国北京）。

通讯作者：Jinpeng Li（*E*-邮箱：*lijinpeng@ucas.ac.cn*）

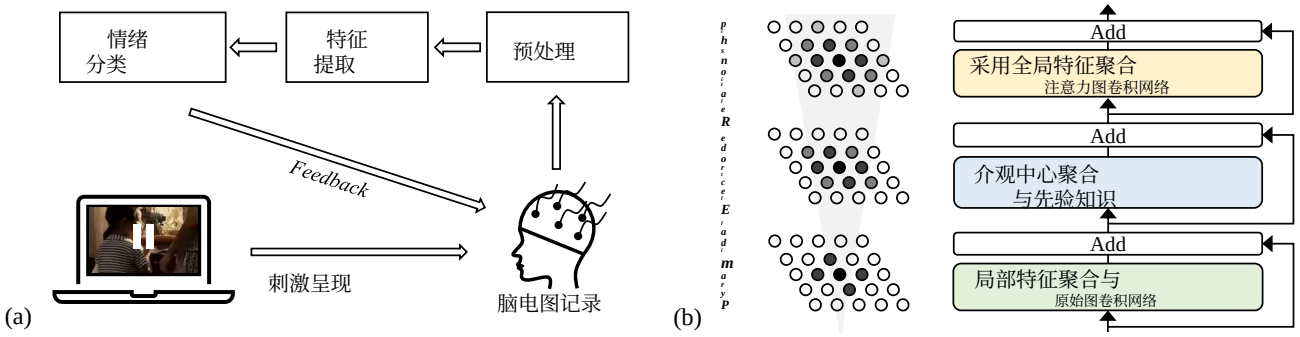


图1. 脑电情绪识别范式与 PGCN 的概念设计。(a) 脑电情绪识别的基本流程图，包括视听刺激呈现（以诱发相应情绪）、脑电信号采集、预处理、特征提取、情绪分类以及（有时）向受试者提供反馈。(b) PGCN 中的特征聚合包含三个主要组成部分。原始图卷积网络从相邻节点提取局部偏置信息；虚拟中观中心在先验知识的指导下，对脑区内的信息进行聚合；注意力图卷积网络则在全局层面进一步融合结构连接与功能连接。

为解决这些问题，我们提出了一种基于图的金字塔网络，逐步将感知野从局部扩展到中观和全局，并融入神经科学研究中的先验知识。如图 1（b）所示，PGCN 包含三个主要组成部分。第一部分关注不同节点之间紧密的局部连接。该部分根据不同电极的三维空间距离构建邻接矩阵，并采用两层图卷积网络，将相邻节点之间具有强区域特异性的结构关联进行融合。第二部分关注特定脑区内节点之间的功能连接。基于脑研究先验知识 [15], [16]划分不同的中观脑区，计算各脑区内节点之间的注意力相关系数，并生成虚拟中观节点。第三部分关注全脑不同节点之间可能存在的长距离依赖关系。我们使用注意力机制计算全局邻接矩阵，以融合节点之间的数值关系和位置关系，并使用图卷积网络融合全脑尺度上的节点关系。最后，将不同尺度的特征与原始特征融合，并采用三层全连接网络进行最终的情绪识别。

与以往主要仅使用二维电极关系构建图卷积网络的研究相比，PGCN 在借鉴情绪相关神经科学先验研究、构建脑区虚拟中观中心的同时，将节点之间的绝对位置关系、相对位置关系和数值关系融合到网络中。为实现这一目标，我们构建了 PGCN，从局部、中观到全局不同尺度聚合脑电特征。本文的主要贡献有三点：

(1) 我们提出了**金**字塔**图卷**积**网**络，用于处理不同尺度的脑电电极特征。PGCN 能够有效挖掘节点结构与功能连接中蕴含的信息，从而提升网络的有效性。

(2) 基于情绪相关神经科学中的先验知识，我们设计了不同的介观区域，并计算其虚拟中心，以区分不同脑区在情绪识别任务中的作用。

（3）我们在三个开放数据集上评估了该网络的性能。实验结果表明，PGCN 达到了最先进性能。此外，可视化结果进一步证明了所提出方法的有效性。论文代码将在发表后开源。

本文其余部分安排如下：第二节简要回顾相关工作；第三节详细阐述所提出的 PGCN；第四节展示 PGCN 在三个情绪识别数据集上的实验结果；第五节对 PGCN 及其可视化进行更深入的分析；第六节总结全文。

II. 相关工作

A. 脑电情绪识别

由于采集到的脑电原始数据含有伪迹和噪声，直接将脑电原始数据用于情绪识别颇具挑战。滤波、基线校正和重新参考等预处理操作能够有效抑制或消除伪迹和噪声。一些研究报告了使用预处理后的脑电信号进行端到端情绪识别。TSception [17]使用时间和空间卷积层提取时频特征以及左右大脑半球之间的差异，以实现端到端情绪识别。EEGNet [18]使用深度可分离卷积提取时空模式，在各种脑机接口任务中表现突出。

尽管预处理后的脑电数据可直接用于情绪识别，但进一步提取与情绪相关的脑电特征效果更好。经过谱分析 [19]和频带截取后，频域特征提取能够获取大脑神经活动的节律信息。常用的频域特征包括功率谱密度（PSD）特征 [20], 微分熵（DE）特征 [21], 差分不对称性（DASM）和有理不对称性（RASM）等。

提取脑电特征后，研究者设计了不同模型进行情绪识别。传统机器学习方法，如支持向量机（SVM） [22], 和聚类 [23], 已被证明能够进行情绪识别。

近年来，随着深度学习的快速发展，它已成为处理脑电特征的主流方法。Zheng 等人 [24] 构建了深度置信网络（DBN），以探索不同频带和通道的作用。Yang 等人 [25] 提出了一种带有子网络节点的分层网络结构，用于区分人类情绪。由于人类情绪具有时间连续性，循环神经网络（RNN）或长短期记忆网络能够有效利用脑电图的时间相关性 [26], 。ACRNN [27] 采用卷积神经网络提取空间信息，并应用带扩展自注意力的循环神经网络来探索脑电特征的时间信息；Zhang 等人 [28] 引入卷积神经网络和循环神经网络，以级联或并行方式探索保留的空间和时间信息。

B. 图卷积网络

得益于实用结构信息的引入，GCN被认为是处理非欧几里得数据的有效方法，并且在社交网络 [29], 知识图谱 [30] 和交通预测 [31], 等领域取得了巨大成功。

无向图可以表示为 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$，其中 $\mathcal{E}$ 表示连接不同节点的边集合，属于 $\mathcal{V}$的集合。通过连接所有边 $\mathcal{E}$，可以构建出刻画图关系的邻接矩阵$\mathbf{A} \in \mathbb{R}^{n\times n}$；与此同时，通过聚合每个节点的特征$\mathbf{x} \in \mathbb{R}^{d}$，可以构建出刻画图中节点特征的特征矩阵$\mathbf{X} \in \mathbb{R}^{n\times d}$，其中 n 表示节点数量， d 表示输入特征的维度。

Kipf等 [29]提出的简化 GCN 有效地简化了原始复杂的谱 GCN 方法 [32], , 简化后的 GCN 可表示为

$$\mathbf{Z} = \sigma\left(\tilde{\mathbf{D}}^{-\frac{1}{2}}\tilde{\mathbf{A}}\tilde{\mathbf{D}}^{-\frac{1}{2}}\mathbf{X}\mathbf{\Theta}\right), \tag{1}$$

其中 $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 和 $\mathbf{D}_{ii} = \sum_j \mathbf{A}_{ij}$，$\mathbf{I} \in \mathbb{R}^{n\times n}$ 是 n 维度矩阵， $\mathbf{\Theta}$ 是可训练权重矩阵。

