

分类号: TP391

密 级: 公开

学校代码: 10363

学 号: 2220910107



安徽工程大学

Anhui Polytechnic University

硕士学位论文

题 目 基于深度学习的脑电数据分类
方法研究

论 文 作 者 朱 耀

校 内 导 师 陈乃金 教授

校 外 导 师 张静涛 部长

专业学位类别 计算机技术

研究方向 (领域) 数据分析与知识工程

论文提交日期: 2025 年 5 月 9 日

分类号：TP391

密 级：公开

单位代码：10363

学 号：2220910107

题 目 基于深度学习的脑电数据分类方法研究

英文并列

题 目 **Research on the Classification Method of EEG Data
based on Deep Learning**

论文作者： 朱耀

校内导师： 陈乃金教授

校外导师： 张静涛部长

专 业： 计算机技术


研究方向： 数据分析与知识工程

论文答辩日期： 2025 年 5 月 10 日

安徽工程大学学位论文原创性声明

本人郑重声明：我恪守学术道德，崇尚严谨学风。所呈交的学位论文，是本人在导师的指导下，独立进行研究工作所取得的成果。除文中已明确注明和引用的内容外，本论文不包含任何其他个人或集体已经发表或撰写过的作品及成果的内容。论文为本人亲自撰写，我对所写的内容负责，并完全意识到本声明的法律后果由本人承担。

学位论文作者签名：



日期：2025 年 5 月 9 日

安徽工程大学学位论文版权使用授权书


学位论文作者完全了解学校有关保留、使用学位论文的规定，同意学校保留并向国家有关部门或机构送交论文的复印件和电子版，允许论文被查阅或借阅。本人授权安徽工程大学可以将本学位论文的全部或部分内容编入有关数据库进行检索，可以采用影印、缩印或扫描等复制手段保存和汇编本学位论文。

保密 ☐，在_____年解密后适用本版权书。

本学位论文属于


不保密 ☐。

学位论文作者签名：



日期：2025 年 5 月 9 日

指导教师签名：



日期：2025 年 5 月 9 日

基于深度学习的脑电数据分类方法研究

摘 要

随着深度学习与人工智能技术的发展,脑电数据分类成为医学、心理学等领域研究的关键问题。情感计算领域所采用的信号大致可分为非生理信号(如面部表情、语音)和生理信号(如脑电、心电)两类。相较于非生理信号,脑电生理信号具有难以伪装、较好的时间分辨率等特点,可通过较为准确脑电信号分类,实现神经性疾病辅助诊断、精神状态监测等目的,所以对其进行分类研究具有重要的理论和实践意义。目前,国内外研究机构针对脑电数据分类问题相关研究方法较多,通过研究发现,现有的方法在缓解过拟合和梯度消失、优化长距离依赖、多特征融合等方面略显不足,为此本论文对该类问题展开研究,具体研究工作如下:

(1) 针对脑电数据二分类中过拟合和梯度消失问题,提出一种自注意力的混合神经网络分类算法,该算法采用微分熵特征矩阵的脑电信号提取方法,以实现时空特征的更优整合,然后采用卷积神经网络来提取关键的空间特征,以展现不同电极间的相互关系,其次通过自注意力机制,模型进一步精炼时间特征,并结合双向长短期记忆神经网络来深入挖掘序列中的时间依赖性,从而提升了模型的准确率和鲁棒性。最后通过引入残差连接,减少梯度消失、过拟合等情况。在 DEAP 数据集上的实验结果表明,模型在效价和唤醒分类准确度达到了 96.75%和 94.95%,说明提出的算法具有可行性。

(2) 针对脑电数据的三、四分类长距离依赖和动态变化建模时存在局限性问题,提出了一种基于动态时空图卷积注意力网络分类算法,该算法结合了动态图卷积神经网络和多头注意力机制的优点,同时融合了位置编码和软阈值正则化技术,从多个角度改进了情绪识别性能。首先,动态图卷积模块通过 Chebyshev 多项式构造图邻接矩阵,捕获电极通道间的复杂关系,学习全局和局部空间特征,并加入残差连接以增强信息流动;然后,Transformer 编码器在动态图卷积网络提取的特征基础上,结合多头注意力机制和位置编码,建模脑电信号的时间动态特性,增强对长序列数据的表征能力。最后,通过全局特征池化结合多层非线性全连接网络,进一步提升情绪分类精度。在 SEED 和 SEED-IV 数据集上进行独立、依赖实验评估模型,独立被测实验准确率分别为 82.33%和 61.36%,依赖实验准确率分别为 98.54%和 90.25%。

(3) 针对脑电数据的三、四分类多特征分类问题,提出了一种多特征融合分类算法,通过脑电数据微分熵,功率谱密度,差分不对称,理性不对称等多特征提取和组合的方法来提高多特征分类的准确性和鲁棒性,同时通过挑选特征和组合,对组合后的特征集进行分类,获得了性能较优的特征组合。

关键字: 深度学习, 脑电数据分类, 自注意力机制, 混合神经网络, 动态时空图卷积网络, 多特征提取

Research on EEG Data Classification Method Based on Deep Learning

ABSTRACT

With the development of deep learning and artificial intelligence technologies, the classification of electroencephalogram (EEG) data has become a key issue in the research of medical, psychological and other fields. The signals used in the field of affective computing can be roughly divided into two categories: non-physiological signals (such as facial expressions and voice) and physiological signals (such as EEG and electrocardiogram signals). Compared with non-physiological signals, EEG signals have characteristics such as being hard to fake and having better temporal resolution. Through relatively accurate classification of EEG signals, purposes such as auxiliary diagnosis of neurological diseases and mental state monitoring can be achieved. Therefore, research on their classification holds important theoretical and practical significance. Currently, numerous research methods have been proposed by domestic and foreign institutions for the classification of EEG data. However, studies have shown that existing approaches still have shortcomings in mitigating overfitting and gradient vanishing, optimizing long-range dependencies, and achieving effective multifeature fusion. Therefore, this

paper conducts in-depth research on these issues, with the specific research work outlined as follows:

(1) For the issues of overfitting and vanishing gradient in binary classification of EEG data, a self-attention hybrid neural network classification algorithm was proposed, which used the EEG signal extraction method of differential entropy feature matrix to achieve better integration of spatiotemporal features, and then the convolutional neural network was used to extract the key spatial features to show the interrelationship between different electrodes, and secondly, through the self-attention mechanism, the model further refined the time features, and combined with the bidirectional long short-term memory neural network to dig deep into the time dependence in the sequence. As a result, the accuracy and robustness of the model are improved. Finally, by introducing residual connection, the gradient disappearing, overfitting and other conditions are reduced. Experimental results on the DEAP dataset show that the model achieved classification accuracies of 96.75% and 94.95% for valence and arousal classification, respectively, demonstrating the feasibility of the proposed algorithm.

(2) There are limitations in modeling long-distance dependencies and dynamic changes for three-class and four-class classification of EEG data, a single-feature classification algorithm based on dynamic spatiotemporal graph convolutional attention network was proposed, which combined the

advantages of dynamic graph convolutional neural network and multi-head attention mechanism, and integrated position coding and soft threshold regularization technology to improve the performance of emotion recognition from multiple perspectives. Firstly, the dynamic graph convolution module constructs a graph adjacency matrix through Chebyshev's polynomial to capture the complex relationships between electrode channels, learn global and local spatial features, and add residual connections to enhance information flow. Then, on the basis of the features extracted by the dynamic graph convolutional network, the Transformer encoder combined with the multi-head attention mechanism and position coding to model the temporal dynamic characteristics of EEG signals and enhance the representation ability of long sequence data. Finally, the accuracy of sentiment classification is further improved by combining global feature pooling with multi-layer nonlinear fully connected networks. On the SEED and SEED-IV datasets, independent and dependent experiments were conducted to evaluate the model, achieving accuracies of 82.33% and 61.36% in independent experiments, and 98.54% and 90.25% in dependent experiments, respectively.

(3) Aiming at the problem of three-four classification and multi-feature classification of EEG data, a multi-feature fusion classification algorithm was proposed, which improved the accuracy and robustness of multi-feature classification by extracting and combining multiple features

such as differential entropy, power spectral density, differential asymmetry, and rational asymmetry of EEG data.

Zhu Yao (Computer Technology)

Supervised by Prof. Chen Naijin, Zhang Jingtao

KEY WORDS: deep Learning, classification of EEG data, self-attention mechanism, hybrid neural networks, dynamic spatiotemporal graph convolutional network, multi-feature extraction

目 录

摘 要	I
ABSTRACT	III
第 1 章 绪论	1
1.1 研究背景及意义	1
1.2 论文的研究内容和组织结构	2
1.2.1 本文的研究内容	2
1.2.2 本文的组织结构	3
1.3 本章小结	4
第 2 章 国内外研究现状	5
2.1 引言	5
2.2 基于深度学习的脑电数据分类	5
2.3 基于特征提取的脑电数据分类	10
2.4 本章小结	15
第 3 章 自注意力机制混合神经网络脑电数据分类算法	16
3.1 引言	16
3.1.1 微分熵	16
3.1.2 残差连接	17
3.1.3 自注意力机制	18
3.2 自注意力的混合神经网络模型	18
3.2.1 卷积神经网络	18
3.2.2 双向长短期记忆神经网络	19
3.2.3 自注意力的混合神经网络结构	20
3.3 实验设计与结果分析	21
3.3.1 实验数据集	21
3.3.2 实验参数设置	23
3.3.3 实验结果与分析	23
3.4 本章小结	29
第 4 章 动态时空图卷积注意力网络脑电数据分类算法	30
4.1 引言	30
4.1.1 特征提取	30
4.1.2 动态图卷积神经网络	30
4.1.3 转换器	31
4.1.3 多头注意力	32
4.2 动态时空图卷积注意力网络模型架构	33

4.3 实验设计与结果分析	35
4.3.1 实验数据集	35
4.3.2 实验设置	37
4.3.3 验结果与分析	37
4.4 本章小结	45
第 5 章 脑电数据的多特征融合分类算法	46
5.1 引言	46
5.2 脑电特征概述	46
5.2.1 时域特征	46
5.2.2 频域特征	46
5.2.3 空域特征	47
5.3 实验设计	48
5.4 实验结果与分析	48
5.4.1 多特征组合	48
5.4.2 混淆矩阵	50
5.5 本章小结	52
第 6 章 总结和展望	54
6.1 工作总结	54
6.2 论文不足与未来展望	55
6.2.1 论文不足	55
6.2.2 未来展望	55
参考文献	56
攻读学位期间参与的科研项目	62
攻读学位期间发表的学术成果	62
致 谢	63

第一章 绪论

1.1 研究背景及意义

情感作为人类心理和生理反应的综合体现，在日常生活中扮演着至关重要的角色。近年来，随着人工智能技术的飞速发展，情感计算已成为该领域的一个重要研究方向。人类情感的复杂性体现在其与神经活动和化学反应的紧密联系上，尽管现有理论尚无法全面解释情感现象，但离散情感模型和维度情感模型为科研人员提供了量化和区分不同情感状态的方法。1971 年 Ekman 和 Fresian 定义六种离散情感，即厌恶、伤心、害怕、高兴、惊奇和生气^[1]，离散模型为情感计算领域的研究提供了直观的情感表示方式。1974 年 Mehrabian 和 Russell 提出了效价，唤醒和支配情感模型来表示人类情感^[2,3]，该模型为情感计算领域的研究提供了连续的情感表示方式。

随着科学技术的不断发展与革新，研究人员逐渐发现，情感的产生与变化与大脑皮层的活动密切相关。这一发现，为基于脑电 (Electroencephalography, EEG) 信号进行情感分类研究提供了坚实的科学基础。EEG 是一种通过在人的头皮表面放置电极设备，记录下一系列时间分辨率高、动态复杂且非线性的脑电信号^[4]。由于 EEG 信号的采集过程相对简便、成本较低，同时能够直观地反映大脑神经元的电活动状态，不仅包含人类大脑的神经活动信息，还蕴含了丰富的情感特征信息，因此成为研究者从大脑神经活动根源上深入研究情感的重要手段。这些优势使得 EEG 信号在情感研究领域得到了广泛关注和深入研究。基于 EEG 数据的分析应用在医学、教育和军事等领域有着广阔的前景。

在 EEG 数据的分类领域，传统机器学习方法面临一些弊端。首先，传统方法通常依赖于人工特征提取，这不仅耗时且容易受到特征选择的限制，可能导致信息丢失或不足。其次，传统算法如支持向量机、随机森林^[5]等通常需要大量的预处理和特征工程。而深度学习方法通过自动学习数据的高层次特征，能够处理原始 EEG 信号，减少人工干预，提升分类精度。深度学习模型如卷积神经网络和递归神经网络具有强大的模式识别能力，能够在多层次上学习 EEG 信号中的时空依赖性，表现出更强的泛化能力，尤其在大数据和复杂任务中展现出优越性。

因此,基于深度学习的脑电数据的情绪分类识别研究具有巨大的应用价值和现实意义。

1.2 论文的研究内容和组织结构

1.2.1 本文的研究内容

本文针对脑电情感识别任务,通过构建深度学习模型对脑电信号进行建模,提出有效的网络模型来解决问题。具体而言,本文主要进行了以下研究工作:

(1)提出了一种融合自注意力机制的混合神经网络(hybrid neural network, HNN)模型。本模型采用微分熵特征矩阵的脑电信号提取方法^[6],以实现时空特征的更优整合,然后采用卷积神经网络(convolutional neural networks, CNN)来提取关键的空间特征,以展现不同电极间的相互关系,其次通过自注意力机制,模型进一步精炼时间特征,并结合双向长短期记忆网络(bidirectional long short-term memory networks, BLSTM)来深入挖掘序列中的时间依赖性,从而提升了模型的准确率和鲁棒性。最后通过引入残差连接,减少梯度消失、过拟合等情况。

(2)提出了一种动态时空图卷积注意力网络模型,用于 EEG 情绪识别任务。该模型结合了动态图卷积神经网络(dynamic graph convolutional neural network, DGCNN)和多头注意力机制的优点,同时融合了位置编码和软阈值正则化技术,从多个角度改进了情绪识别性能。具体而言:DGCNN 模块通过 Chebyshev 多项式构造图邻接矩阵,捕获 EEG 通道间的复杂关系,学习全局和局部空间特征,并加入残差连接以增强信息流动。随后 Transformer 编码器在 DGCNN 提取的特征基础上,结合多头注意力机制和位置编码,建模 EEG 信号的时间动态特性,增强对长序列数据的表征能力。最后通过全局特征池化结合多层非线性全连接网络,进一步提升情绪分类精度。