C. 脑电情绪识别中的 *GCN*

由于脑电特征是一种特定的结构化非欧几里得数据，基于图卷积网络的脑电情感识别得到了快速发展。DGCNN [10] 通过梯度反向传播动态更新表征节点间关系的邻接矩阵，从而获得更准确的节点间关系并提升情绪识别效果。RGNN[13]采用两种正则化器、基于节点的域对抗训练以及情绪感知分布学习，以优化跨受试者情绪识别效果。受大脑认知过程神经学知识的启发，LGG-net [33] 提出了局部和全局图滤波层，用于学习不同脑功能区内部及其之间的脑活动，以模拟人脑认知过程中复杂的关系，从而实现最佳的情绪识别效果。LR-GCN [34]采用自注意力前向更新拉普拉斯矩阵，并通过梯度反向传播更新邻接矩阵，从而联合构建可学习的脑电电极关系。为应对个体差异以及不同脑电区域之间动态且不确定的关系，(V-IAG) [14] 提出了变分实例自适应图方法，并取得了良好效果。

D. 情绪与人脑

脑网络长期以来一直受到研究，旨在帮助人们理解人类情绪。Sporns等 [35] 提出，与人脑连接组相关的研究可在微观尺度、中观尺度和宏观尺度上开展，分别对应神经元、神经元簇和脑区。然而，由于人脑中的神经元数量庞大，目前尚不适合开展神经元层面的研究，因此大多数工作聚焦于神经元簇及更大尺度。

人脑具有显著的小世界属性，这一点可由相邻神经元更有可能频繁交换信息这一事实证明。He 等 [15] 首次利用结构影像数据构建了一个包含54个节点的脑网络，并观察到了小世界属性。随后许多研究采用不同的节点划分方法证实了小世界属性，并发现节点度的分布遵循带有指数截断尾部的幂律分布 [36]。Hagmann 等 [16] 采用弥散谱成像技术构建了加权脑结构网络，发现脑网络可划分为六个模块，且每个模块都有相应的核心节点，这些核心节点主要分布在额叶、颞叶和枕叶。

为进一步提升神经元之间的通信效率 [37], , 研究发现大脑具有显著的“长程连接”。尽管与短距离连接相比，长距离连接在能量和空间上的成本更高，但它们能够显著降低多个间接短距离连接之间的布线成本，从而实现更快速、更直接且噪声更少的信息传输 [38]。

III. 方法

A. 概述

PGCN 构建了一个金字塔网络，逐层融合不同尺度的脑电特征。模型的整体架构如图 2 所示，可分为以下步骤。(1) 考虑到脑网络中频繁的局部连接，我们根据电极之间的空间距离构建稀疏结构邻接矩阵，并引入图卷积网络来聚合局部特征。(2) 为了更好地区分不同脑区与情绪的相关性，我们基于先验研究构建了中观尺度的脑区，并计算每个脑区的虚拟中观中心，以表征中观特征。(3) 为了平衡远距离连接的重要性与经济性，我们将原始节点与虚拟中观节点融合，借助注意力机制构建稀疏的全局图连通网络，并通过图卷积聚合全局特征。(4) 最后，将融合后的特征输入一个 3 层全连接网络，以完成最终的情绪识别任务。

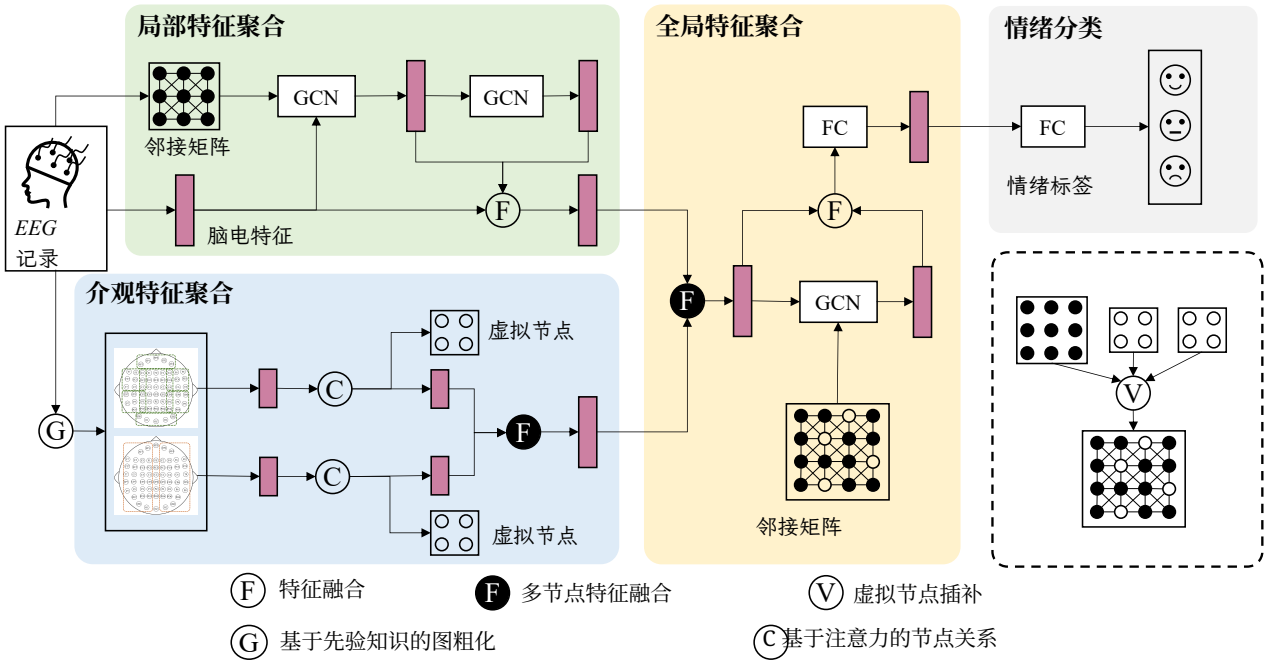


图2. 所提出的 PGCN 流程图。为了挖掘电极关系，PGCN 聚合多尺度信息，即局部、中观和全局特征，以执行情绪分类任务。图卷积网络用于对这些关系进行建模。

B. 局部特征聚合

局部特征聚合关注人脑中频繁的局部连接，并构建有效的信息传输机制，以融合相邻节点的脑电信息。为了关注短距离相邻特征，我们首先根据电极的相对空间位置进行稀疏图关系推理，使节点度数符合指数截断幂分布[36]，并确保邻接矩阵具有足够的稀疏性[13]。随后，我们构建了一个两层图卷积网络来聚合邻接节点的特征。最后，我们将原始特征与经过图卷积后的特征融合，以抑制过平滑[39]。

1) 稀疏图关系推理： GCN 依赖于构建准确的节点关系矩阵并计算相应的拉普拉斯矩阵。在脑电情绪识别任务中，构建不同电极 i 和 j 的邻接矩阵的一种常见方法是：

$$\mathbf{A}_{ij} = \begin{cases} 1 & \text{if} \quad j \in \mathcal{N}_i \\ 0 & \text{if} \quad j \notin \mathcal{N}_i \end{cases}, \tag{2}$$

其中， $\mathcal{N}_i$ 表示电极 i的二维空间邻居。

然而，该方法仍存在一些问题：（1）所有市售脑电电极帽上的电极都无法均匀分布，且仅用数字 0 和 1 无法准确描述电极之间的关系。（2）构建的邻接矩阵会导致稀疏性过高，进而使优化过程中丢失一些关键连接。（3）由于脑电图在不同受试者甚至不同会话之间存在很大差异，构建固定的邻接矩阵会导致优化不足。

受 Salvador 等人 [40] 和 Zhong 等人 [13],的研究启发，为了更好地描述不同节点之间的连接，我们基于不同节点间空间距离的平方倒数构建了一个初始邻接矩阵：

$$\mathbf{A}_{ij} = \begin{cases} 1 & \text{if} \quad \mathbf{A}_{ij} \geq 1 \\ \dfrac{\delta}{d_{ij}^2} & \text{if} \quad 0.1 \leq \mathbf{A}_{ij} \leq 1 \\ 0.1 & \text{if} \quad \mathbf{A}_{ij} \leq 0.1 \end{cases}, \tag{3}$$

其中， d_{ij} 是节点 i 和 j之间的三维距离， δ 是稀疏因子。在实验中，我们发现当 δ 设为 9 时效果最佳。我们将大于 0.1 的 $\mathbf{A}ij$ 截断，以保持稀疏性；并将小于 1 的 $\mathbf{A}ij$ 截断，以降低自环和距离极近邻居的权重。