(3)提出一种多特征提取与组合方法,提升脑电数据分类的准确性与效率。在 EEG 情感研究中,许多研究者通常提取一种或几种时频特征或空间域特征,且对脑电数据特征的分析仍显不足。因此,本研究计划通过提取并结合时频域与空间域的特征,筛选出能够有效区分情感类别的特征,并对这些特征进行优化组合,以寻找到性能最佳的特征集。

本文总体框架图如 1-3 所示。




图 1-3 全文总体框架

Figure 1-3 The overall framework of the full text

1.2.2 本文的组织结构

本文分为 6 个章节来阐述，具体的论文章节安排如下：

第 1 章，绪论。说明了基于脑电数据分类方法的研究背景，以及研究其意义，之后概括本课题的所用数据集和研究要点。

第 2 章，国内外现状。主要围绕深度学习和特征提取的脑电数据分类两个方面的研究进展来阐述。

第 3 章，自注意力机制混合神经网络脑电情绪分类算法，提出了一种基于注意力机制的混合神经网络用于脑电信号分类，模型包括卷积神经网络、双向长短期记忆网络、残差连接和自注意力机制，成功优化了模型的泛化能力，并有效解决了过拟合和梯度消失问题。

第 4 章，动态时空图卷积注意力网络的脑电数据分类算法，该模型巧妙融合了 DGCNN 与 Transformer 架构，既显著提升了学习复杂模式的能力，又增强了模型对不同图结构的灵活适应度。

第 5 章，脑电数据的多特征融合分类算法，通过多特征融合的方法来提高对脑电数据分类的精度。

第 6 章，总结和展望。针对本课题的研究成果、论文中的不足之处做出总结，以及对未来的展望。

1.3 本章小结

首先，在 1.1 节中阐述了本研究的研究背景及意义，为后续研究的开展奠定了基础。接着，在 1.2 小节，简明扼要地勾勒出了本文具体的研究内容，同时清晰呈现了包括各主要章节在内的整体架构布局。

第 2 章 国内外研究现状

2.1 引言

EEG 作为一种非侵入式的大脑活动监测技术，自 20 世纪初期被发现以来，一直是神经科学和生物医学工程领域的重要研究工具。EEG 信号携带了大脑活动的大量信息，对于理解大脑功能、诊断神经系统疾病以及开发脑-机接口系统具有重要的应用价值。然而，由于脑电信号的非线性、非平稳性和复杂性，如何有效地从原始 EEG 信号中提取有用的特征，一直是研究人员面临的关键挑战^[3]。

近年来，随着人工智能技术的飞速发展，神经网络作为一种强大的数据驱动模型，已经在脑电信号特征提取和分类中显示出巨大的潜力。神经网络能够学习数据的复杂模式，自动提取特征，从而在脑电信号的解码和识别中取得了显著的进展。国际上，众多研究团队致力于开发新型神经网络架构和优化算法，以提高脑电信号特征提取的准确性和效率。在国内，基于神经网络的脑电信号处理也得到了广泛的关注，众多高校和研究机构在这一领域取得了丰硕的研究成果。然而，尽管国内外的研究都在不断深入，脑电信号特征提取算法仍面临着诸如计算复杂度高、模型泛化能力弱、特征解释性不足等问题。

下面从深度学习的脑电数据研究和特征提取的脑电数据研究两个层面，分别阐述。

2.2 基于深度学习的脑电数据分类

2018 年及以前，LI 等人^[7]提出了一种新型神经网络模型，即双半球域对抗神经网络（bi-hemisphere domain adversarial neural network, BiDANN）模型，用于 EEG 情绪识别。BiDANN 由一个全局域鉴别器和两个局部域鉴别器组成，它们与分类器相互对抗，以提取每个半球的情绪特征。同时，该模型旨在减少源域与目标域在各半球间可能存在的域差异，从而提升识别模型的泛化能力。在 SEED 数据库上进行了大量的实验，实验结果表明，提出模型在 EEG 情绪识别方面取得了最佳性能。WANG 等人^[8]提出了一种名为广泛动态图学习系统（broad dynamical graph learning system, BDGLS）的新型架构，用于处理 EEG 信号并进

行情绪识别。BDGLS 融合了 DGCNN 和广泛学习系统 (broad learning system, BLS) 的优点, 在非欧几里得空间提取特征, 同时通过随机生成节点来优化连接权重。在数据集 SEED 上进行的实验表明, 与其他方法相比, BDGLS 实现了最佳的识别准确率。

2019 年, MA 等人^[9]提出了一种用于情绪识别的多模态残差长短期记忆 (multimodal residual long-short-term memory, MMResLSTM) 网络。该网络在每个 LSTM 层的模态间共享权重, 以捕捉 EEG 与其他生理信号的相关性。它结合残差网络的空间快捷路径与 LSTM 的时间快捷路径, 从而高效学习情绪相关的高级特征。基于公开数据集 DEAP 对所提出的网络进行了评估。实验结果表明, 所提出的 MMResLSTM 网络取得了良好的效果, 唤醒分类准确率为 92.87%, 效价分类准确率为 92.30%。田莉莉等人^[10]提出了一种基于一维 CNN 的脑电信号情感识别方法。该方法利用 CNN 自动提取脑电信号的情感特征, 避免了传统方法中人工构建特征的繁琐过程。同时, 改进了 CNN 的网络结构和训练过程, 提高模型的性能和泛化能力。最后, 使用随机森林分类器对提取的特征进行分类, 实验结果表明, 该方法在 SEED 数据集上取得了 94.7% 的情感分类准确率, 证明了该方法的有效性和鲁棒性。

2020 年, DU 等人^[11]提出了一种深度学习方法, 通过自动提取不同电极脑电信号间的功能关系来获取空间特征。该模型为基于注意的带域鉴别器的长短期记忆 (Attention-based LSTM with Domain Discriminator, ATDD-LSTM), 该架构具有两个显著特征: (1) ATDD-LSTM 通过在 LSTM 提取的特征向量上应用注意力机制, 自动筛选关键 EEG 通道, 以增强情绪识别的针对性, 使模型关注与特定情绪相关的通道; (2) 为减少不同会话或个体间的特征分布差异, ATDD-LSTM 采用域鉴别器调整数据表示空间, 以生成更具通用性的域特征。在三个公开的 EEG 情绪数据库 (DEAP、SEED 和 CMEED) 上对所提出的 ATDD-LSTM 模型进行了情绪识别测试, 实验结果取得了优异的表现。TAO 等人^[12]提出了一种基于注意机制的卷积循环神经网络 (attention-based convolutional recurrent neural network, ACRNN), 用于从 EEG 信号中提取更多判别性特征, 提高情绪识别准确率。首先, ACRNN 采用通道注意机制, 自适应调整不同通道的权重, 并利用 CNN 提取 EEG 信号的空间特征。其次, 为探索 EEG 信号的时间信息,

将扩展自注意力集成至 RNN，以基于信号的内在相似性重新编码其重要性。在 DEAP 和 DREAMER 数据库上进行了广泛的实验。实验结果表明，提出的 ACRNN 优于最先进的方法。陈景霞等人^[13]提出了两种新型的混合神经网络模型，即级联卷积-循环神经网络、级联卷积-卷积神经网络，在 DEAP 上进行的分类实验结果显示，这两种模型的分类准确率分别为 93.15% 和 92.37%。这两种混合模型相较于单一模型，在学习和利用脑电信号的时空相关性方面较具优势，提高了情感分类的准确率。

2021 年，LI 等人^[14]提出了一种名为自组织图神经网络（self-organized graph neural network, SOGNN）的新型模型，用于跨受试者脑电图情感识别。SOGNN 通过自组织图构建模块动态地学习 EEG 情感信号之间的通道间关系，并利用图卷积层提取局部和全局连接特征，从而提高跨受试者情感识别的性能。在 SEED 和 SEED-IV 数据集上进行的实验结果表明，SOGNN 能够实现最先进的情感识别性能，并优于现有的方法。FDEZ 等人^[15]提出基于分层标准化方法来提高基于脑电图的跨被试情绪识别准确率的方法。该方法对比了传统的批标准化方法和分层标准化方法，并分析了不同特征提取方法和标记方法对识别准确率的影响。在 SEED 和 SEED-IV 数据集上进行的实验结果表明，分层标准化方法能够有效减少被试之间的差异性，从而提高跨被试情绪识别的准确率。LIU 等人^[16]提出了一种动态经验卷积神经网络（dynamic empirical convolutional neural network, DECNN）的 EEG 信号情绪识别算法，旨在解决主观独立情绪识别的挑战。该算法结合了动态微分熵（dynamic differential entropy, DDE）特征提取方法和卷积神经网络，并分析了与情绪分类相关的脑区，找到了与情绪识别相关的关键电极。实验结果表明，DECNN 算法的准确率比现有方法提高了 3.53%，并且能够有效地识别不同受试者的情绪状态，为情感计算和脑机接口的发展提供了新的思路和方法。

2022 年，ZHONG 等人^[17]提出了一种用于基于 EEG 的情绪识别的正则化图神经网络（regularized graph neural network, RGNN）。RGNN 结合大脑不同区域的生物拓扑结构，以捕捉 EEG 通道间的局部与全局关系。此外，提出了两个正则化方法：节点域对抗训练（node-wise domain adversarial training, NodeDAT）用于优化跨受试者的 EEG 变化，情绪感知分布学习（emotion-aware distribution

learning, EmotionDL) 则用于缓解噪声标签对模型的影响。在两个公共数据集 SEED 和 SEED-IV 上进行的大量实验表明, 该模型在大多数实验环境中的性能优于最先进的模型。DU 等人^[18]提出了一种名为多维图卷积网络 (multidimensional graph convolution network, MD-GCN) 的跨受试者脑电图情绪识别方法。通过预设邻接矩阵和图卷积神经网络, 有效融合 EEG 信号的时间和空间特征, 在 SEED 和 SEED-IV 数据集上取得了优异的识别准确率。LIU 等人^[19]提出了一种名为 TCACNet 的新型卷积神经网络, 用于基于 EEG 的运动想象分类。TCACNet 结合了全局和局部子网络来处理 EEG 信号, 并通过时间注意机制和通道注意机制来克服 EEG 信号的时变性和任务相关信息在电极通道之间分布不均匀的挑战。实验结果表明, TCACNet 在两个公开数据集上分别实现了 11.4% 和 7.9% 的分类准确率提升, 并且在数据效率方面也优于其他模型。LIU 等人^[20]提出了一种基于最小生成树 (minimum spanning tree, MST) 的图神经网络 (graph neural network, GNN) 方法, 用于从 EEG 信号中进行情感分类。该方法通过捕捉不同情感状态下的脑网络拓扑特征 (如节点度、中心性和偏心率), 结合层次聚合机制和改进的图嵌入提取, 提高了分类性能。在 DEAP 数据集上的实验表明, 该模型在多频段 (尤其是 Theta、Lower Beta 和 Gamma) 情感分类任务中优于传统方法, 其中 Lower Beta 频段的分类准确率达到 92%。研究进一步揭示了情感的多频段交互特性, 为理解情感的神经机制和 EEG 信号的情感分类提供了新的方法和视角。柳长源等人^[21]结合 CNN 和长短期记忆网络 (long short term memory, LSTM) 的优势, 构建了递归卷积神经网络长短期记忆 (recurrent convolutional neural network long short term memory, RCNN-LSTM) 脑电情感信号分类模型, 该模型在 DEAP 数据集上的测试结果显示, 其平均准确率为 96.63%。

2023 年, ZHONG 等人^[22]提出了一种名为双侧半球不对称注意力网络 (bihemispheric asymmetric attention network, Bi-AAN) 的新型深度学习模型。该模型结合了 Transformer 架构和大脑左右半球不对称性的特性, 并完全依赖于注意力机制来提取情感特征。通过将不同的注意力权重分配给左右半球, Bi-AAN 可以模拟两个半球之间不同的情感反应。在 DEAP 和 DREAMER 数据集上的实验结果表明, Bi-AAN 在情感识别任务中优于传统的机器学习算法和最先进的深度学习方法, 证明了其有效性和优越性。ZHANG 等人^[23]提出了一种基于深度强

化学习的无监督时间感知采样网络（time-aware sampling network, TAS-Net），TAS-Net 能够自适应地检测关键情绪片段，并忽略不相关和误导性的部分，从而提高无监督情绪识别的准确性。在三个公共数据集（SEED, DEAP 和 MAHNOB-HCI）上进行了大量实验，使用留一交叉验证进行情感识别，结果证明了所提出的方法优于其他的无监督情感识别方法。

2024 年, JIN 等人^[24]提出了金字塔图卷积网络（pyramidal graph convolutional network, PGCN）。PGCN 聚合了局部、中观和全局三个层次特征，实验结果表明，PGCN 在增强网络深度和感受野之间进行了有效的权衡，同时抑制了随之而来的过度平滑，并在受试者依赖和受试者独立场景中都取得了最先进的性能。GONG 等人^[25]提出了一种新型的 EEG 情绪识别模型，该模型结合了大脑半球的不对称性以及 EEG 信号的空间、频谱和时间等多域特性，旨在提高情绪识别性能。构建了全局空间投影矩阵（global spatial projection matrix, GSPM）和双半球差异投影矩阵（bihemisphere discrepancy projection matrix, BDPM），并设计了双流时空卷积神经网络来提取两种矩阵范式中的深度特征。最后，使用基于 Transformer 的融合模块来学习融合特征的依赖关系，并保留判别信息。在 SEED、SEED-IV 和 DEAP 公开数据集上进行的广泛实验取得了优异的平均结果，并通过可视化分析和消融实验验证了模型的可解释性和有效性。HAN 等人^[26]提出一种创新的基于深度学习模型的多尺度情绪识别方法（multi-scale emotion recognition method, MS-ERM），用于分析 EEG 信号并识别人物的情绪状态。该模型结合了多尺度卷积和 TimesNet 网络，以有效提取动态时间特征、跨通道空间特征和复杂时间特征。通过对 DEAP 数据集进行的大量测试，结果表明，该方法在情绪分类方面优于现有方法，在唤醒度和效价分类中分别达到了 91.31% 和 90.45% 的平均分类准确率。