参考 Jin等人 [34]在 LR-GCN 中的工作，我们将$\mathbf{A}$ 设为可学习矩阵，并通过梯度反向传播对其进行更新。

2) 用于局部表示聚合的 *GCN*： 构建合适的邻接矩阵 $\mathbf{A}$后，我们计算ˆ相应的拉普拉斯矩阵$\mathbf{L}$ ，并使用 GCN 在邻居节点之间进行信息传输：

$$\mathbf{H}^{(l+1)} = \sigma\left(\hat{\mathbf{L}}\mathbf{H}^{(l)}\mathbf{W}^{(l)}\right), \tag{4}$$

其中，$\mathbf{H}^{(l)}$ 和$\mathbf{H}^{(l+1)}$ 分别表示第 l层的输入和输出节点表示；初始输入表示$\mathbf{H}^{(0)}$ 为原始输入特征$\mathbf{X}$。$\mathbf{W}^{(l)}$ 为可学习权重矩阵， σ 为激活函数。

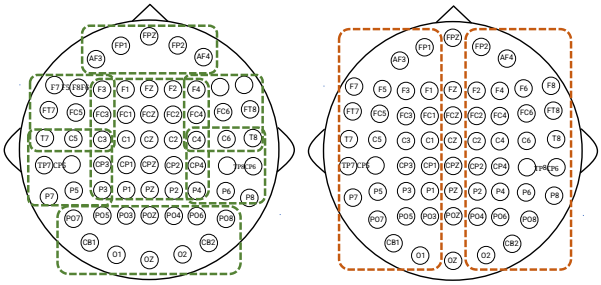
为了防止图卷积网络出现过平滑，我们仅设计了一个两层局部图卷积网络，并引入跨层连接；局部特征聚合的最终输出为：

$$\mathbf{X}^{local} = \text{concat}\left(\mathbf{X}, \mathbf{H}^{(1)}, \mathbf{H}^{(2)}\right) \tag{5}$$

C. 介观特征聚合

人类大脑皮层的不同区域之间连接紧密且高度集中，已有研究尝试将大脑皮层划分为若干情绪相关脑区 [16], [41]。参考当前脑科学研究的先验知识，我们构建了不同的中观脑区，并计算每个区域中虚拟中观中心的位置和特征。由于区域内的特征仅向虚拟中观中心汇聚，因此在扩大感知野的同时，能够有效避免过平滑。

1) 面向中观区域的图粗化：为实现中观特征聚合，我们设计了两种具有不同感受野的中观划分方案，如图3所示。



(a) 7个中观区域 (b) 2个中观区域

图3. 基于先验知识的脑区划分。

图3(a)展示了参考大脑皮层解剖结构进行的第一种划分。大脑皮层通常分为四个脑叶：额叶、顶叶、颞叶和枕叶 [42], ，每个脑叶负责不同的任务；例如，枕叶与视觉处理和解释有关。首先，我们将电极划分为五个区域；其次，有研究报告称，位于颞叶的电极（FT7、T7、TP7、FT8、T8、TP8）对情绪识别十分重要，因此我们对颞叶中的电极进行了更细致的二次划分 [24], [43]；最后，受Hagmann等人 [16], 的工作启发，我们调整了区域划分，以满足结构连接和功能连接的需求。

图3(b)展示了根据大脑的两个大脑半球划分中观区域的另一种有效方式。胼胝体连接着大脑的两个大脑半球，人类的所有活动都通过它们之间的信息交互来实现。然而，大脑两半球的功能存在显著差异。

2) 中观节点关系：构建中观脑区后，我们通过自注意力机制，重点关注介观区域内部的功能连接。输入是每个介观区域内各节点的特征集合：$\mathbf{h} = \left\{\vec{h}_1, \vec{h}_2, ..., \vec{h}_N\right\}$、$\mathbf{h} \in \mathbb{R}^{N\times F}$，其中 N表示介观区域中的节点数量， F表示每个节点的特征数量。基于注意力的连接矩阵$\mathbf{e}$可表示为：

$$\mathbf{e} = \text{LeakyReLU}((\mathbf{hW})(\mathbf{hW})^T), \tag{6}$$

其中，$\mathbf{W}$ 是一个可学习权重矩阵，$\cdot^T$ 表示转置。

3) 虚拟中观中心：计算出中观区域的基于注意力的连接矩阵后，我们开始构建虚拟中观中心。通过对$\mathbf{e}$按行求和，我们计算每个中观区域内的权重系数 $\mathbf{\Lambda} \in \mathbb{R}^{1\times N}$，其中 $\mathbf{\Lambda}_i$表示每个节点与所有其他节点之间的功能连接权重。之后，我们开始计算虚拟中观区域中心的特征和位置：

$$\begin{aligned} \mathbf{p}^{locate} &= \text{softmax}(\mathbf{\Lambda})\mathbf{P}, \\ \mathbf{m}^{feature} &= \text{softmax}(\mathbf{\Lambda})\mathbf{h}, \end{aligned} \tag{7}$$

其中，$\mathbf{P} \in \mathbb{R}^{N\times 3}$ 是电极的绝对位置矩阵。

计算出每个中观区域的区域中心后，我们根据不同的划分融合特征和位置。图3 (a)和图3 (b)中的融合特征和位置分别为$\mathbf{M}^{(1)} \in \mathbb{R}^{7\times F}$ 和$\mathbf{P}^{(1)} \in \mathbb{R}^{7\times 3}$，$\mathbf{M}^{(2)} \in \mathbb{R}^{2\times F}$ 和$\mathbf{P}^{(2)} \in \mathbb{R}^{2\times 3}$。

最后，我们通过虚拟节点插补，将虚拟中观中心与原始电极节点融合，并获得包含重要局部和中观属性的融合特征与位置矩阵。

$$\begin{aligned} \mathbf{X}^{meso} &= \left(concat\left((\mathbf{X}^{local})^T, (\mathbf{M}^{(1)})^T, (\mathbf{M}^{(2)})^T\right)\right)^T, \\ \mathbf{P}^{meso} &= \left(concat\left(\mathbf{P}^T, (\mathbf{P}^{(1)})^T, (\mathbf{P}^{(2)})^T\right)\right)^T. \end{aligned} \tag{8}$$

D. 全局特征聚合

尽管中观划分能够有效缓解节点信息无法远距离传递的问题，但随着节点数量增加，范围更广的介观区域很容易导致信息丢失。

注意力机制在构建全局特征关系方面非常有效 [44]。为了整合远距离节点相关性，我们构建了一种基于注意力的绝对位置依赖特征相关邻接矩阵，用于表征各节点之间可能存在的连接，并消除它们之间的弱连接关系。构建全局电极连接关系后，我们使用图卷积进行全局特征聚合。

1) 全局节点关系：我们将节点位置编码与其空间位置相结合，以更好地表征全局节点关系。完整节点$\mathbf{P}^{meso}$由原始电极节点$\mathbf{P}$ 和虚拟中观节点$\mathbf{P}^{virtual}$组成。由于虚拟节点也具有相应的特征，我们将所有节点的特征与位置编码相加，得到位置增强节点特征，如下所示：

$$\mathbf{X}^{enhanced} = \mathbf{X}^{meso} + embed\left(\mathbf{P}^{meso}\right). \tag{9}$$

之后，我们使用包含 6 个头的多头自注意力计算关系矩阵$\mathbf{G} \in \mathbb{R}^{6\times N'\times N'}$，并利用可学习的权重向量$\mathbf{w} \in \mathbb{R}^{1\times 6}$将$\mathbf{G}$ 融合到最终的注意力关系矩阵$\mathbf{A}^{global} \in \mathbb{R}^{N'\times N'}$中:

$$\mathbf{A}^{global} = \mathbf{wG}. \tag{10}$$

实证表明，密集注意力矩阵会加剧过度平滑，但我们有意保留邻接矩阵中权重最高的 20% 连接，以确保其稀疏性。

2）用于全局表示聚合的图卷积网络：得到基于全局注意力的邻接矩阵 $\mathbf{A}^{global}$后，我们计算相应的拉普拉斯矩阵 $\hat{}\mathbf{L}^{global}$ ，并将其用于图卷积:

$$\mathbf{O}^{(l+1)} = \sigma\left(\hat{\mathbf{L}}^{global}\mathbf{O}^{(l)}\mathbf{W}^{(l)}\right), \tag{11}$$

其中，$\mathbf{O}^{(l)}$ 为输入节点表示，$\mathbf{O}^{(l+1)}$为输出节点表示，初始输入表示 $\mathbf{O}^{(0)}$ 为原始输入特征 $\mathbf{X}^{meso}$。$\mathbf{W}^{(l)}$ 为可学习权重矩阵， σ 为激活函数。

随后，我们将输入介观特征$\mathbf{X}^{meso}$ 与全局图卷积网络的输出$\mathbf{O}^{(1)}$ 拼接起来，得到涵盖局部、介观和全局感知野的特征。

$$\mathbf{X}^{global} = concat\left(\mathbf{X}^{meso}, \mathbf{O}^{(1)}\right) \tag{12}$$

最后，我们将$\mathbf{X}^{global}$ 设为一个三层全连接情绪识别网络的输入，以获得受试者情绪的最终输出。模型实现细节见附录 A。

IV. 实验

本节评估所提出的 PGCN 在三个知名情绪识别数据库 SEED[24], SEED-IV[45],和 SEED-V[46]上的有效性。

A. 数据集与实验方案

为全面评估所提出的 PCGN 的有效性，我们在上述三个数据集上进行了受试者依赖和受试者独立实验；同时进行了预处理和特征提取，以便后续对模型进行客观评估。在受试者依赖实验中，训练数据和测试数据均来自同一位受试者，以评估模型在同一受试者跨时段应用中的有效性；在受试者独立实验中，训练数据和测试数据来自不同受试者，以评估模型在跨受试者应用中的有效性。数据集与实验方案的详细说明见附录 B。所有基线方法的实验结果均摘自相关引文。

B. SEED 上的实验

表 I 展示了 PGCN 及所有基线方法在 SEED数据集上的受试者相关情绪识别准确率，所有基线方法的结果均摘自相应参考文献。SVM 是一种传统的机器学习方法，DBN 和 BiDANN-S 是深度学习方法，而 DGCNN、GCB-net+BLS、RGNN 和 V-IAG 则是基于图卷积网络的方法。

令人鼓舞的是，在受试者依赖的情绪识别任务中，我们的 PGCN 在全频带以及 θ、β 和 γ 波段上取得了最佳情绪识别结果，在 δ 和 α 频段上的表现则略逊于此前表现最佳的模型 V-IAG。据我们所知，情绪识别准确率首次提升至 96.93%。比较不同频带的情绪识别结果可以发现，该模型更善于捕捉高频特征所携带的情绪信息，从而获得更高的准确率，这与许多先前研究的发现一致 [13], [24]。

表 II 展示了 PGCN 和所有基线模型在 SEED数据集上进行被试独立情绪识别的结果。表 II 汇总了基于监督学习和迁移学习的实验结果。

对比结果表明，在基于监督学习的方法中，所提出的 PGCN 取得了最佳结果，比移除域自适应模块后的 RGNN 高出 2.67%。由于迁移学习会使用测试集中的额外数据（不使用测试集标签）进行模型训练，因此监督学习方法的表现明显落后于迁移学习方法；添加域适应模块后，RGNN 的表现比 PGCN 高出 0.71%。然而，在实际的在线情绪识别中，几乎不可能从测试集中获取足够的数据来训练迁移学习模型。

C. SEED-IV 实验

表 III 展示了所提出的 PGCN 在 SEED-IV 上进行情绪识别的结果。在受试者依赖实验中，在相同的实验设置下，PGCN 的准确率比 RGNN 高 2.87%。此外，我们在图 4 中给出了不同会话中不同受试者的受试者依赖结果。结果表明，超过三分之二的受试者准确率高于 80%，且三分之一的准确率高于 90%。相比之下，会话 1 中的情绪识别结果几乎均匀分布在 0.6 至 1 之间，直观地展示了相同实验设置下不同受试者之间存在显著差异。

在受试者无关实验中，除 RGNN 外，PGCN 相较于所有基线方法的表现均提升了 3% 以上。对于未使用域适应（DA）模块的 RGNN，PGCN 的表现也提升了 2.04%；而在 RGNN 中加入 DA 模块后，PGCN 的表现则略低 0.15%。我们发现，加入 DA 模块后，BiHDM 和 RGNN 的表现分别提升了 1.56% 和 2.19%，这表明域适应在减少受试者间分布差异方面具有出色的能力。

D. SEED-V 上的实验

表 IV 展示了所提出的 PGCN 在 SEED-V数据集上进行情绪识别的结果。所有基线方法的实验结果均摘自相应的

表 I SEED数据集上的受试者相关分类准确率（均值/标准差）

方法	δ (1–3 Hz)	θ (4–7 Hz)	α(8–13 Hz)	β (14–30 Hz)	γ (31–50 Hz)	所有频带
支持向量机 [22]	60.50 / 14.14	60.95 / 10.20	66.64 / 14.41	80.76 / 11.56	79.56 / 11.38	83.99 / 9.72
深度置信网络 [24]	64.32 / 12.45	60.77 / 10.42	64.01 / 15.97	78.92 / 12.48	79.19 / 14.58	86.08 / 8.34
DGCNN [10] †	74.25 / 11.42	71.52 / 5.99	74.43 / 12.16	83.65 / 10.17	85.73 / 10.64	90.40 / 8.49
BiDANN-S [47]	76.97 / 10.95	75.56 / 7.88	81.03 / 11.74	89.65 / 9.59	88.64 / 9.46	92.38 / 7.04
GCB-net+BLS [12]	79.98 / 8.93	76.51 / 9.56	81.97 / 11.05	89.06 / 8.69	89.10 / 9.55	94.24 / 6.70
RGNN [13] †	76.17 / 7.91	72.26 / 7.25	75.33 / 8.85	84.25 / 12.54	89.23 / 8.90	94.24 / 5.95
V-IAG [14] †	**81.14 / 9.46**	82.37 / 7.44	**84.51 / 9.68**	92.15 / 8.90	92.96 / 6.19	95.64 / 5.08
PGCN（我们的方法） †	79.62 / 10.53	**83.62/ 6.91**	83.74 / 9.57	**92.33/ 8.66**	**93.05 /5.78**	**96.93/ 5.11**

†根据两个会话的结果计算平均准确率。

表 II SEED数据集上的受试者独立分类准确率（均值/标准差）

	方法	所有频带
迁移学习	TCA [48]	63.64 / 14.88
	DANN [49]	75.08 / 11.18
	BiDANN-S [47]	84.14 / 6.87
	RGNN [13]	85.30 / 6.72
监督学习	支持向量机 [22]	56.73 / 16.29
	DGCNN [10]	79.95 / 9.02
	RGNN（无域适应） [13]	81.92 / 9.35
	PGCN（我们的方法）	**84.59/ 8.68**

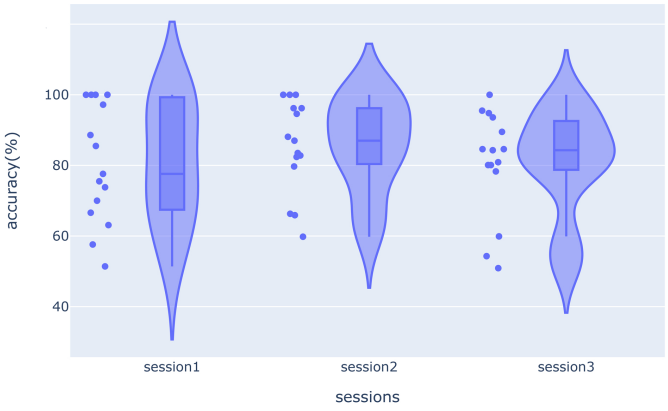


图4. SEED-IV数据集上的受试者依赖情绪识别准确率。

表 III SEED-IV数据集上的受试者依赖和受试者独立分类准确率（均值/标准差）

方法	受试者依赖	受试者独立
支持向量机 [22]	56.61 / 20.05	37.99 / 12.52
深度置信网络 [24]	66.77 / 7.38	- / -
DGCNN [10]	69.88 / 16.29	52.82 / 9.23
BiDANN-S [47]	70.29 / 12.63	65.59 / 10.39
BiHDM [50]	74.35 / 14.09	69.03 / 8.66
RGNN [13]	79.37 / 10.54	73.84 / 8.02
BiHDM 不含域适应 [50]	72.22 / 14.69	67.47 / 8.22
RGNN 不含域适应 [13]	- / -	71.65 / 9.43
PGCN（本文方法）	**82.24/ 14.85**	**73.69/ 7.16**