2025 年至今, Cen 等人^[27]提出了一种卷积和注意力机制条件对抗域自适应神经网络（convolution and attention-based conditional adversarial domain adaptation neural network, CA2DANet），用于基于 EEG 的情绪识别。该模型由特征提取器、特征融合网络、标签预测器和域判别器组成，可以提取来自不同域的 EEG 信号的深度特征，通过在 SEED 数据集上进行实验，实验结果显示其精度分别为 96.29% 和 81.05%，分别在受试者依赖性和受试者独立的实验上。Jin 等人^[28]提

出了一种名为多尺度时空特征融合神经网络（Multi scale spatio-temporal feature fusion neural network, MSTFNet）的新型深度学习模型，用于运动想象脑机接口的 EEG 分类。该模型由多尺度卷积和高效通道注意力机制，由特征增强模块、多尺度时间特征提取模块、空间特征提取模块和特征融合模块组成，该模型在 BCI Competition IV 2a 和 BCI Competition IV 2b 数据集上进行了评估，并与其他最先进的模型进行了比较，结果表明 MSTFNet 具有更高的分类精度和泛化能力。

2.3 基于特征提取的脑电数据分类

2018 年及以前，FENG 等人^[29]提出了一种基于多特征提取的 EEG 信号自动分类方法，该方法使用小波包分解将 EEG 信号分解成五个频段，并计算每个频段的样本熵和快慢波能量比作为特征。然后，使用支持向量机（support vector machine, SVM）进行分类，并使用径向基函数（radial basis function, RBF）作为核函数。实验结果表明，该方法可以有效地识别 EEG 信号，并与其他现有的方法相比获得了更高的分类准确率。PARK 等人^[30]提出了一种名为滤波器组正则化共同空间模式集成（filter bank regularized common spatial pattern, FBRCSPP）的新方法，用于解决运动想象 EEG 分类的两个主要问题：小样本设置下的性能下降和对频率带的依赖性。FBRCSPP 方法通过结合滤波器组结构、正则化共同空间模式（regularized common spatial pattern, R-CSP）和集成学习技术，同时解决了上述两个问题，并取得了更高的平均分类准确率，特别是在小样本设置情况下，性能提升更为显著。文献[31]针对基于空间模式（common spatial patterns, CSP）的 EEG 特征提取方法中只选择少数特征导致信息丢失的问题，提出了一种特征加权与正则化（feature weighting and regularization, FWR）方法。FWR 利用所有 CSP 特征，并通过高斯函数加权和对加权特征进行正则化，有效提高了 MI-BCI 的分类准确率，优于传统的特征选择方法。

2019 年，GUPTA 等人^[32]提出了一种 EEG 信号的跨被试情绪识别方法。该方法采用灵活解析小波变换（flexible analytic wavelet transform, FAWT）将 EEG 信号分解为不同子带，并从中提取特征。经过平滑处理后，提取的特征被输入随机森林和支持向量机分类器进行情绪分类。实验结果表明，该方法在情绪分类任务上优于现有方法，并能够对相同刺激下的不同被试进行通道特定的情绪分类。

ZENG 等人^[33]提出了一种新的方法，用于通过经验模态分解（empirical mode decomposition, EMD）、相空间重建（phase space reconstruction, PSR）和神经网络来区分局灶性 EEG 信号和非局灶性 EEG 信号。首先，使用 EMD 将 EEG 信号分解为固有模态函数（intrinsic mode functions, IMF），并提取包含大部分 EEG 信号能量的第三和第四个 IMF 分量。其次，重建这两个 IMF 分量的相空间，其中保留了与 EEG 系统动力学相关的属性。然后，使用神经网络作为分类器，将特征向量作为输入，根据两组之间系统动力学的差异来区分局灶性和非局灶性 EEG 信号。最后，在 Bern Barcelona 数据库上进行了实验，以评估该方法的有效性。文献[34]提出了一种基于功能性脑网络的多特征提取方法，用于分类四类运动想象 EEG 信号。该方法结合 CSP 和局部特征尺度分解（local characteristic-scale Decomposition, LCD）算法从 EEG 信号中提取频率域和空间域特征，并构建功能性脑网络，提取节点度作为特征来表征脑活动。实验结果表明，该模型取得了较高的分类准确率，并具有良好的鲁棒性和实时性。

2020 年，晁浩等人^[35]提出了一种基于集成深度学习模型的 EEG 情感识别方法。首先，从 EEG 信号的时域、频域和时频域提取特征；其次，使用具有胶质细胞链的深度信念网络（improved deep belief networks with glia Chains, DBN-GC）分别提取这些特征的高层抽象表示；最后，利用判别式受限玻尔兹曼机对高层抽象特征进行融合，并进行情感状态预测。实验结果表明，DBN-GC 能够有效利用 EEG 不同通道之间的相关性信息，而集成深度学习模型能够有效融合不同分析域的特征，从而提高情感识别的准确率。文献[36]提出了一种基于量子力学的框架，用于对 EEG 信号进行特征提取和分类。该框架首先将 EEG 信号数据集制备成量子态，并利用量子小波包变换提取小波包能量熵作为后续量子分类器的输入特征。最后，论文提出了改进的量子支持向量机，该分类器可以高效地实现任意非线性核函数，从而显著提升 EEG 信号识别的性能。论文通过实验仿真验证了该框架的可行性和有效性。文献[37]提出了一种基于时间尺度分解（time-scale decomposition, TSD）、离散小波变换（discrete wavelet Transform, DWT）、PSR 和神经网络的新型方法，用于自动识别单通道 EEG 信号中的癫痫发作。实验结果显示该方法实现了 98.15% 的平均分类准确率，优于许多现有方法。

2021 年，ALBAQAMI 等人^[38]提出了一种利用小波包分解（wavelet packet

decomposition, WPD) 进行特征提取, 并使用梯度提升决策树 (gradient boosting decision tree, GBDT) 进行分类的自动检测异常脑电图信号的方法, 使用天普大学医院脑电图异常语料库 V2.0.0 来测试所提方法。结果显示准确率达到 87.68%, 并且在同一数据集上比最先进的技术准确率高出 1% 以上, 灵敏度高出 3% 以上。TUNCER 等人^[39]提出了一种新的方法, 利用混沌局部二值模式 (chaotic local binary pattern, CLBP) 和 WPD 技术来识别 EEG 信号中的异常信号。该方法首先对 EEG 信号进行 WPD 分解, 然后对分解后的信号应用 CLBP 提取特征。接着, 使用迭代最小冗余最大相关性方法选择最具有临床意义的特征。最后, 利用支持向量机对这些特征进行分类, 将 EEG 信号分为正常和异常两类。实验结果表明, 该方法在 TUH EEG 数据集上取得了较高的分类准确率, 证明了其在识别异常 EEG 信号方面的有效性。LI 等人^[40]提出了一种基于 EMD 和 CSP 的新型癫痫发作起始检测方法。该方法首先使用小波变换和 EMD 对 EEG 信号进行滤波预处理和时频分解。然后, 应用 CSP 来降低多通道时频表示的维度, 并提取方差作为唯一的特征。接着, 使用由十个支持向量机 (support vector machine, SVM) 组成的 SVM 组作为鲁棒的分类器。实验结果表明, 该方法在 CHB-MIT 数据库和山东大学第二医院临床 EEG 数据库上均取得了优异检测结果, 并能够帮助识别与癫痫发作起始相关的脑电图通道。

2022 年, 文献[41]提出了一种基于近似经验核映射的融合方法, 通过将不同维度的特征映射到同一维度, 并输入 SVM 进行分类。实验结果表明, 与单一特征相比, 融合特征能够显著提高情感识别的准确率, 尤其是在高频段 (即 β 和 γ 波段) 以及对负面情绪的分类。文献[42]提出了一种基于最小生成树脑网络 (minimum spanning tree based brain network, MSTBN) 和集合经验模态分解-小波包变换 (ensemble empirical mode decomposition-wavelet packet transform, EEMD-WPT) 的多维特征提取方法。该方法首先利用小波包变换将 EEG 信号分解为 θ 、 α 、 β 和 γ 四个频段, 并构建多频带连接矩阵。然后, 通过 Prim 算法构建 MSTBN 并提取全局和局部特征, 以捕捉不同脑区之间的信息交互。接着, 应用 EEMD-WPT 提取非线性特征, 以捕捉脑部神经活动过程。最后, 将所提特征融合, 输入随机森林分类器进行实验。结果表明, 该方法在 DEAP 数据集上取得了较高的识别准确率, 证明了其有效性。文献[43]提出了一种基于稀疏表示和

混合模型的方法，用于 EEG 信号分类。首先对 EEG 信号进行稀疏表示，并使用多种优化技术提取特征，然后，将这些特征聚类到七个不同的混合模型中，包括五个新提出的模型，用于特征提取和选择。这七种模型为有限混合逻辑回归模型（Finite Mixture Logistic Regression Model, FMLR）和基于期望最大化的高斯混合模型（Expectation-Maximization based Gaussian Mixture Model, EM-GMM），基于变分贝叶斯矩阵分解（Variational Bayesian Matrix Factorization, VBMF）的 GMM（VBMF-GMM）、VBMF 和概率主成分分析（Principal Component Analysis, PCA）与 GMM（VBMF-PCA-GMM）、VBMF 和偏最小二乘（Partial Least Squares, PLS）与 GMM（VBMF-PLS-GMM）、VBMF 和典型相关分析（Canonical Correlation Analysis, CCA）与 GMM（VBMF-CCA-GMM）以及经验 VBMF 与 GMM（VBMFGMM）。最后，使用机器学习、迁移学习和深度学习方法对提取的特征进行分类，并取得了超过 95% 的分类精度。

2023 年，张灵维等人^[44]提出了一种融合 DWT 和 EMD 的脑电信号特征提取与分类方法。该方法将原始语言想象脑电信号分别进行 DWT 和 EMD 分解，提取分解后各通道信号的特征并进行融合，然后使用径向基核函数 SVM 进行分类。实验结果表明，该方法能够有效提高语言想象脑电信号分类的准确率，相较于单独使用 DWT 或 EMD 方法，分类准确率分别提高了 20.77% 和 21.12%。SHEN 等人^[45]提出了一种基于 EMD 的改进型 EEG 信号特征提取方法，用于抑郁症识别。该方法通过引入正则化参数来优化 EMD 特征提取的鲁棒性，并有效地解决了 EMD 方法中存在的模式混叠问题。实验结果表明，该方法在四个 EEG 数据集上均取得了良好的抑郁症识别效果，并且计算成本低于其他方法。XU 等人^[46]提出了一种名为正交回归中的全局冗余最小化（global redundancy minimization in orthogonal regression, GRMOR）的特征选择方法，用于情绪识别。GRMOR 通过引入全局冗余评估项，有效地评估了所有 EEG 特征之间的依赖性，并选择了一个具有区分性和非冗余性的 EEG 特征子集，从而提高了情绪识别的性能。实验结果表明，GRMOR 在去除冗余特征和选择信息特征方面优于其他九种流行的特征选择方法，尤其是在高密度 EEG 数据集上表现更佳。

2024 年，JIN 等人^[47]提出了一种名为多尺度时空特征融合神经网络（multiscale spatialtemporal feature fusion neural network, MSTFNet）的新型深度

学习模型，该模型由四个不同的模块组成：特征增强模块、多尺度时间特征提取模块、空间特征提取模块和特征融合模块。实验结果表明，MSTFNet 的分类准确率优于现有的先进方法，展现其有效性和先进性。LIU 等人^[48]提出了一种基于多维特征提取和双分支超图卷积网络。该方法首先利用 Conv-LSTM 模块和功率谱密度从时空域和频域提取 EEG 信号的特征，以解决传统方法特征提取不足的问题。然后，通过构建超图来探索高维空间中的内在特征，揭示癫痫信号特征提取的本质共性。最后，利用集成学习的概念，在双分支超图卷积上进行癫痫检测。实验结果表明，该方法在 TUH 数据集上取得了 96.9% 的平均准确率，F1 分数为 97.3%，Pre 为 98.2%，Re 为 96.7%，优于现有方法。文献[49]提出了一种名为选择性提取多视图时频分解空间（Selective extract the Multi-View Time-Frequency decomposed Spatial, S-MVTFS）特征矩阵的新方法，用于解码非侵入式运动想象脑电信号。该方法通过时间-频域分解提取欧几里得和黎曼空间中的空间特征，并在流形嵌入空间中选择具有区分度的特征，最后通过稀疏支持矩阵机进行分类。S-MVTFS 方法在三个 BCI 竞赛 MI-EEG 数据集上进行了基准测试，其分类性能优于多种现有方法。

2025 年至今，Irfan 等人^[50]提出了一种基于 EEG 信号的新生儿睡眠阶段分类方法，该方法结合了多域选择性特征融合和堆叠集成分类器。该方法首先从单通道 EEG 信号中提取多种特征，包括离散小波变换、连续小波变换、频谱统计和时域特征。该方法在两个新生儿睡眠分析数据集上进行了评估，结果表明，该方法在区分睡眠与清醒、安静睡眠与非安静睡眠以及安静睡眠与清醒方面具有很高的准确性和可靠性。Zhi 等人^[51]提出了一种基于监督对比学习的域泛化网络（supervised contrastive learning-based domain generalization network, SCLDGN），用于解决跨被试运动想象和运动执行解码中的域偏移问题。SCLDGN 通过特征编码器学习 EEG 信号的判别性特征表示，并通过深度相关性对齐进行域对齐，以学习域不变特征。此外，它还引入了类正则化块，以学习类相关特征并实现类级对齐。实验结果表明，SCLDGN 在六个公共 MI/ME 数据集上取得了优于其他方法的性能，并且能够学习到与 MI/ME 相关的神经生理学意义上的模式。