表 IV SEED-V数据集上的受试者依赖和受试者独立分类准确率（均值/标准差）

方法	受试者依赖	受试者独立
支持向量机 [24]	69.5 / 10.28	- / -
BDAE [51]	79.7 / 4.76	- / -
MD-AGCN [52]	80.77 / 6.61	- / -
PGCN（我们的方法）	**81.69/ 10.57**	**61.78/ 8.59**

引文。BDAE [51] 借助双模态深度自动编码器提取的高层表征特征，提升了情绪识别性能；MD-AGCN [52] 提出了一种多域自适应图卷积网络，融合频域知识与时域知识，充分利用脑电信号的互补信息。可以发现，在被试相关任务中，PGCN 的表现比此前最佳的 MD-AGCN 高出 0.92%；在被试无关任务中，PGCN 的情绪识别准确率达到 61.78%。

五、讨论

本章通过消融实验展示 PGCN 各个模块的作用，并尝试阐明 PGCN 表现出色的原因。我们还对 PGCN 的结果进行了可视化。

A. 消融研究

我们对 PGCN 中的局部、中观和全局模块进行拆分与组合，以展示各模块对情绪识别的影响，结果见表V。在消融实验中，我们仅修改由局部、中观和全局模块组成的特征提取网络，其他部分保持不变。在表V中，

骨干网络表示基于二维电极邻接矩阵的最基础且常用的两层图卷积网络[33], [14], , 并且骨干模块与局部模块不会同时启用。

这三个模块将 PGCN 在 SEED数据集上的情感识别准确率从 92.34% 提高到了 96.93%，在 SEED-IV数据集上的准确率则从 75.94% 提高到了 82.24%；此外，似乎每个模块都作出了积极贡献。下面将对表V中的数据进行更详细的讨论。

(1) 单独引入每个模块都能全面提升模型性能：局部模块在 SEED 和 SEED-IV 数据集上的 Shapley值约为 2%，中尺度模块约为 3%–3.5%，而全局模块在这两个数据集上的 Shapley值分别约为 1% 和 2%。(2) 对比基线与仅中尺度模块可知，中尺度模块能有效提升网络性能，在SEED数据集上提升了 2.57%，在 SEED-IV数据集上提升了 4.77%。我们推测，这种提升可能是因为中尺度模块能够借助先验知识提取中尺度节点之间的判别特征，并通过将提取出的特征与骨干网络的输出相融合，有效提升网络性能。(3) 由于移除中尺度模块由局部模块和全局模块组成，将其与仅局部模块进行比较可见，在局部模块的基础上引入全局模块，只使 SEED 上的情绪识别能力提升了 0.39%，而在 SEED-IV 上则没有带来提升。我们推测，对于基于图卷积网络的模型，堆叠网络层会伴随严重的过平滑问题。为验证这一猜想，我们在图5中进行了更深入的实验。作为对比，仅全局模块使基线提升了约 0.5%，这可能是因为基线中的图卷积网络尚未得到充分训练和优化。

由于中尺度模块包含脑区尺度和半球尺度这两个不同尺度，我们对中尺度模块中的子模块进行了消融，并将结果列于表VI中。

在引入中尺度模块之前，局部模块和全局模块的堆叠使网络具备了相应的局部感知和全局感知，但由于

随着图卷积网络的加深，通过引入 7 区域和 2 区域的中尺度模块，网络获得了中观感知野，同时增加了一些关键的虚拟中观中心，从而提升了拟合能力。

在表V和表VI中，针对PGCN对超参数进行了优化，但其他模型可能存在更优的选择。不过，为了控制变量并减少参数调优，我们尽量保持超参数不变；但这可能会使消融实验呈现出比逐个模型分别优化更显著的改进。

B. PGCN 为何有效？网络架构分析

为进一步探究PGCN为何有效，我们绘制了随着图卷积网络层数增加而变化的折线图，并将其展示在图5和图6中。在此，原始图卷积网络指基于二维电极邻接矩阵、最常用的图卷积网络；对于PGCN的6层网络，我们添加了一个基于注意力的全局尺度层。

我们绘制了图5中节点平滑度随网络层数增加的曲线，以直观展示过平滑问题。在此情况下，节点平滑度通过计算每一层输出特征中节点之间的余弦相似度得出。得益于重新设计的初始化邻接矩阵，与原始图卷积网络相比，PGCN 在局部层的节点平滑度增幅较小 [53]。在中观层，引入虚拟节点后，PGCN 的节点平滑度几乎保持不变，甚至有所下降，同时其感知野更大；而原始图卷积网络的节点平滑度则持续上升。在全局层，全局感知野使 PGCN 的节点平滑度迅速上升，并超过原始图卷积网络。

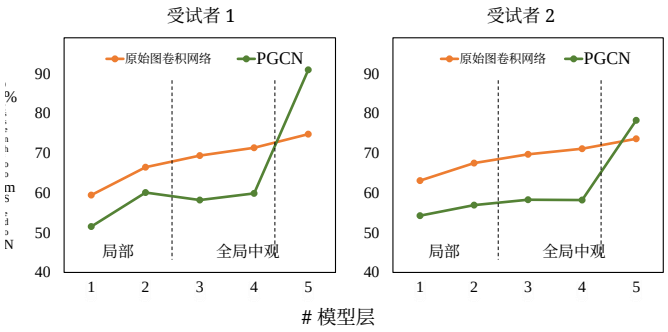


图5. 节点平滑度随网络层数增加的变化曲线。节点平滑度通过计算每一层输出特征中节点之间余弦相似度的均值得出。

图6展示了不同网络层数下网络的平均预测准确率。对于原始图卷积网络，随着网络层数增加，识别准确率在两层时达到最高值92.34%，随后趋于下降，这也是目前大多数用于情绪识别任务的图卷积网络采用两层网络的原因 [33], [14]。对于PGCN，随着网络层数增加，识别准确率在五层时达到最高值96.93%，之后开始下降。

与原始图卷积网络相比，PGCN得益于稀疏图关系推理和局部特征聚合的引入，在浅层网络（第 $\leq$ 2层）中性能高出1.2%。随着网络不断加深（2 $<$ 层 $\leq$ 4），原始图卷积网络中更大的感受野带来的更佳情绪识别效果，逐渐不敌过平滑所导致的高特征相似性问题，性能开始下降；而在PGCN中，得益于网络能够在先验知识的指导下，以高度稀疏的方式聚合介观特征，特征被聚合到虚拟节点，从而扩大感知野，同时不会导致过度的特征

表V SEED和SEED-IV数据集上的受试者相关分类准确率（均值/标准差）消融研究。

方法	骨干网络	局部	中观	全局	SEED	SEED-IV
基线	●	○	○	○	92.34 / 7.68	75.94 / 13.02
仅全局	●	○	○	●	92.93 / 8.35	76.36 / 14.17
仅局部	○	●	○	○	93.69 / 6.12	77.84 / 14.68
仅中尺度	●	○	●	○	94.91 / 6.54	80.71 / 12.72
移除中尺度	○	●	○	●	94.08 / 7.16	77.84 / 13.08
移除全局	○	●	●	○	95.41 / 6.71	80.6 / 13.27
移除局部	●	○	●	●	96.41 / 4.54	80.96 / 14.52
PGCN	○	●	●	●	**96.93 /5.11**	**82.24 /14.85**