2.4 本章小结

上述文献均是从神经网络模型搭建和特征提取算法层面进行的研究, 尽管许多研究在脑电信号的时间频率特征提取和分类精度上取得了较好成果, 但在挖掘脑电信号中蕴含的丰富拓扑信息和建模长距离依赖性方面, 仍然存在不足。此外, 传统的脑电信号分类模型在处理长距离依赖和动态变化方面的建模能力也较为欠缺。现有研究往往忽视了多个脑区间信息的协同作用, 导致多模块间的协作不足, 且大多数方法的泛化能力较弱, 难以适应复杂多变的脑电数据, 本文对此展开研究。

第3章 自注意力机制混合神经网络脑电数据分类算法

3.1 引言

本节主要对自注意力机制混合神经网络分类算法所用到的微分熵、残差连接、自注意力机制等理论进行阐述，同时用该混合网络解决脑电数据的二分类问题。

3.1.1 微分熵

由于情感脑电信号具有连续性、非线性等特征，且采用较多的电极导联来采集信号，难免地产生了一些噪声或冗余等信号，这些会对脑电信号识别、分类等产生影响。微分熵（differential entropy, DE）能较好地对脑电信号的特征提取，已在脑电识别领域获得了较为广泛应用，在分析 EEG 信号复杂性和随机性等层面，DE 较具优势^[52,53,54]。

DE 特征原始计算公式如下所示^[54]：

$$y(X) = - \int_a^b f(x) \log(f(x)) dx \quad (3.1)$$

式中： x 是一个连续随机变量，在这里指从某个通道上的某个频带获取的数据， $f(x)$ 表示连续信息的概率密度函数， $[a, b]$ 表示信息取值区间。

一般而言，31~50Hz 带通滤波后的 gamma 等频带 EEG 信号 90% 以上服从高斯分布 $N(\mu, \sigma_i^2)$ ，所以 DE 特征计算可进一步采用以下公式计算^[55]：

$$\begin{aligned} y_D(X) &= - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) \cdot \log \frac{1}{\sqrt{2\sigma^2}} \exp\left(-\frac{(x-\mu)^2}{2\sigma^2}\right) dx \\ &= \frac{1}{2} \log 2\ell\sigma^2 \end{aligned} \quad (3.2)$$

式中： ℓ 和 σ 分别是 x 的欧拉常数和标准差。

32 个脑电电极通道位置排列如图 3-1 (a) 所示，基于 32 个电极通道通过 DE 提取一个 9×9 的特征矩阵见（图 3-1 (b)），特征矩阵电极通道可视化图见 3-1 (c) 所示，本研究用大脑中的相对位置来表征二维平面上电极的分布，在这个矩阵中，没有安装电极的区域在实验中未显示出作用，将其数值设定为 0，然后对 DE 值进行归一化处理。特征提取流程图具体见图 3-1。




图 3-1 特征提取流程图

Fig.3-1 Feature extraction flowchart

3.1.2 残差连接

网络层数增加到某个极值时，导致 CNN 训练集损失率增大，产生梯度消失和识别率降低，发生网络退化。残差连接（Residual connections, RC）可以解决这个问题，其作用是使输入数据能够直接绕过某些层传递至后续层，既不产生额外参数，也不增加计算复杂度，从而解决梯度消失、网络退化等问题^[56]，RC 结构如图 3-2 所示，其中包括激活函数整流线性单元（rectified linear unit, relu），其功能是增强神经网络的非线性特性，两个权值层 weight layer，输入 X 的 identity 恒等映射。

$$F(X) = F(X) + X \quad (3.3)$$

式中：X 为输入，F(X)是一个关于 X 的残差映射。




图 3-2 RC 结构图

Fig.3-2 RC Structure diagram

3.1.3 自注意力机制

自注意力机制是一种独特的注意力机制，它在分析序列数据时，能全面考虑序列中任一元素与其它所有元素之间的相互影响。这一机制显著提高了模型对序列上下文信息的理解力，从而提升了处理序列数据时的精确度。

过程如图 3-3 所示。输入序列由 $X=[x_1, x_2, \dots, x_n]$ 表示，通过权重矩阵 W_Q , W_K 和 W_V 对输入序列进行线性变换，分别得到查询向量 Q ，键向量 K 和值向量 V 。然后， Q 与 K 通过点积运算计算出注意力的分数，这些分数随后通过 softmax 函数的作用，被转换成用于加权各个输入元素的注意力权重。最后，将值向量 V 与对应的权重相乘并求和得到输出。




图 3-3 SAT 结构图

Fig.3-3 SAT Structure diagram

3.2 自注意力的混合神经网络模型

3.2.1 卷积神经网络

卷积神经网络包括卷积层、池化层和全连接层。本研究在基本结构中加入了批量归一化 (batch normalization, BN) 和防止过拟合随机失活 Dropout 正则化方法，目的是提升参数的泛化能力并避免训练过程中的过拟合问题。此外，在卷积层之间插入了残差连接块，目的是减轻梯度消失和梯度爆炸的问题，这使得网络能够有效地训练更深的结构。

在构建过程中，本研究采纳了一种新型的卷积模块，即空间与通道重建卷

积（spatial channel-reconstruction convolution, SCConv）^[57]。SCConv 通过剔除多余特征，不仅提高了效率，而且减少了复杂性和计算资源消耗。这一优点在实验过程中得到了有效证实，多次实验后得到的各层参数如表 3-1 所示。

表 3-1 CNN 模型参数

Tab.3-1 CNN Model Parameters

类型	特征尺寸	卷积核大小
卷积 1	(24, 5, 5)	(5, 5)
卷积 2	(24, 5, 5)	(3, 3)
卷积 3	(128, 4, 4)	(2, 2)
最大池化	(128, 1, 1)	(2, 2)
全连接 1	96	—
全连接 2	16	—

3.2.2 双向长短期记忆神经网络

BLSTM 网络对 LSTM 进行了优化，通过引入一个反向的 LSTM 层来实现，这样模型不仅能够捕捉历史数据，还能预见未来趋势，进而增强其预测性能。BLSTM 由三个相互连接的 LSTM 层组成，每个层同时处理序列的正向和反向信息。这种结构能够有效捕捉序列中的长距离依赖。在正向 LSTM 层中，输入数据通过门控单元进入隐藏层，经过一系列计算生成新的隐藏状态。反向 LSTM 层则接收前一个时刻的状态和当前输入，进行相似处理。两个方向的输出结合，形成综合信息流，增强了模型对序列数据的理解和预测能力。图 3-4 描述了 BLSTM 架构的组件。计算过程如式 3-4 和式 3-5 所示^[58]：

$$h_t = LSTM(X_t h_{t-1}, C_{t-1}) \quad (3-4)$$

$$Y_t = \sigma(W_1 h_1 + W_2 h_2) \quad (3-5)$$

式中： h_t 为当前时刻的隐藏状态， X_t 为输入向量， h_{t-1} 为前一时刻的隐藏状态， C_{t-1} 为前时刻的单元状态， h_1 为前向 LSTM 输出状态， h_2 为后向 LSTM 输出状态， W_1 为前向输出权重矩阵， W_2 为后向输出矩阵， Y_t 代表最终的输出结果。




图 3-4 BLSTM 结构

Fig.3-4 BLSTM Structure diagram

3.2.3 自注意力的混合神经网络结构




图 3-5 自注意力的混合神经网络模型

Fig.3-5 Self attention hybrid neural network mode

如图 3-5 所示，本章设计了一种新型网络架构，该架构集成了卷积神经网络、残差连接、自注意力机制和双向长短期记忆网络技术，以实现对序列数据中的空间和时间特征的精确提取。这种端到端的训练模式不仅简化了训练过程，还提升了整体的运作效率，使其成为处理序列数据的重要手段。该模型首先对原始 EEG 数据进行预处理将数据划分四个频段（theta、alpha、beta、gamma）数据在提取各个频段 DE 特征生成特征数据集，然后将数据输入模型中。首先通过三个卷积

层和两个残差块提取输入数据的特征,并应用批量归一化提高模型的稳定性和收敛速度,然后将特征展平并通过两个全连接层减少维度,并应用 Dropout 减少过拟合,通过软阈值函数降噪,在通过自注意力层为序列中的每个元素分配不同的权重,以捕捉序列内的复杂依赖关系,然后通过 BLSTM 捕捉长距离依赖关系,最后通过全连接层输出最终的分类结果。HNN 算法训练优化过程具体见表 2。

表 3-2 HNN 算法训练优化过程

Tab.3-2 Procedure of HNN algorithm training optimization
算法 1: Procedure of HNN algorithm training optimization
输入: train_data, arousal_train_label, valence_train_label
输出: 效价和唤醒损失率、准确率
1: 读入数据集及对应标签数据集
2: Net = AttentiveResCNN_BiLSTM()
3: repeat:
4: 声明一个网络
5: 计算数据通过第一层 CNN 网络
6: 计算数据通过第一层残差连接层
7: 计算数据通过第二层 SCConv
8: 计算数据通过第三层 CNN 网络
9: 计算数据通过第二层残差连接层
10: 计算数据通过第一、二层全连接
11: 正则化防止数据过拟合
12: 通过软阈值函数去噪和保留 EEG 数据重要信息
13: 计算数据结果的自注意力机制
14: 计算数据通过 BLSTM
15: 计算数据通过第三层全连接
16: until 迭代次数和收敛条件满足要求

3.3 实验设计与结果分析

3.3.1 实验数据集

本章利用公开的大规模 EEG 情感数据集 DEAP 验证所提出注意力混合神经网络模型的有效性^[59]。DEAP 数据集是由英国伦敦玛丽皇后大学、荷兰特温特大学、瑞士日内瓦大学、瑞士联邦理工学院的研究人员合作采集。基于音乐视频材料诱发刺激,记录了 32 名受试者观看 40 分钟音乐视频(每段视频 1 分钟)时的生理信号。实验过程中,参与者需要对每个视频的愉悦度(valence)、唤醒度(arousal)、优势度(dominance)、喜好度(liking)进行量表评价,同时还记

录了前 22 名参与者的面部表情视频。信号采集信息：生理信号采用 512Hz 采样，后进行 128Hz 复采样（官方提供了经过预处理的复采样数据）。电极分布见图 3-6，详细信息如表 3-3 所示。




图 3-6 32 导电极分布图

Figure 3-6 32 conductive electrode distribution maps

表 3-3 DEAP 数据集的详细信息

Tab.3-3 The details of the DEAP dataset

属性	描述
受试者	32（男女比例 1:1）
视频数量	40 个一分钟视频
受试者试验	40 次
试验长度	63s（3 秒基线和 60 秒试验）
评定量表	唤醒、效价、支配和喜爱
脑电数据	$40 \times 32 \times 8064$ (试验 $\times$ 通道 $\times$ 数据)
标签	40×4 （试验 $\times$ 标签）

本章采用了 32 个通道的脑电信号，将其下采样至 128Hz，并通过 4-45Hz 的巴特沃斯带通滤波器将信号分解为 theta、alpha、beta、gamma 四个波段，同时消除了信号中的噪声和伪迹。在提取四个波段 3 秒基线信号和 60 秒实验信号的 DE 之后，将一维的 EEG 数据转换为二维矩阵（ 9×9 ），能更有效地保留并利用其

空间信息。在二维空间中，不同电极间的空间关系得以保持和展现，这有助于模型捕捉到关键的空间特征。进一步地，通过堆叠不同频段的数据，可以构建三维数据结构（ $4 \times 9 \times 9$ ），这样便能同时利用各频段的频谱信息。通过整合来自不同频段的信息，模型能够获得更为全面和深入的特征集，这进一步强化了模型在识别任务中的效能。

3.3.2 实验参数设置

本章采用 6:2:2 比例划分训练集、验证集和测试集，并在不同超参数组合上进行训练，以筛选最佳超参数。表 3-4 汇总了所用超参数及其最优值。为达到最优效果，总迭代次数设为 100，批次大小设置为 100，学习率设为 0.001，选择 Adam 作为模型优化器，网络隐藏层神经元设为 8，L2 正则化系数设为 0.00001。

表 3-4 超参数和最优值

Tab.3-4 hyperparameters and optimal values

超参数	取值范围	最优值
Batch size	50,100,150	100
learning_rate	0.01,0.001,0.0001	0.001
optimizer	Adam,AdamW	Adam
hidden_size	5~10	8
weight_decay	0.001,0.0001,0.00001	0.00001

3.3.3 实验结果与分析

将本章所提出的注意力的混合神经网络模型应用到 DEAP 数据集上，并对唤醒和效价维度上二分类计算进行深入研究。模型的性能评估采用准确率（accuracy）、精确度（precision）、召回率（recall）和 F1 分数（f1_score）等作为主要指标，具体计算公式如下所示^[3]：

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3-6)$$

$$precision = \frac{TP}{TP + FP} \quad (3-7)$$

$$recall = \frac{TP}{TP + FN} \quad (3-8)$$

$$f1_score = \frac{2 \times recall \times precision}{recall + precision} \quad (3-9)$$

式中：TP、TN、FP、FN 分别代表真实为正预测为正、真实为负预测为负、真实为负预测为正、真实为正预测为负的样本数量。f1_score 是通过精确度和召回率计算得出的调和平均值，它兼顾了精确度和召回率两个重要指标。

实验结果如表 3-5 所示，从表中可以看出实验效果十分优异。为深入验证模型的泛化性能及可靠性，本研究进行了独立的测试实验。具体而言，在 32 名参与者中，选择 1 名参与者的数据作为测试样本，剩余 31 名参与者的数据构成训练样本。根据表 3-6 的数据分析，32 名受试者在效价分类任务上的平均准确率达到 93.58%，而 f1_score 的平均值为 96.46%；在唤醒度分类任务上平均准确率为 91.42%，f1_score 的平均值为 94.37%。这些结果充分证明了所采用的方法具备良好的泛化能力。

表 3-5 DEAP 上的实验结果

Tab.3-5 Experimental results on DEAP

	Accuracy (%)	Precision (%)	Recall (%)	f1_score (%)
效价	96.75	96.41	99.18	97.77
唤醒	94.95	94.27	97.27	95.74