每一行中，● 表示启用了该模块，○ 表示屏蔽了该模块。主干模块和局部模块不会同时启用。

表VI 中尺度层在 SEED 和 SEED-IV数据集上的有效性。

7 个区域	2 个区域	SEED	SEED-IV
○	○	94.08 / 7.16	77.84 / 13.08
●	○	94.74 / 6.66	80.34 / 14.71
○	●	94.85 / 5.91	79.77 / 13.16
●	●	**96.93 /5.11**	**82.24 /14.85**

在每一行中，● 表示启用了该模块，○ 表示屏蔽了该模块。

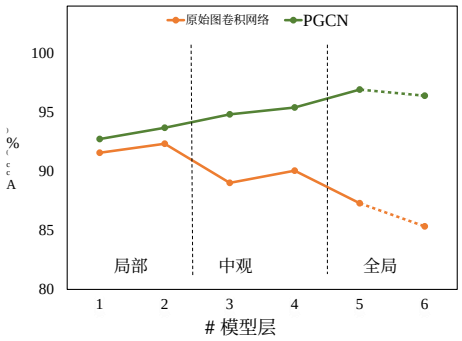


图6. 原始图卷积网络和PGCN在SEED数据集上的平均预测准确率。随着感知野增大，原始图卷积网络的准确率在第二层之后开始下降，而PGCN的拟合能力则持续提升，直到第五层才开始下降。

相似性问题影响电极节点，网络性能持续提升。当网络达到全局感知野（第 > 4层）时，原始图卷积网络中的过平滑问题会更加明显，进一步降低模型的有效性；在PGCN中，通过将电极节点与虚拟节点融合，并采用基于稀疏注意力的邻接矩阵，感知野扩大带来的更佳信息交互仍能与过平滑导致的特征信息过度交互相抗衡，直至网络层数达到5层，模型性能持续提升；但随着网络层数继续增加，过平滑逐渐占据上风，模型性能随之下降。

C. 表示可视化

为了展示情绪识别过程中脑部的激活情况，我们从SEED和SEED-IV数据集中各选取了五名受试者，并在图7中展示了他们学习得到的邻接矩阵对角元素的热力图。邻接矩阵的对角元素最直观地体现了图卷积中节点特征的权重；为便于展示，我们将邻接矩阵的对角元素缩放至0到1之间。

综合两个数据集的结果可以看出，经过学习后，额叶、颞叶和枕叶中的电极获得了较大的权重。具体而言，在三分类SEED数据集中，位于颞叶和枕叶的节点显著激活，位于额叶的部分节点也有激活。在四分类SEED-IV数据集中，颞叶和枕叶的节点显著激活，额叶的激活则更为显著。两个数据集中节点激活情况的差异，可能是由三分类和四分类任务存在一定程度的归纳偏置所致；四分类任务需要同时关注额叶、颞叶和枕叶的信息，才能准确识别情绪。

为展示节点之间的连接，我们从 SEED 和 SEED-IV 数据集中各选取了两名受试者，并在图8中绘制学习得到的邻接矩阵中权重最高的10条连接。与绘制热力图不同，我们移除了对角线元素，并绘制了这些连接。

比较图8中的不同弦图可见，不同受试者的前10个连接差异较大。例如，对于SEED数据集中的受试者1，主要连接集中在额叶和颞叶，枕叶中的连接较少；相比之下，对于受试者2，关键连接位于颞叶和枕叶，而额叶的重要性则有所下降。SEED-IV数据集也存在类似情况。在这两个数据集中，尽管不同受试者之间的关键连接性有所差异，但结合两个数据集的弦图来看，大多数关键连接都与颞叶、额叶和枕叶有关，而这些脑区与情绪和视觉密切相关。

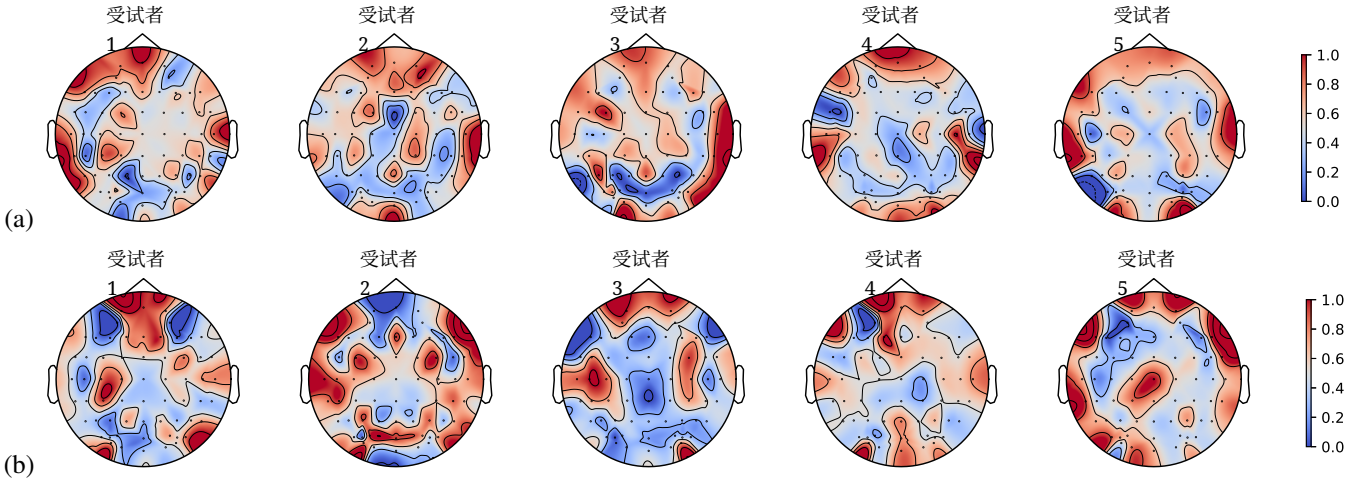


图7. 在（a）SEED和（b）SEED-IV数据集上进行受试者相关情绪识别时，学习得到的邻接矩阵对角元素的热力图；为便于展示，将对角元素压缩至0到1之间。对于大多数受试者，位于额叶、颞叶和枕叶的电极具有更高的自权重。

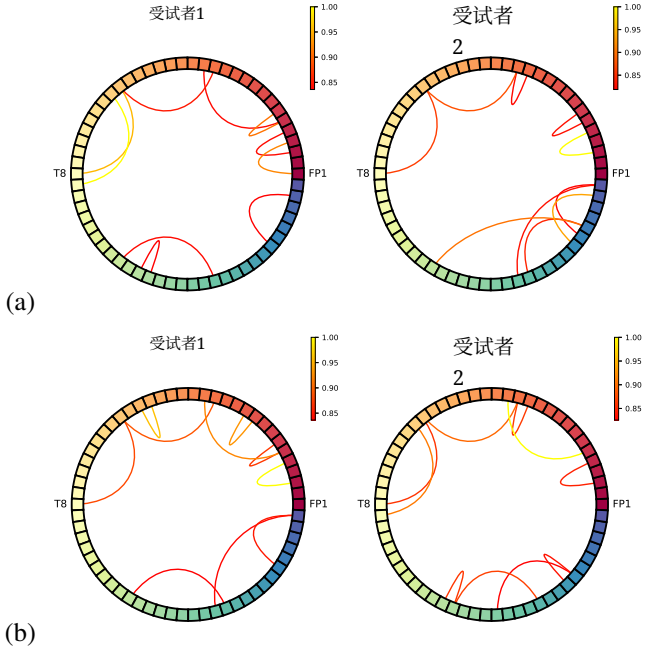


图8. （a）SEED数据集和（b）SEED-IV数据集上学习得到的邻接矩阵的前10个连接；占据最重要连接的电极分布于额叶、颞叶和枕叶。

结合图7和图8可以看出，尽管存在跨受试者和跨数据集的受试者相关差异，位于额叶、颞叶和枕叶的节点特征具有更高的自环权重；不仅如此，这些区域中的节点还通过与其他节点建立强连接，在网络中发挥主导作用，最终实现出色的情绪识别。