表 3-6 独立测试实验

Tab.3-6 Independent testing experiments

编号	Accuracy (效价)	f1_score (效价)	Accuracy (唤醒)	f1_score (唤醒)
s01	93.03%	96.14%	90.03%	93.79%
s02	93.01%	96.17%	91.13%	94.30%
s03	92.47%	95.88%	90.86%	94.37%
s04	95.16%	97.32%	88.17%	92.64%
s05	94.89%	97.21%	91.94%	94.88%
s06	94.09%	96.75%	90.86%	94.11%
s07	93.01%	96.13%	91.13%	94.37%
s08	94.62%	97.04%	92.47%	95.10%

s09	93.55%	96.42%	92.74%	95.32%
s10	93.55%	96.43%	93.28%	95.66%
s11	92.74%	96.03%	90.05%	93.54%
s12	93.28%	96.27%	90.86%	94.11%
s13	92.74%	95.98%	90.05%	93.42%
s14	95.70%	97.64%	93.01%	95.50%
s15	94.09%	96.75%	92.20%	94.95%
s16	94.35%	96.92%	90.86%	94.13%
s17	95.97%	97.77%	91.13%	94.13%
s18	93.28%	96.27%	93.01%	95.43%
s19	93.82%	96.59%	88.98%	92.79%
s20	93.28%	96.32%	91.94%	94.82%
s21	92.47%	95.82%	91.94%	94.86%
s22	93.55%	96.43%	92.74%	95.32%
s23	94.09%	96.74%	93.01%	95.50%
s24	94.35%	96.90%	89.52%	93.16%
s25	94.09%	96.78%	89.25%	93.03%
s26	90.59%	94.78%	91.67%	94.62%
s27	94.09%	96.78%	87.37%	91.85%
s28	94.62%	97.04%	91.94%	94.68%
s29	93.55%	96.43%	91.13%	94.15%
s30	92.20%	95.67%	91.94%	94.71%
s31	92.20%	95.66%	92.74%	95.28%
s32	92.20%	95.66%	92.47%	95.17%
平均值	93.58%	96.46%	91.42%	94.37%

接受者操作特性曲线（receiver operating characteristic curve, ROC）是一种直观展示分类器性能的图形化工具，该曲线通过以真阳性率（true positive rate, TPR）为纵坐标，假阳性率（false positive rate, FPR）为横坐标，来形象地描绘分类器的表现。其中，TPR 指的是模型准确判断出的真正正例的比率，FPR 指的

是真实负例被错误分类为正例的比率。ROC 曲线中 area 代表的是曲线下方的面积，area 的值越大，整体性能越好。从图 3-7（a）和图 3-7（b）中可以得到 area 的值分别为 0.99 和 0.97，可以得出本研究模型的分类性能高。




图 3-7 效价和唤醒 ROC 曲线

Fig.3-7 Valence and arousal ROC curve

图 3-8（a）和图 3-8（a）代表效价和唤醒训练与验证的损失曲线，结果表明训练损失减少并趋于平稳，表明模型最小化误差；验证损失减少后趋于稳定，模型泛化良好，没有过拟合，所用函数为交叉熵损失函数^[60]，公式如 3-10 所示。图 3-9（b）和图 3-9（b）代表效价和唤醒训练与验证的准确率，结果表明训练准确率提高并接近完美；验证准确度提高，达到高准确度前有些波动，显示模型在未见数据上表现良好但略有波动。

$$L = -[y \log \hat{y} + (1 - y) \log(1 - \hat{y})] \quad (3-10)$$

式中 y 代表样本的真实标签，取 0 或 1，0 代表负类，1 代表正类， $\hat{y}$ 表示模型预测为正类的概率。




图 3-8 效价损失率和准确率

Fig.3-8 The loss rate and accuracy rate




图 3-9 唤醒损失率和准确率

Fig.3-9 The loss rate and accuracy rate

混淆矩阵（Confusion Matrix, CM）是评估分类模型性能的关键工具，它通过表格的形式展示了算法对各个类别的预测准确性。从图 3-10（a）中得出效价约有 9.09% 被误分类，图 3-10（b）中得出唤醒度约有 15.79% 被误分类，整体分类准确率较高。




图 3-10 效价和唤醒混淆矩阵

Fig.3-10 Valence confusion and arousal confusion matrix

精度召回率（precision recall, PR）曲线，是一个脑电情感分类模型重要的性能评价指标之一，用于衡量情感分类模型的准确性和可靠性。围绕着精确度和召回率两个核心指标，其中横轴是召回率，纵轴是精确度，曲线面积越大，模型整体性能越好。图 3-11（a）代表效价 PR 曲线，该曲线下方面积为 1.00，图 3-11（b）代表唤醒 PR 曲线，该曲线下方面积为 0.99，可以得出该模型能够准确地预测正类样本，并且漏报和误报的概率都很低。




图 3-11 效价和唤醒 PR 曲线

Fig 3-11 Valence and arousal PR curve

为了更全面地展现所提方法的优势，本章将所采用的研究方法与现有的研究成果进行了对比分析，比较结果如表 3-7 所示。

表 3-7 与其他方法对比

Tab.3-7 Comparison with other methods

文献索引	分类器	数据集	Accuracy (%)
文献[61]	Softmax	DEAP	效价：84.27 唤醒：85.86
文献[62]	CNN-SVM	DEAP	效价：75.22 唤醒：80.52
文献[63]	3D-CNN-BLSTM-GRU-AT	DEAP	效价：90.57 唤醒：90.59
文献[54]	2D-CNN-LSTM	DEAP	效价：92.31 唤醒：91.92
本章	HNN	DEAP	效价：96.75 唤醒：94.95

上述比较分析显示，本研究提出的方法相较于现有研究成果，具有更高的分类精度。这是因为本文所采用的 HNN 模型能够识别脑电通道的时间特性和整体依赖关系，整合脑电信号在时间和空间上的信息，保持了脑电通道与信号的独立性，并通过软阈值技术降低了噪声的干扰。自注意力机制提升了特征表达能力，残差连接在卷积层中进一步改善了梯度传播和特征提取。实验结果显示，与现有

研究对比，该模型展现了更高的准确率，从而进一步证明了该模型的有效性。

3.4 本章小结

本章提出了一种基于注意力机制的混合神经网络用于脑电信号分类，模型包括卷积神经网络、双向长短期记忆网络、残差连接和自注意力机制，成功优化了模型的泛化能力，并有效解决了过拟合和梯度消失问题。模型采用微分熵特征矩阵提取方法来优化时空特征的整合，并通过 CNN 提取关键的空间特征，以及利用自注意力机制和 BLSTM 深入挖掘时间序列的依赖性，从而提高了分类准确率和鲁棒性。在 DEAP 数据集上的实验结果表明，HNN 模型在效价和唤醒分类准确度上显著优于现有的四种典型算法，分别达到了 96.75%和 94.95%，并且在独立测试中保持了高准确率，分别为 93.58%和 91.42%，证明了模型的有效性和先进性。

第 4 章 动态时空图卷积注意力网络脑电数据分类算法

4.1 引言

本节主要对动态时空图卷积注意力网络分类算法所用到的理论知识进行阐述，同时用该网络解决脑电数据的三、四分类问题。

4.1.1 特征提取

在脑电特征的分类上，可以将特征提取其分为单通道特征和多通道特征两大类^[64]。目前，大量研究集中在单通道特征上，这些特征包括统计特征^[65]、分形维数^[66]、功率谱密度（power spectral density, PSD）^[67]、微分熵^[68]以及小波特征^[69]等。一些特征在多个通道上计算特征来捕捉通道间的相互关系，例如 PSD^[70]、不对称特性^[71]和功能连接^[72]，这通常涉及到使用相关性、一致性和相位同步等常用指标来评估大脑各通道之间的功能连接。但是，进行功能连接分析需要对每位受试者进行耗时的人工分析，这并不适合实时应用的需求。本节主要使用微分熵特征。

4.1.2 动态图卷积神经网络

动态图卷积神经网络（dynamic graph convolutional neural network, DGCNN）是一种先进的图神经网络模型，它通过动态图卷积操作捕获图数据的局部和全局结构信息，能够处理动态变化的图结构，适用于多种图数据分析任务，特别在处理复杂和动态变化的图数据时展现出优异的性能。由 DGCNN 学习的邻接矩阵将更有用，因为它捕获 EEG 通道的内在连接。模型结构如图 4-1 所示。

模型的计算过程如式（4-1）所示^[73]：

$$y = g(L^*)x = U^* g(\Lambda^*) U^{*T} x \quad (4-1)$$

式中： L 表示拉普拉斯矩阵， U 是经过拉普拉斯矩阵的奇异值分解获得的正交矩阵， Λ^* 表示对角矩阵， x 表示信号。

由于很难直接计算出 $g(\Lambda^*)$ 的表达式，所以通过使用 K 阶 Chebyshev 多项式来代替 $g(\Lambda^*)$ 来简化计算，使计算变得更加容易和快速^[16]。具体转换如式（4-2）所示：

$$g(\Lambda^*) = \sum_{k=0}^{K-1} \theta_k T_k(\tilde{\Lambda}^*) \quad (4-2)$$

由式 (4-2) 得到式 (4-1) 中定义的计算过程可以重写为式 (4-3)。

$$\begin{aligned} y &= U^* g(\Lambda^*) U^{*T} x \\ &= \sum_{k=0}^{K-1} U^* \begin{bmatrix} \theta_k T_k(\tilde{\lambda}_0^*) & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \theta_k T_k(\tilde{\lambda}_{N-1}^*) \end{bmatrix} U^{*T} x \\ &= \sum_{k=0}^{K-1} \theta_k T_k(\tilde{L}^*) x \end{aligned} \quad (4-3)$$

式中: $\tilde{L}^* = 2L^* / \lambda_{\max}^* - I_N$ 。

上述表达式意味着计算 x 的图卷积可以表示为 x 与每个 Chebyshev 多项式分量的卷积结果的组合。




图 4-1 DGCNN 结构图

Fig.4-1 DGCNN structure diagram

4.1.3 转换器

转换器 (Transformer) 是一种基于注意力机制的编码器-解码器模型, 它完全摒弃了循环和卷积神经网络, 而是利用自注意力机制和多头注意力机制来捕捉输入和输出序列之间的依赖关系, 并使用位置编码来注入序列的顺序信息。在机器翻译等任务中取得了显著的成果, 并具有更好的并行化能力、更短的计算路径、更高的翻译质量和更快的训练速度等优点^[74]。Transformer 总体架构如图 4-2 所示, 编码器和解码器分别如图 4-2 的左半部分和右半部分所示。包含以下模块,

Positional Encoding (位置编码): 为每个 token 添加其位置信息, 因为 Transformer 本身不捕捉顺序信息。**Encoder Layer (编码层)**: 重复 N 次, 每次包括以下模块:
Add & Norm (残差连接与归一化), 在每个子层 (如 Self-Attention 和 Feed Forward) 后添加残差连接, 并进行层归一化;
Self-Attention (自注意力机制): 允许模型在不同的输入 token 之间进行权重计算, 从而更好地捕捉依赖关系;
Feed Forward (前馈神经网络): 一个简单的线性变换, 通常包括两个线性映射和一个 ReLU 激活函数。**Masked Multi-Head Attention (带掩码的多头注意力机制)**: 在解码器中使用, 确保只关注已经生成的输出 tokens。
Linear and Softmax (线性变换和 softmax): 对最终的输出 embedding 进行线性变换, 然后应用 softmax 函数得到概率分布。**Multi-Head Attention (多头注意力机制)**: 扩展自我关注机制, 通过多个独立的注意 heads, 可以捕获不同方面的交互信息。




图 4-2 Transformer 体系结构

Fig.4-2 Transformer architecture

4.1.3 多头注意力

与其使用键、值和查询执行单一的注意力函数, 不如将查询、键和值分别以

不同的、学习过的线性投影 h 次线性投影到 q 、 k 和 v 维度，这是有益的。然后，在查询、键和值的每个投影版本上，并行地执行注意力函数，生成输出值。将它们连接起来并再次进行投影，得到最终值，如图 4-3 所示。

多头注意力（Multi-Head Attention, MHSA）：在实践中，多个自注意子层可以并行堆叠，它们的连接输出通过投影矩阵 W 融合，形成一个称为多头注意力的结构，多头注意力允许模型在不同的位置共同关注来自不同表示子空间的信息，计算公式如式（4-4），式（4-5）^[74]。

$$Attention(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (4-4)$$

$$\begin{aligned} MultiHead(Q, K, V) &= \text{Concat}(head_1, \dots, head_h)W^O \\ where &= Attention(QW_i^Q, KW_i^K, VW_i^V) \end{aligned} \quad (4-5)$$

Multi-Head Attention




图 4-3 多头注意力机制

Fig.4-3 Multi-Head Attention

4.2 动态时空图卷积注意力网络模型架构

动态时空图卷积注意力网络（Dynamical Spatial-Temporal Graph Convolutional Attention Network, DST-GCAN）结合了 DGCNN 和 Transformer 结构，充分利用两者的优势来提取特征并完成预测任务，模型整体结构如图 4-4 所示。模型首先通过 DGCNN 模块捕获输入数据的局部图结构信息，其中 BatchNorm1d 进行批标准化，Graph Convolution 动态构建图，Residual Layers 和 ReLU 激活函数增强

梯度流和非线性表达能力；接着通过 Transformer 模块学习全局特征，利用 Positional Encoding 捕获序列位置信息，多头注意力机制（Multi-Head Attention）提取全局上下文，配合 Add & Norm 和 Feed Forward 层提升特征表示能力。随后，模型通过 Global Pooling 将节点信息聚合为全局特征，并经过三层全连接网络（Linear1-Linear3）和 Soft Thresholding 模块调整特征重要性，最终输出预测结果。该模型将局部与全局特征提取相结合，利用 DGCNN 动态图构建的灵活性和 Transformer 注意力机制的高效性，并通过残差连接和阈值化操作提高训练稳定性和任务适应性，在图数据处理和预测分析等任务中表现出色。

训练 DST-GCAN 模型的详细算法在算法 4-1 中给出。

算法 4-1 DST-GCAN 的训练算法

输入：训练样本 X 和 Y，邻接矩阵 K，迭代次数 num_epochs，批次大小 B，其他正则化超参数；

输出：分类结果；

- 1: 在 GTN 中初始化模型参数；
 - 2: for ep=1: num_epochs do
 - 3: 初始化变量: correct = 0, total = 0, total_loss = 0;
 - 4: 模型前向传播计算输出 output;
 - 5: 计算损失 loss;
 - 6: 获取预测标签 pred(通过 output.argmax(dim=1))
 - 7: 更新累计统计量;
 - 8: 正确预测样本数 correct;
 - 9: 总样本数 total;
 - 10: 损失值累加 total_loss;
 - 11: 反向传播更新模型参数:
 - loss.backward()
 - optimizer.step()
 - optimizer.zero_grad();
 - 12: 打印当前批次损失和准确率;
 - 13: 返回最佳测试准确率 acc_test_best;
-