六、结论

本文提出了一种金字塔图卷积网络，通过有效平衡GCN感受野扩大的优势与随之而来的过平滑问题，提高情绪识别准确率。在PGCN中，设计了三个独立模块，用于获取不同尺度下电极之间的信息。局部模块主要关注小世界属性；中观模块学习基于先验知识构建的不同脑区之间的连接；全局模块则学习全局节点之间的稀疏连接。随后，有效整合这三个模块学习到的特征，以提升情绪识别效果。所提出的PGCN在三个公开数据集上均取得了最佳结果。未来的工作将重点关注：1）设计优化的中观结构，在进一步减少过平滑的同时获取判别性特征；2）探索更有效的初始脑邻接矩阵；3）尝试引入更多先验知识，以提高情绪识别准确率。

参考文献

[1] R. Cowie、E. Douglas-Cowie、N. Tsapatsoulis、G. Votsis、S. Kollias、W. Fellenz 和 J. G. Taylor，《人机交互中的情绪识别》，*IEEE Signal Processing Magazine*，第18卷，第80页，2001年，第1期，第32页。[2] V. Zotev、A. Mayeli、M. Misaki 和 J. Bodurka，《利用实时同步功能磁共振成像和脑电神经反馈对重度抑郁障碍进行情绪自我调节训练》，*NeuroImage: Clinical*，第27卷，文章编号102331，2020年。[3] J. K. Carpenter、L. A. Andrews、S. M. Witcraft、M. B. Powers、J. A. Smits 和 S. G. Hofmann，《焦虑及相关障碍的认知行为疗法：随机安慰剂对照试验的荟萃分析》，*Depression and Anxiety*，第35卷，第6期，第502–514页，2018年。[4] E. Q. Wu、P.-Y. Deng、X.-Y. Qu、Z. Tang、W.-M. Zhang、L.-M. Zhu、H. Ren、G.-R. Zhou 和 R. S. Sheng，《基于深度学习网络和脑电信号检测飞行员疲劳状态》，*IEEE*认知与发展系统汇刊，2020年。[5] C. D. Katsis、N. Katertsidis、G. Ganiatsas 和 D. I. Fotiadis，《赛车驾驶员情绪识别：一种生物信号处理方法》，*IEEE Transactions on Systems, Man, and Cybernetics-Part A: Systems and Humans*，第38卷，第3期，第502–512页，2008年。[6] Y. Gu、S. Chen 和 I. Marsic，《口语情绪识别的深度多模态学习》，载于*2018 IEEEInternational Conference on Acoustics, Speech and Signal Processing (ICASSP)*。IEEE，2018年，第5079–5083页。[7] F. Noroozi、D. Kaminska、C. Corneanu、T. Sapinski、S. Escalera 和 G. Anbarjafari，《情绪性身体姿势识别综述》，*IEEE*情感计算汇刊，2018年。

[8] N. Zeng、H. Zhang、B. Song、W. Liu、Y. Li 和 A. M. Dobaie，《通过学习深度稀疏自编码器进行面部表情识别》，神经计算，第273卷，第643–649页，2018年。[9] G. Nam、H. Lee、J.-H. Lee 和 J.-W. Hur，《述情障碍中的伪装情绪：情绪加工方面的主观困难与共情痛苦增加》，精神病学前沿，第11卷，2020年。[10] T. Song、W. Zheng、P. Song 和 Z. Cui，《使用动态图卷积神经网络进行脑电情绪识别》，IEEE情感计算汇刊，第11卷，第3期，第532–541页，2018年。[11] K. A. Robbins、J. Touryan、T. Mullen、C. Kothe 和 N. Bigdely-Shamlo，《脑电结果对预处理方法有多敏感：一项基准测试研究》，IEEE神经系统与康复工程汇刊，第28卷，第5期，第1081–1090页，2020年。[12] T. Zhang、X. Wang、X. Xu 和 C. P. Chen，《GCB-Net：图卷积宽网络及其在情绪识别中的应用》，IEEE情感计算汇刊，2019年。[13] P. Zhong、D. Wang 和 C. Miao，《使用正则化图神经网络进行基于脑电图的情绪识别》，IEEE情感计算汇刊，2020年。[14] T. Song、S. Liu、W. Zheng、Y. Zong、Z. Cui、Y. Li 和 X. Zhou，《用于脑电情绪识别的变分实例自适应图》，IEEE情感计算汇刊，2021年。[15] Y. He、Z. J. Chen 和 A. C. Evans，《通过磁共振成像测得的皮层厚度揭示人脑中的小世界解剖网络》，大脑皮层，第17卷，第10期，第2407–2419页，2007年。[16] P. Hagmann、L. Cammoun、X. Gigandet、R. Meuli、C. J. Honey、V. J. Wedeen 和 O. Sporns，《绘制人类大脑皮层的结构核心》，PLoS Biology，第6卷，第7期，文章编号e159，2008年。[17] Y. Ding、N. Robinson、Q. Zeng、D. Chen、A. A. P. Wai、T.-S. Lee 和 C. Guan，《TSception：一种使用脑电进行情绪检测的深度学习框架》，载于2020年国际神经网络联合会议（IJCNN）。IEEE，2020年，第1–7页。[18] V. J. Lawhern、A. J. Solon、N. R. Waytowich、S. M. Gordon、C. P. Hung 和 B. J. Lance，《EEGNet：一种用于基于脑电图的脑机接口的紧凑型卷积神经网络》，神经工程学杂志，第15卷，第5期，文章编号056013，2018年。[19] M. X. Cohen，《神经时间序列数据分析：理论与实践》。麻省理工学院出版社，2014年。[20] A. H. Kemp、R. B. Silberstein、S. M. Armstrong 和 P. J. Nathan，《视觉情绪刺激皮层电生理加工中的性别差异》，神经影像，第21卷，第646页，2004年，第2期，第632页。[21] R.-N. Duan、J.-Y. Zhu 和 B.-L. Lu，《用于基于脑电图的情绪分类的微分熵特征》，载于2013年第六届IEEE/EMBS神经工程国际会议（NER）。IEEE，2013年，第81–84页。[22] J. A. Suykens 和 J. Vandewalle，《最小二乘支持向量机分类器》，神经处理快报，第9卷，第3期，第293–300页，1999年。[23] Z. Liang、S. Oba 和 S. Ishii，《用于人类情绪识别的无监督脑电解码系统》，神经网络，第116卷，第268页，2019年，第257页。[24] W.-L. Zheng 和 B.-L. Lu，《利用深度神经网络研究基于脑电图的情绪识别中的关键频段和通道》，IEEE自主心智发展汇刊，第7卷，第3期，第162–175页，2015年。[25] Y. Yang、Q. J. Wu、W.-L. Zheng 和 B.-L. Lu，《使用带有子网络节点的分层网络进行基于脑电图的情绪识别》，IEEE认知与发展系统汇刊，第10卷，第2期，第408–419页，2017年。[26] S. Alhagry、A. A. Fahmy 和 R. A. El-Khoribi，《使用长短期记忆循环神经网络进行基于脑电图的情绪识别》，Emotion，第8卷，第10期，第355–358页，2017年。[27] W. Tao、C. Li、R. Song、J. Cheng、Y. Liu、F. Wan 和 X. Chen，《通过通道注意力和自注意力进行基于脑电图的情绪识别》，IEEE情感计算汇刊，2020年。[28] D. Zhang、L. Yao、K. Chen、S. Wang、X. Chang 和 Y. Liu，《理解用于基于脑电图的人类意图识别的时空保持表征》，IEEE控制论汇刊，第50卷，第7期，第3033–3044页，2019年。[29] T. N. Kipf 和 M. Welling，《基于图卷积网络的半监督分类》，arXiv预印本 arXiv:1609.02907，2016年。[30] T. Hamaguchi、H. Oiwa、M. Shimbo 和 Y. Matsumoto，《知识库外实体的知识迁移：一种图神经网络方法》，arXiv预印本 arXiv:1706.05674，2017年。[31] L. Zhao、Y. Song、C. Zhang、Y. Liu、P. Wang、T. Lin、M. Deng 和 H. Li，《T-GCN：用于交通预测的时序图卷积网络》，IEEE智能交通系统汇刊，第21卷，第9期，第3848–3858页

[32] M. Defferrard、X. Bresson 和 P. Vandergheynst，《具有快速局部化谱滤波的图卷积神经网络》，神经信息处理系统进展，第 29 卷，2016 年。[33] Y. Ding、N. Robinson、Q. Zeng 和 C. Guan，《Lggnet：从局部-全局-图表示中学习的脑机接口方法》，arXiv 预印本 arXiv:2105.02786，2021 年。[34] M. Jin、H. Chen、Z. Li 和 J. Li，《利用具有可学习电极关系的图卷积网络进行基于脑电图的情绪识别》，载于 2021 年第 43 届 IEEE 医学与生物学工程学会年度国际会议（EMBC）。IEEE，2021 年，第 5953–5957 页。[35] O. Sporns、G. Tononi 和 R. K¨otter，《人类连接组：人脑的结构描述》，PLoS计算生物学，第 1 卷，第 4 期，第 e42 页，2005 年。[36] G. Gong、Y. He、L. Concha、C. Lebel、D. W. Gross、A. C. Evans 和 C. Beaulieu，《利用活体弥散张量成像纤维束追踪绘制人类大脑皮层的解剖连接模式》，大脑皮层，第 19 卷，第 3 期，第 524–536 页，2009 年。[37] E. Bullmore 和 O. Sporns，《脑网络组织的经济性》，《自然综述：神经科学》，第 13 卷，第 5 期，第 336–349 页，2012 年。[38] G. Buzs´aki、C. Geisler、D. A. Henze 和 X.-J. Wang，《中间神经元多样性系列：皮层中间神经元的回路复杂性与轴突布线经济性》，《神经科学趋势》，第 27 卷，193，2004 年 4，186 号。[39] G. Li、M. M¨uller、G. Qian、I. C. D. Perez、A. Abualshour、A. K. Thabet 和 B. Ghanem，《DeepGCNs：使 GCN 像 CNN 一样深入》，IEEE模式分析与机器智能汇刊，2021 年。[40] R. Salvador、J. Suckling、M. R. Coleman、J. D. Pickard、D. Menon 和 E. Bullmore，《人脑功能性磁共振图像的神经生理架构》，大脑皮层，第 15 卷，第 9 期，第 1332–1342 页，2005 年。[41] G. E. Bruder、J. W. Stewart 和 P. J. McGrath，《抑郁障碍中的右脑与左脑：行为、电生理学和神经影像学发现的临床与理论意义》，《神经科学与生物行为综述》，第 78 卷，第 178–191 页，2017 年。[42] K. H. Jawabri 和 S. Sharma，《生理学：大脑皮层功能》，2019 年。[43] W.-L. Zheng、J.-Y. Zhu 和 B.-L. Lu，《识别脑电情绪识别中的时间稳定模式》，IEEE情感计算汇刊，第 10 卷，第 3 期，第 417–429 页，2017 年。[44] P. Veli˘ckovi´c、G. C ucurull、A. Casanova、A. Romero、P. Lio 和 Y. Ben- gio，《图注意力网络》，arXiv 预印本 arXiv:1710.10903，2017 年。[45] W.-L. Zheng、W. Liu、Y. Lu、B.-L. Lu 和 A. Cichocki，《Emotionmeter：用于识别人类情绪的多模态框架》，IEEE控制论汇刊，第 49 卷，第 3 期，第 1110–1122 页，2018 年。[46] W. Liu、J.-L. Qiu、W.-L. Zheng 和 B.-L. Lu，《多模态深度学习模型在多模态情绪识别中的识别性能与鲁棒性比较》，IEEE认知与发展系统汇刊，2021 年。[47] Y. Li、W. Zheng、Y. Zong、Z. Cui、T. Zhang 和 X. Zhou，《一种用于脑电情绪识别的双半球域对抗神经网络模型》，IEEE情感计算汇刊，2018 年。[48] S. J. Pan、I. W. Tsang、J. T. Kwok 和 Q. Yang，《通过迁移成分分析实现域适应》，IEEE神经网络汇刊，第 22 卷，第 2 期，第 199–210 页，2010 年。[49] Y. Ganin、E. Ustinova、H. Ajakan、P. Germain、H. Larochelle、F. Lavi-olette、M. Marchand 和 V. Lempitsky，《神经网络的域对抗训练》，《机器学习研究期刊》，第 17 卷，第 1 期，第 2096–2030 页，2016 年。[50] Y. Li、L. Wang、W. Zheng、Y. Zong、L. Qi、Z. Cui、T. Zhang 和 T. Song，《一种用于脑电情绪识别的新型双半球差异模型》，IEEE认知与发展系统汇刊，第 13 卷，第 2 期，第 354–367 页，2020 年。[51] L.-M. Zhao、R. Li、W.-L. Zheng 和 B.-L. Lu，《从脑电图和眼动信号中分类五种情绪：互补表示特性》，载于 2019年第9届IEEE/EMBS神经工程国际会议（NER）。IEEE，2019 年，第 611–614 页。[52] R. Li、Y. Wang 和 B.-L. Lu，《一种用于基于脑电图的情绪识别的多域自适应图卷积网络》，载于第29届ACM多媒体国际会议论文集，2021 年，第 5565–5573 页。[53] D. Chen、Y. Lin、W. Li、P. Li、J. Zhou 和 X. Sun，《从拓扑视角衡量并缓解图神经网络的过平滑问题》，载于AAAI人工智能会议论文集，第 34 卷，第 04 期，2020 年，第 3438–3445 页。

附录 A

本文使用 PyTorch 构建 PGCN，并将其部署在 2080TI GPU 上。局部模块包含两层图卷积网络，输入尺寸为 62 × 5 ，输出尺寸为 62 × 30；中观模块包含两层网络，输出尺寸为 71 × 30；全局网络包含一层图卷积网络，输出尺寸为 71 ×70；情绪识别网络包含一个 3 层全连接网络。模型优化方面，我们使用 AdamW优化器和预热，将学习率设为 1e-2，批量大小设为 64。我们使用平均准确率（ACC）和标准差（STD）评估模型。

附录 B

*1）SEED*数据集：SEED数据集收集了15名受试者（7名男性和8名女性）观看具有三种不同情绪倾向——负面、正面和中性——的电影片段时的脑电图情绪数据。每名受试者进行了三次脑电数据采集，每次会话包含15个具有不同情绪的电影片段。每个电影片段对应一个试次，每个试次包括5秒的提示、4分钟的电影片段、45秒的自我评估和15秒的休息时间。

在受试者依赖实验中，我们遵循了 [24], [10], [47], 的实验设置：对于每名受试者，使用同一会话中的前九个试次作为训练集，后六个试次作为测试集，并计算所有受试者在两个会话上的均值和标准差 [24], [13], [14]。在受试者无关实验中，我们遵循了 [10], [47] 中的实验设置，并实施留一受试者交叉验证，计算所有受试者在全部三个会话上的均值和标准差。

2) SEED-IV 数据集： SEED-IV数据集从15名受试者（7名男性和8名女性）中采集了脑电图情绪数据，这些受试者观看了包含四种情绪倾向的电影片段：中性、悲伤、恐惧和快乐。每名受试者在三个会话中观看了24个电影片段，每个电影片段对应一个试次，每个试次持续约2分钟。

在受试者依赖实验中，我们遵循了 [50], [13], 的实验设置；对于每名受试者，为确保数据平衡，我们首先将每个会话中每种情绪数据的最后两个试次留作测试集，并将剩余的16个试次用作训练集。在受试者无关实验中，我们遵循了 [50], [13]的实验设置，并采用留一受试者交叉验证。在评估结果时，我们计算了三次会话中所有受试者的平均准确率。

3) SEED-V 数据集： SEED-V数据集从16名受试者（6名男性和10名女性）中采集了脑电数据，包含五种情绪倾向：快乐、厌恶、中性、恐惧和悲伤。每名受试者在三个会话中观看了15个电影片段。

在受试者依赖实验中，我们遵循先前的实验设置 [51], [52], ，使用前十个试次的数据作为训练集，最后五个试次作为测试集。对于受试者无关实验，我们同样采用留一法实验方法。我们分别计算了两种实验中所有受试者在三个会话上的准确率和标准差。