图 4-4 DST-GCAN 模型架构

Fig.4-4 DST-GCAN model architecture

4.3 实验设计与结果分析

4.3.1 实验数据集

本章利用公开的大规模 EEG 情感数据集 SEED 和 SEED-IV 验证所提出模型架构的有效性^[70,75]。SEED 数据集是由上海交通大学开发。实验中选择了 15 个中国电影剪辑（包含正面、中性和负面三种情绪）作为刺激材料，每个片段时长约为 4 分钟。被试者为 15 名（7 男 8 女），每个被试进行三次实验，每次实验相隔一周。每次实验有 15 个试验（即观看 15 个电影片段），每个片段之前有 15 秒的提示，观看结束后有 10 秒的结果反馈，让参与者报告他们对每个片段的情感反应。

SEED-IV 数据集：同样是上海交通大学开发的数据集。实验前选择了 168 个电影片段作为四种情绪（快乐、悲伤、恐惧和中性）的素材库，44 名参与者（22 名女性，均为大学生）对这些片段的情绪进行评估和打分。最终的数据集包含 15 名被试者（在不同时间做 3 组实验）的数据，三组实验使用的刺激完全不同，总共 45 个实验。每个被试观看 24 个电影片段（每种情绪有 6 个片段），每个电影剪辑的持续时间约为两分钟。信号采集与处理：与 SEED 数据集类似，对脑电信号进行了预处理，包括下采样、带通滤波等操作。信号采集与处理：脑电信号以

200Hz 的采样率下采样，为滤除噪声和伪影，在 0.5Hz 和 70Hz 之间用带通滤波器对脑电信号进行处理，设备为 62 导电极，电极分布见图 4-5。详细信息如表 4-2 所示。




图 4-5 62 导电极分布图

Figure 4-5 62 conductive electrode distribution maps

表 4-1 数据集的详细信息

Tab.4-1 details of the dataset

数据集	属性	描述
SEED	受试者	15 (7 男 8 女)
	视频数量	15 个四分钟视频
	受试者试验	每人 3 次
	脑电数据	62×47001 (channel×data)
	标签数据	1×15 (15 次试验)
SEED-IV	受试者	15 (7 男 8 女)
	视频数量	72 个二分钟视频
	受试者试验	每人 3 次
	脑电数据	62×35001 (channel×data)

4.3.2 实验设置

实验设置和数据集总结如表 4-2 所示。

表 4-2 数据集和实验设置摘要

Tab.4-2 Summary of datasets and experimental settings

数据集	任务	模态	训练方案	测试方案	特征
SEED	3 emotions	EEG, Eye movement	session- dependent	train:test=7:3, leave-one-out cross- validation	PSD, DE in five bands(1-4Hz; 4-8Hz;8-14Hz; 14-31Hz;31- 50Hz)
SEED-IV	4 emotions	EEG, Eye movement	session- dependent	train:test=7:3, leave-one-out cross- validation	PSD, DE in five bands(1-4Hz; 4-8Hz;8-14Hz; 14-31Hz;31- 50Hz)

4.3.3 验结果与分析

本文对 SEED 和 SEED-IV 进行了独立被测实验和依赖实验的分类，以评估模型性能。

4.3.3.1 独立被测实验

对于 SEED, SEED-IV, 使用独立被测实验的分类来评估本文的模型。具体来说，采用留一交叉验证，即在每次验证期间，在 14 个受试者上训练模型，并在剩余的受试者上进行测试。为了训练所提出的模型，本文采用了 AdamW 优化器来最小化模型损失。所提出的模型由 AdamW 优化器训练，学习率为 0.001，权重衰减率为 0.01，小批量大小为 64。在训练过程中采用了 dropout 操作，dropout 率为 0.5，以随机阻止内部层的输出单元。对于 15 个受试者的 SEED/SEEDIV 数据库，留一交叉实验将进行 15 次。然后，使用测试对象的平均准确率来评估模型性能。实验结果如表 4-3 所示，列出所提模型与其他方法的结果对比，所提出的具有 delta 和 beta 波段特征的比具有相同特征的其他方法实现了更高的准确率，模型在 SEED 数据集上的平均准确率达到 82.33%，在 SEED-IV 数据集上的平均

准确率达到 61.34%，优于现有方法。

表 4-3 SEED 和 SEED-IV 上的独立被测实验分类准确率（平均值/标准差）

Tab.4-3 Independent test experiment classification accuracy (mean/std) on SEED and SEED-IV

	Model	delta	theta	alpha	beta	gamma	all
		band	band	band	band	bands	bands
SEED	RTNN[76]	—	—	—	—	—	79.54 /—
	DGCNN[73]	49.79 /10.94	46.36 /12.06	48.29 /12.28	56.15 /14.01	54.87 /17.53	79.95 /09.02
	SVM[77]	43.06 /08.27	40.07 /06.50	43.97 /10.89	48.64 /10.29	51.59 /11.83	56.73 /16.29
	DANN[78]	56.66 /06.48	54.95 /10.45	59.37/ 10.57	67.14/ 07.10	71.30/ 10.84	75.08/ 11.18
	Our	51.54 /10.55	62.96 /05.76	53.48 /11.14	71.44 /08.32	68.00 /09.43	82.33 /04.76
	DGCNN[73]	—	—	—	—	—	52.82 /09.23
	SVM[77]	—	—	—	—	—	37.99 /12.52
	DAN[79]	—	—	—	—	—	58.87 /08.13
	Our	50.61 /09.94	50.58 /10.10	46.43 /07.82	46.40 /09.38	42.79 /05.14	61.34 /07.70
SEED-IV							

4.3.3.2 依赖实验

对于 SEED, SEED-IV, 使用依赖实验的分类来评估本文的模型。具体来说将数据集合并按照 3:7 划分数据集, 70%用于训练模型, 30%用于测试数据。实验结果如表 4-4 所示, 列出所提模型与其他方法的结果对比, 模型在两个数据集上都取得优于其他模型的性能。

表 4-4 SEED 和 SEED-IV 上的依赖实验分类准确率（平均值/标准差）

Tab.4-4 Dependent experiment classification accuracy (mean/std) on SEED and SEED-IV

Model		delta	theta	alpha	beta	gamma	all
		band	band	band	band	bands	bands
SEED	BiDANN[80]	76.97	75.56	81.03	89.65	88.64	92.38
		/10.95	/07.88	/11.74	/09.59	/09.46	/07.04
	RGNN[81]	76.17	72.26	75.33	84.25	89.23	94.24
		/07.91	/07.25	/08.85	/12.54	/08.90	/05.95
	DGCNN[73]	74.25	71.52	74.43	83.65	85.73	90.40
		/11.42	/05.99	/12.16	/10.17	/10.64	/08.49
	SVM[77]	60.50	60.95	66.64	80.76	79.56	83.99
		/14.14	/10.20	/14.41	/11.56	/11.38	/09.92
	Our	89.57	88.78	85.83	93.14	96.59	98.54
		/09.37	/08.54	/11.54	/09.48	/06.62	/01.86
	BiDANN[80]	—	—	—	—	—	70.29
							/12.63
SEED-IV	RGNN[81]	—	—	—	—	—	79.37
							/10.54
	MD-	—	—	—	—	—	87.04
	GCN[82]						/05.21
	DGCNN[73]	—	—	—	—	—	69.88
							/16.29
	Our	67.54	63.30	57.09	68.24	67.79	90.25
		/08.61	/13.31	/13.36	/16.84	/16.60	/12.73

从上述表格可以看出本实验模型在脑电信号情感识别中展现出显著优势，不仅在各频带上实现了高准确率，同时保持了较低的标准差，稳定性和性能均优于现有先进模型，显示出其在处理复杂脑电信号特征时的强大能力和应用潜力。

4.3.3.3 混淆矩阵

混淆矩阵（Confusion Matrix，CM）是评估分类模型性能的关键工具，它通

过表格的形式展示了算法对各个类别的预测准确性。图 4-5 展示本模型的混淆矩阵。从图 4-6 (a) 和图 4-6 (c) 中可以得出, 在 SEED 上, 无论是独立测试实验还是依赖实验, 模型对积极情绪的识别效果比消极情绪和中性情绪的识别效果好。从图 4-6 (b) 和图 4-6 (d) 中可以得出, 在 SEED-IV 上得出了中性情绪的识别效果明显优于其他情绪。说明本模型在区分正负极情感方面表现出色。同时, 它也指出了某些情感类别之间存在一定的交叉重叠, 尤其是在“积极”和“中性”之间, 这一发现表明, 观看积极电影和中性电影的参与者可能会产生相似的脑电图模式。





图 4-6 DST-GCAN 的混淆矩阵

Fig.4-6 Confusion matrix of DST-GCAN


4.3.3.4 ROC 曲线

ROC 曲线, 也称为受试者工作特征曲线, 是统计学中常用的评估分类模型性能的工具。ROC 曲线通过绘制真正率 (True Positive Rate, TPR) 对假正率 (False

Positive Rate, FPR) 的图表来展示分类器随着阈值变化时的性能。ROC 曲线下的面积 (Area Under the Curve, AUC) 常用来量化分类器的性能, AUC 的值介于 0 到 1 之间, 值越大, 模型的性能越好。本文在通过在 SEED 和 SEED-IV 数据集上绘制 ROC 曲线来测试模型的性能, 图 4-7(a) 中展示的是 SEED 数据集 ROC 曲线, 即三种情绪消极、中性和积极的 AUC 的值分别为 0.97、0.98 和 0.99。图 4-7(b) 中展示的是 SEED-IV 数据集 ROC 曲线, 展示了四个不同情绪类别的 ROC 曲线, 其中中性类别的模型表现最优, AUC 值达到 0.99, 而悲伤和积极类别的表现也相当出色, AUC 值分别为 0.97, 恐惧类别稍逊一筹, AUC 值为 0.96。从这些图中可以得出, 该模型在区分不同情绪方面具有较高的准确性和可靠性。



(a) 依赖实验 SEED



(b) 依赖实验 SEED-IV

图 4-7 DST-GCAN 的 ROC 曲线

Fig.4-7 Receiver operating xharacteristic of DST-GCAN

4.3.3.5 敏感性分析

本章分析了模型在不同 L2 权重系数下的性能，如图 4-7 所示。具体来说，当 L2 权重因子从 0 增加到 0.1 时，SEED Independently 的准确性略有下降，但仍保持在 80%以上；SEED Experimental 的准确性基本保持不变，始终接近 100%；SEED-IV Independently 的准确性略有上升，但仍低于 70%；SEED-IV Experimental 的准确性也有所提升，但仍然是最低的。说明权重系数对于该模型来说有一定影响，说明该模型本身具有一定的防止过拟合性能。




图 4-7 L2 权重系数变化时 DST-GCAN 的分类准确率

Fig.4-7 Classification accuracy of DST-GCAN when the L2 weight coefficient changes

4.3.3.6 损失曲线

损失函数（Loss Function）是模型训练组成部分，用于衡量模型预测值与真实值的差异，指导模型优化。本章采用交叉熵损失函数（Cross-Entropy Loss）^[60]，适用于多分类任务。能够量化预测结果与真实结果之间的差异，并通过反向传播优化模型参数，从而提高分类准确性，计算过程如公式 4-6。如图 4-8，4-9 是 SEED 数据集独立测试实验和依赖实验的损失函数曲线。从这两张图中可以得出，在模型训练初期，损失值都较高，接近 0.5。随着训练次数的增加，损失值快速下降，在次数达到 10-20 左右时，损失值降低到了较低的水平。在后续的训练过程中，损失值趋于平稳，波动较小，稳定在 0.02 左右。图 4-10，4-11 则是 SEED-IV 数据集独立测试实验和依赖实验的损失函数曲线。不同于图 4-8 和 4-9，图 4-10 与 4-11 初始损失值都较高，约为 1.2，并在接近 30 次后才降到较低水平，趋于稳定，同样稳定在 0.02 左右。说明模型具有较高的鲁棒性和泛化能力。

$$L = - \sum_{i=1}^n y_i \log \hat{y}_i \quad (4-6)$$

式中 L 表示损失值, $\hat{y}_i$ 表示模型预测样本第 i 类的概率, y_i 表示第 i 类的真实概率。




图 4-8 SEED 独立测试实验损失函数

Figure 4-8 SEED independently testing the loss function of the experiment




图 4-9 SEED 依赖实验损失函数

Figure 4-9 SEED depends on the experimental loss function




图 4-10 SEED-IV 独立测试实验损失函数

Figure 4-10 SEED-IV independently testing the loss function of the experiment




图 4-11 SEED-IV 依赖实验损失函数

Figure 4-11 SEED-IV depends on the experimental loss function

4.4 本章小结

在本章中，提出了一种基于深度学习的 DST-GCAN 神经网络，用于情绪识别。该模型通过结合 DGCNN 和 Transformer 架构，充分发挥了两者的优势。残差连接有效缓解了深层网络中的梯度消失问题，同时增强了特征保留能力。多注意力机制使模型能够关注输入特征的不同部分，从而提升对复杂模式的学习能力。位置编码增强了对时序信息的敏感性，软阈值层实现了特征的稀疏化，提升了模型的泛化能力。可学习的邻接矩阵结合预训练邻接矩阵，使模型更灵活地适应不同图结构。在两个公开数据集 SEED 和 SEED-IV 上进行独立被测实验和依赖实验来对模型进行评估，在独立被测实验中分别取得了 82.33%和 61.36%的准确率，在依赖实验中分别取得 98.54%和 90.25%的准确率，比目前先进的模型的准确率高，证明了模型的有效性和先进性。

第 5 章 脑电数据的多特征融合分类算法

5.1 引言

脑电信号具有高度的复杂性、非线性特征及显著的个体差异性。传统的单一特征分类方法通常仅能捕捉脑电数据的某一维度信息，难以全面表征动态特性。在此背景下，多特征融合分类算法被提出，该算法将脑电数据在时域、频域、空域等多个维度下所呈现出的特征进行融合，为脑电数据的分类提供新的研究方向。本章选用 PSD、DE、差异不对称（differential asymmetry, DASM）、理性不对称（rational asymmetry, RASM）和不对称性度量（Asymmetry Measure, ASM）作为关键特征。PSD 呈现脑电在各频率段的能量分布，不同频率所关联的大脑功能状态；DE 可以量化 EEG 的不确定性与复杂度，在认知任务进程或不同个体执行任务时，能灵活变化，反映大脑实时状态；DASM、RASM 和 ASM 聚焦大脑左右半球功能不对称性，DASM 擅于捕捉单侧半球主导活动中的失衡，RASM 优化不对称信息提取，ASM 衡量整体能量不对称程度。与其他特征相比，这些特征组合形成了立体的多维度描述体系，全面覆盖脑电的时域、频域、空域特性，能够精准的捕捉脑电信号动态变化，从而有效提高分类准确性。

5.2 脑电特征概述

5.2.1 时域特征

时域特征是从 EEG 信号的时间序列数据中提取的统计特征，能够反映信号的幅值变化和分布特性。常见的时域特征包括均值、方差、标准差、均方根值、偏度、峰度、极值、信号能量和零交叉率等。其中，均值和方差描述信号的整体趋势和离散程度，标准差和均方根值用来衡量信号波动性，偏度和峰度反映信号的对称性和尖锐程度，极值表示信号的幅值范围，信号能量和零交叉率用于分析信号的功率和变化趋势。

5.2.2 频域特征

频域特征是通过将 EEG 信号进行傅里叶变换等方法，从不同频率分量中提取的特征，以反映信号在各个频段的能量分布和频率特性。常见的频域特征包括

功率谱密度、平均频率、中心频率、带宽、微分熵等。其中，功率谱密度衡量不同频率成分的能量，平均频率和中心频率分别表示信号的主导频率特征，带宽反映信号频率分布的范围，微分熵衡量信号概率分布的复杂度，能够更稳定地表征 EEG 信号的不确定性。此外，EEG 信号通常被分解为 δ (0.5-4 Hz)、 θ (4-8 Hz)、 α (8-13 Hz)、 β (13-30 Hz) 和 γ (>30 Hz) 等不同频段，每个频段与不同的大脑活动和情感状态相关。频域中本章使用功率谱密度和微分熵两种特征，功率谱密度的计算方法如式 (5-1) 所示^[83]，微分熵计算方法在 3.1.1 中给出。

$$P(f) = |C(f)|^2 \quad (5-1)$$

其中 $C(f)$ 是信号的傅里叶变换（或傅里叶级数），定义为：

$$C(f) = \int_{-\infty}^{\infty} x(t) e^{-i2\pi ft} dt \quad (5-2)$$

式中 $x(t)$ 表示原始时域信号， $e^{-i2\pi ft}$ 是傅里叶变换的核函数。

5.2.3 空域特征

空域特征通过分析 EEG 信号在不同通道上的空间分布，提取脑区间的活动模式和相关性，常见方法共变矩阵、共空间模式、差异不对称、理性不对称、不对称性度量等。其中，共变矩阵衡量不同电极间的统计关系，共空间模式优化特定任务的空间滤波，差异不对称对数据序列进行差分运算后，计算所得差分序列的不对称性特征。理性不对称用于描述大脑左右半球在特定频段（alpha 波、beta 波等）能量分布差异的特征。不对称性度量是脑电信号分析中量化大脑左右半球活动差异的基础特征，通过功率、熵值等指标反映情绪、认知或病理状态下的偏侧化模式。空域中本章使用差异不对称、理性不对称、不对称性度量，用来计算 DE 特征之间的差异和比率^[69]。

计算过程如式 5-3，5-4，5-5 所示：

$$DASM = DE(X_{\text{left}}) - DE(X_{\text{right}}) \quad (5-3)$$

$$RASM = DE(X_{\text{left}}) / DE(X_{\text{right}}) \quad (5-4)$$

$$ASM = \frac{DE(X_{\text{left}}) - DE(X_{\text{right}})}{DE(X_{\text{left}}) + DE(X_{\text{right}})} \quad (5-5)$$

式中 X_{left} ， X_{right} 表示左右半球的电极对

5.3 实验设计

本章使用 SEED 和 SEED-IV 数据集进行实验，提取 DE，PSD，DASM，RASM 和 ASM 特征，应用线性加权融合的方法组合不同的特征集构建新的多特征集。权重初始采用均匀分布，权重总和为 1，后续通过多次实验调整。实验流程图如 5-1 所示。




图 5-1 实验设计流程图

Fig.5-1 Design of experiments flowchart

5.4 实验结果与分析

5.4.1 多特征组合

提取数据集集中的 DE，PSD，DASM，RASM 和 ASM 特征。分别组合作为不同的特征集合，对每个特征集合使用留一法交叉验证进行独立测试实验和选择 70%作为训练集，20%作为验证集进行依赖实验。通过 DST-GCAN 算法对多个数

数据集进行实验，所有特征集分类后的平均准确率见表 5-1 和表 5-2 所示。

表 5-1 SEED 上的独立测试和依赖实验平均分类准确率（平均值/标准差）

Tab.5-1 mean classification accuracy (mean/standard deviation) of independent tests and dependent experiments on SEED

特征组合	独立测试	依赖测试
PSD+DE	78.83/07.94	98.32/03.68
PSD+DASM	76.12/08.87	97.62/04.99
PSD+RASM	76.14/08.24	96.83/05.01
DASM+RASM	67.88/10.29	95.60/08.95
PSD+ASM	79.55/04.50	98.60/02.77
PSD+DASM+RASM	75.84/08.25	97.56/04.04
PSD+DASM+ASM	74.84/10.19	97.71/04.43
PSD+RASM+ASM	74.50/08.38	97.63/04.55
PSD+RASM+ASM+DASM	75.08/06.31	97.65/06.22
DE+RASM+ASM+DASM	72.99/07.44	97.46/05.26

表 5-2 SEED-IV 上的独立测试和依赖实验平均分类准确率（平均值/标准差）

Tab.5-2 mean classification accuracy (mean/standard deviation) of independent tests and dependent experiments on SEED-IV

特征组合	独立测试	依赖测试
PSD+DE	51.90/08.59	84.49/12.72
PSD+DASM	52.70/10.55	86.57/13.10
PSD+RASM	51.97/08.98	80.43/15.50
DASM+RASM	49.82/08.44	79.14/16.53
PSD+ASM	62.01/09.64	90.40/13.34
PSD+DASM+RASM	55.06/12.79	84.96/13.43
PSD+DASM+ASM	54.33/08.37	80.12/14.97
PSD+RASM+ASM	54.30/09.16	83.86/14.30
PSD+RASM+ASM+DASM	55.24/08.70	81.36/16.51
DE+RASM+ASM+DASM	52.77/08.68	80.70/15.79

从表 5-1 和 5-2 中可以看出 PSD+ASM 特征集的分类效果最好, 分别在 SEED 数据集的独立测试和依赖测试中获得 79.55%和 98.60%的分类准确率, 在 SEED-IV 数据集的独立测试和依赖测试中获得 62.01%和 90.40%的分类准确率。DASM+RASM 特征集效果最差, 原因可能在于 DASM 和 RASM 仅反映脑区间的信号不对称性, 可能忽略其他关键特征, 两个特征可能有重叠的信息, 导致模型无法从中提取出足够的有用信息来提高性能。DE+RASM+ASM+DASM 特征集效果相对较低, 原因是特征之间高度相关, 可能会互相干扰, 降低分类效果。

为了更全面地展现所提方法的优势, 本章将实验结果与现有的研究成果进行了对比分析, 比较结果如表 5-3 所示。

表 5-3 实验结果对比

Tab.5-3 comparison of experimental results

特征	分类方法	分类准确率
EMD+CSP	SVM[84]	0.9200
小波包变换	深度信念网络[85]	0.9406
小波包变换和希尔伯特-黄变换	混合分类器 (CNN+RNN+SVM) [86]	0.9345
PSD+ASM	DST-GCAN	0.9860

上述比较分析显示, 本章提出的特征组合相较于现有研究成果, 具有更高的分类精度, 证明该组合的有效性。

5.4.2 混淆矩阵

为进一步展示模型的分类效果, 将通过混淆矩阵进一步分析模型在各个类别上的表现。混淆矩阵能够直观地揭示每个类别的真实标签与预测标签之间的关系, 从而揭示模型在不同情感类别上的识别效果, 特别是其在正确分类与误分类之间的分布情况。在众多实验结果中, 选取分类情况最好以及最差的两种情况, 如图 5-2, 图 5-3 分别展示 SEED 独立测试实验和依赖实验的混淆矩阵, 图 5-4, 图 5-5 分别展示 SEED-IV 独立测试实验和依赖实验的混淆矩阵。




图 5-2 SEED 独立测试实验

Fig.5-2 SEED independent testing experiments




图 5-3 SEED 依赖实验

Fig.5-3 SEED experiment-dependent




图 5-4 SEED-IV 独立测试实验

Fig.5-4 SEED-IV independent testing experiments




图 5-5 SEED-IV 依赖实验

Fig.5-5 SEED-IV experiment-dependent

根据图 5-2 所示的特征集分类实验，无论分类效果的好坏 positive 类的分类准确率都高于 negative 和 neutral 两类。这一现象可能源于 negative 与 neutral 两类样本在形态特征上具有较高相似性，导致分类模型容易产生混淆。混淆矩阵结果进一步印证了这一现象：positive 类别与其他两类之间的误判率显著低于 negative 与 neutral 之间的交叉误判率。

从图 5-3 呈现的结果可知，针对 positive 类别的分类表现同样较优。此外，从表 5-1 中可知整个实验的总体结果基本维持在 95%以上。这一数据清晰地表明，该模型在正确分类样本方面展现出良好的性能，误分类的比例较低，且整体性能较为稳定。

从图 5-4 (b) 可知，模型在 neutral 类别的表现颇为出色，分类效果优于其他类别。但是，模型的总体效果欠佳。这表明 DASM+RASM 在处理 neutral 类时展现出一定优势，具备可取之处。从图 5-5 中可以看出 neutral 类别的分类效果同样优于其他三类，原因在于 neutral 类别情感的定义和边界相对较为明确。在分类任务中，其他三类情感存在不同程度的表现形式，从轻微到强烈，使得模型在判断时容易产生混淆。

5.5 本章小结

本章重点研究多特征提取与融合对脑电信号分类性能的优化作用。分别提取 SEED, SEED-IV 数据集中的 DE, PSD, DASM, RASM, ASM 特征。选择特征

进行组合，并对组合后的特征集进行分类实验，由实验结果可知，最优的脑电特征组合是 PSD+ASM，在 SEED 数据集上的独立测试和依赖测试中取得 79.55% 和 98.60% 的准确率，在 SEED-IV 数据集上的独立测试和依赖测试中取得 62.01% 和 90.40% 的准确率。显著优于其他组合，验证了该特征融合方案对提升脑电分类任务精度与鲁棒性的有效性。

第 6 章 总结和展望

6.1 工作总结

基于生理信号的情感识别越来越受到学者们的关注，特别是利用 EEG 信号进行情感识别的研究成果备受瞩目。如何从 EEG 情感信号中提取出有效的情感特征，以及如何提升 EEG 情感分类的准确性和鲁棒性，依然是该领域研究的关键问题。本研究聚焦于 EEG 信号的情感识别任务，针对传统情感特征表征能力有限、模型泛化性不足等问题，系统探索了神经网络架构设计与多特征组合的优化方法来提高分类的准确性和鲁棒性。具体研究内容如下所述：

(1) 针对传统的脑电数据分类面临多模块间协作不足和模型泛化能力弱等问题，提出了一种基于自注意力的混合神经网络分类算法。采用微分熵特征矩阵的脑电信号提取方法构建三维数据结构 ($4 \times 9 \times 9$)，加强电极通道之间空间信息的相互作用，并通过 CNN 提取关键的空间特征，以及利用自注意力机制和 BLSTM 深入挖掘时间序列的依赖性，从而提高了分类准确率和鲁棒性。在 DEAP 数据集上，该算法在效价和唤醒维度的分类准确率分别达到了 96.75% 和 94.95%，并且在独立测试集上依然保持了高准确率，分别为 93.58% 和 91.42%。这些结果充分证明了模型的有效性和先进性。

(2) 针对脑电数据分类任务中未能充分挖掘 EEG 信号中蕴含的丰富拓扑信息，并且在对信号的长距离依赖和动态变化进行建模时存在局限性，提出了一种基于动态时空图卷积注意力网络模型。该模型通过 Chebyshev 多项式构造图邻接矩阵，捕获 EEG 通道间的复杂关系，学习全局和局部空间特征，并加入残差连接以增强信息流动。随后 Transformer 编码器在 DGCNN 提取的特征基础上，结合多头注意力机制和位置编码，建模 EEG 信号的时间动态特性，增强对长序列数据的表征能力。最后通过全局特征池化结合多层非线性全连接网络，进一步提升情绪分类精度。在公开数据集 SEED 和 SEED-IV 上进行独立被测实验和依赖实验来对模型进行评估，在独立被测实验中分别取得了 82.33% 和 61.36% 的准确率，在依赖实验中分别取得 98.54% 和 90.25% 的准确率。

(3) 研究多特征提取与融合策略对脑电信号分类性能的优化作用。基于

SEED, SEED-IV 数据集, 系统提取了 DE, PSD, DASM, RASM, ASM 特征, 通过对比不同特征组合的分类实验发现, PSD+ASM 的特征集在独立测试和依赖测试中显著优于其他组合, 验证了该特征融合方案对提升脑电分类任务精度与鲁棒性的有效性。

6.2 论文不足与未来展望

6.2.1 论文不足

针对脑电数据分类的模型构造和特征融合算法取得了一些成果, 但研究工作仍有不足之处, 具体表现在下面几个方面:

(1) 多框架融合提高分类性能的同时, 也增加了模型的复杂度, 导致计算效率的下降, 在调整参数时, 可能未能探索所有超参数的最优组合。

(2) 尽管在特征融合过程中已经提取了时频域和空间域的特征, 但所提取的特征种类仍显不足。

6.2.2 未来展望

未来的工作从以下几个方面展开:

(1) 进一步研究不同模块之间的交互关系。优化融合策略, 以实现更好的性能提升。

(2) 提取更多的特征种类, 进行大量的特征算法实验对比, 获取最佳的 EEG 情感特征提取算法。

(3) 使用多模态数据集, 并引入实时性较强的数据集进行实验, 提高模型的普适性和实时性。

(4) 引入迁移学习 (Transfer Learning) 方法, 研究如何将一个数据集上训练的模型迁移到不同受试者或不同数据集上, 以提升模型的泛化能力和跨数据集的适应性。

参考文献

- [1] Ekman P, Friesen W V. Constants across cultures in the face and emotion[J]. Journal of personality and social psychology, 1971, 17(2): 124-129.
- [2] Zhou F, Kong S, Fowlkes C C, et al. Fine-grained facial expression analysis using dimensional emotion model[J]. Neurocomputing, 2020, 392: 38-49.
- [3] 李锦瑶, 杜肖兵, 朱志亮, 等. 脑电情绪识别的深度学习研究综述[J]. 软件学报, 2023, 34(1): 255-276.
- [4] Mu W, Lu B L. Examining four experimental paradigms for EEG-based sleep quality evaluation with domain adaptation[C]//2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC). Montreal, QC, Canada: IEEE, 2020: 5913-5916.
- [5] Fan C, Peng Y, Peng S, et al. Detection of train driver fatigue and distraction based on forehead EEG: a time-series ensemble learning method[J]. IEEE transactions on intelligent transportation systems, 2021, 23(8): 13559-13569.
- [6] Wang T, Huang X, Xiao Z, et al. EEG emotion recognition based on differential entropy feature matrix through 2D-CNN-LSTM network[J]. EURASIP Journal on Advances in Signal Processing, 2024, 2024(1): 1-19.
- [7] Li Y, Zheng W, Zong Y, et al. A bi-hemisphere domain adversarial neural network model for EEG emotion recognition[J]. IEEE Transactions on Affective Computing, 2018, 12(2): 494-504.
- [8] Ma J, Tang H, Zheng W L, et al. Emotion recognition using multimodal residual LSTM network[C]//Proceedings of the 27th ACM international conference on multimedia. Nice: ACM, 2019: 176-183.
- [9] Wang X, Zhang T, Xu X, et al. EEG emotion recognition using dynamical graph convolutional neural networks and broad learning system[C]//2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Madrid, Spain: IEEE, 2018: 1240-1244.
- [10] 田莉莉, 邹俊忠, 张见, 等. 基于改进的卷积神经网络脑电信号情感识别[J]. 计算机工程与应用, 2019, 55(22): 99-105.
- [11] Du X, Ma C, Zhang G, et al. An efficient LSTM network for emotion recognition from multichannel EEG signals[J]. IEEE Transactions on Affective Computing, 2020, 13(3): 1528-1540.
- [12] Tao W, Li C, Song R, et al. EEG-based emotion recognition via channel-wise attention and self attention[J]. IEEE Transactions on Affective Computing, 2020, 14(1): 382-393.
- [13] 陈景霞, 郝为, 张鹏伟, 等. 基于混合神经网络的脑电时空特征情感分类[J]. 软件学报, 2020, 32(12): 3869-3883.
- [14] Li J, Li S, Pan J, et al. Cross-subject EEG emotion recognition with self-organized graph neural network[J]. Frontiers in Neuroscience, 2021, 15: 1-10.
- [15] Fdez J, Guttenberg N, Witkowski O, et al. Cross-subject EEG-based emotion recognition through neural networks with stratified normalization[J]. Frontiers in neuroscience, 2021, 2021(15): 1-10.

- [16] Liu S, Wang X, Zhao L, et al. Subject-independent emotion recognition of EEG signals based on dynamic empirical convolutional neural network[J]. IEEE/ACM transactions on computational biology and bioinformatics, 2021, 18(5): 1710-1721.
- [17] Zhong P, Wang D, Miao C. EEG-based emotion recognition using regularized graph neural networks[J]. IEEE Transactions on Affective Computing, 2022, 13(3): 1290-1301.
- [18] Du G, Su J, Zhang L, et al. A multi-dimensional graph convolution network for EEG emotion recognition[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-11.
- [19] Liu X, Shi R, Hui Q, et al. TCACNet: Temporal and channel attention convolutional network for motor imagery classification of EEG-based BCI[J]. Information Processing & Management, 2022, 59(5): 1-17.
- [20] Liu H, Zhang J, Liu Q, et al. Minimum spanning tree based graph neural network for emotion classification using EEG[J]. Neural Networks, 2022, 145: 308-318.
- [21] 柳长源, 李文强, 毕晓君. 基于 RCNN-LSTM 的脑电情感识别研究[J]. 自动化学报, 2022, 48(3): 917-925.
- [22] Zhong X, Gu Y, Luo Y, et al. Bi-hemisphere asymmetric attention network: recognizing emotion from EEG signals based on the transformer[J]. Applied Intelligence, 2023, 53(12): 15278-15294.
- [23] Zhang Y, Pan Y, Zhang Y, et al. Unsupervised time-aware sampling network with deep reinforcement learning for eeg-based emotion recognition[J]. IEEE Transactions on Affective Computing, 2024, 15(3): 1090-1103.
- [24] Jin M, Du C, He H, et al. PGCN: Pyramidal graph convolutional network for EEG emotion recognition[J]. IEEE Transactions on Multimedia, 2024, 26: 9070-9082.
- [25] Gong L, Chen W, Zhang D. An attention-based multi-domain bi-hemisphere discrepancy feature fusion model for EEG emotion recognition[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 28(10):5890-5903.
- [26] Han L, Zhang X, Yin J. EEG emotion recognition based on the TimesNet fusion model[J]. Applied Soft Computing, 2024, 159: 1-14.
- [27] Cen H M, Zhao M Q, Cui K B, et al. A convolution and attention-based conditional adversarial domain adaptation neural network for emotion recognition using electroencephalography[J]. Biomedical Signal Processing and Control, 2025, 100: 1-13.
- [28] Jin J, Chen W J, Xu R, et al. Multiscale spatial-temporal feature fusion neural network for motor imagery brain-computer interfaces[J]. IEEE Journal of Biomedical and Health Informatics, 2025, 29(1): 198-209.
- [29] Feng B, Zhao J, Fu W. Automated classification of epileptic EEG signals based on multi-feature extraction[C]//2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS). Beijing, China: IEEE, 2018: 382-386.
- [30] Park S H, Lee D, Lee S G. Filter bank regularized common spatial pattern ensemble for small sample motor imagery classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(2): 498-505.
- [31] Mishuhina V, Jiang X. Feature weighting and regularization of common spatial patterns in EEG-based motor imagery BCI[J]. IEEE Signal Processing Letters, 2018,

- 25(6): 783-787.
- [32] Gupta V, Chopda M D, Pachori R B. Cross-subject emotion recognition using flexible analytic wavelet transform from EEG signals[J]. IEEE Sensors Journal, 2019, 19(6): 2266-2274.
- [33] Zeng W, Li M, Yuan C, et al. Classification of focal and non focal EEG signals using empirical mode decomposition (EMD), phase space reconstruction (PSR) and neural networks[J]. Artificial Intelligence Review, 2019, 52: 625-647.
- [34] Ai Q, Chen A, Chen K, et al. Feature extraction of four-class motor imagery EEG signals based on functional brain network[J]. Journal of neural engineering, 2019, 16(2): 1-17.
- [35] 晁浩, 刘永利, 连卫芳. EEG 情感识别中基于集成深度学习模型的多分析域特征融合[J]. 控制与决策, 2020, 35(7): 1674-1680.
- [36] Li Y C, Zhou R G, Xu R Q, et al. A quantum mechanics-based framework for EEG signal feature extraction and classification[J]. IEEE transactions on emerging topics in computing, 2020, 10(1): 211-222.
- [37] Zeng W, Li M, Yuan C, et al. Identification of epileptic seizures in EEG signals using time-scale decomposition (ITD), discrete wavelet transform (DWT), phase space reconstruction (PSR) and neural networks[J]. Artificial Intelligence Review, 2020, 53(4): 3059-3088.
- [38] Albaqami H, Hassan G M, Subasi A, et al. Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree[J]. Biomedical Signal Processing and Control, 2021, 70: 1-9.
- [39] Tuncer T, Dogan S, Acharya U R. Automated EEG signal classification using chaotic local binary pattern[J]. Expert systems with Applications, 2021, 182: 1-8.
- [40] Li C, Zhou W, Liu G, et al. Seizure onset detection using empirical mode decomposition and common spatial pattern[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 458-467.
- [41] Chen C, Li Z, Wan F, et al. Fusing frequency-domain features and brain connectivity features for cross-subject emotion recognition[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-15.
- [42] Zhang S, Zhang Q. A Multidimensional Feature Extraction Method Based on MSTBN and EEMD-WPT for Emotion Recognition from EEG Signals[C]//2022 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Las Vegas, NV, USA: IEEE, 2022: 2042-2048.
- [43] Prabhakar S K, Lee S W. Improved sparse representation based robust hybrid feature extraction models with transfer and deep learning for EEG classification[J]. Expert Systems with Applications, 2022, 198: 1-26.
- [44] 张灵维, 周正东, 许云飞, 等. 基于特征融合的语言想象脑电信号分类[J]. 浙江大学学报(工学版), 2023, 57(4): 726-734.
- [45] Shen J, Zhang Y, Liang H, et al. Exploring the intrinsic features of EEG signals via empirical mode decomposition for depression recognition[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 356-365.
- [46] Xu X, Jia T, Li Q, et al. EEG feature selection via global redundancy minimization for emotion recognition[J]. IEEE Transactions on Affective Computing, 2023,

- 14(1):421-435.
- [47] Jin J, Chen W, Xu R, et al. Multiscale spatial-temporal feature fusion neural network for motor imagery brain-computer interfaces[J]. IEEE Journal of Biomedical and Health Informatics, 2024, 29(1): 198-209.
- [48] Liu J, Yang Y, Li F, et al. An epilepsy detection method based on multi-dimensional feature extraction and dual-branch hypergraph convolutional network[J]. Frontiers in Physiology, 2024, 15: 1-12.
- [49] Luo T. Selective multi-view time-frequency decomposed spatial feature matrix for motor imagery EEG classification[J]. Expert Systems with Applications, 2024, 247: 1-19.
- [50] Irfan M, Wang L S, Shahid H, et al. Multidomain Selective Feature Fusion and Stacking Based Ensemble Framework for EEG-Based Neonatal Sleep Stratification[J]. IEEE Journal of Biomedical and Health Informatics, 2025, 2025: 1-10.
- [51] Zhi H Y, Yu T Y, Gu Z H, et al. Supervised contrastive learning-based domain generalization network for cross-subject motor decoding[J]. IEEE Transactions on Biomedical Engineering, 2025, 72(1): 401-412.
- [52] Wang X Y, Ma Y L, Cammon J, et al. Self-supervised EEG emotion recognition models based on CNN[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 1952-1962.
- [53] Gnog S, Xing K B, Cichocki A, et al. Deep learning in EEG: advance of the last ten-year critical period[J]. IEEE Transactions on Cognitive and Developmental Systems, 2021, 14(2): 348-365.
- [54] Wang T, Huang X Q, Xiao Z N, et al. EEG emotion recognition based on differential entropy feature matrix through 2D-CNN-LSTM network[J]. EURASIP Journal on Advances in Signal Processing, 2024, 49: 1-19.
- [55] Zheng W L, Lu B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. IEEE Transactions on Autonomous Mental Development, 2015, 7(3): 162-175.
- [56] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [57] Li J, Wen Y, He L. Scconv: spatial and channel reconstruction convolution for feature redundancy[C]// Conference on Computer Vision and Pattern Recognition. Vancouver : IEEE, 2023: 6153-6162.
- [58] Li X Q, Li P H, Fang Z D, et al. Research on EEG emotion recognition based on CNN+BiLSTM+self-attention model[J]. Optoelectronics Letters, 2023, 19(8): 506-512.
- [59] Sandoer K, Christian M, Mohammad S. DEAP: a database for emotion analysis using physiological signals [J]. IEEE Transactions on Affective Computing, 2012, 3(1): 18-31.
- [60] Wang J Y, Jang J S R. Training a singing transcription model using connectionist temporal classification loss and cross-entropy loss[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2022, 31: 383-396.

- [61] Zhang Y, Zhang Y, Wang S. An attention-based hybrid deep learning model for EEG emotion recognition[J]. *Signal, Image and Video Processing*, 2023, 17(5): 2305-2313.
- [62] Gao Q, Yang Y, Kang Q, et al. EEG-based emotion recognition with feature fusion networks[J]. *International Journal of Machine Learning and Cybernetics*, 2022, 13(2): 421-429.
- [63] Celebi M, Ozturk S, Kaplan K. An emotion recognition method based on EWT-3D-CNN-BiLSTM-GRU-AT model[J]. *Computers in Biology and Medicine*, 2024, 169: 1-16.
- [64] Jenke R, Peer A, Buss M. Feature extraction and selection for emotion recognition from EEG[J]. *IEEE Transactions on Affective computing*, 2014, 5(3): 327-339.
- [65] Tang C, Wang D, Tan A H, et al. EEG-based emotion recognition via fast and robust feature smoothing[C]//*Brain Informatics: International Conference, BI 2017, Beijing, China: Proceedings*. 2017: 83-92.
- [66] Liu Y, Sourina O. Real-time fractal-based valence level recognition from EEG[C]//*Transactions on computational science XVIII: special issue on Cyberworlds*. Berlin Heidelberg, 2013: 101-120.
- [67] Lin Y P, Wang C H, Jung T P, et al. EEG-based emotion recognition in music listening[J]. *IEEE Transactions on Biomedical Engineering*, 2010, 57(7): 1798-1806.
- [68] Shi L C, Jiao Y Y, Lu B L. Differential entropy feature for EEG-based vigilance estimation[C]//*2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. Osaka, Japan: IEEE, 2013: 6627-6630.
- [69] Albaqami H, Hassan G M, Sunasi A, et al. Automatic detection of abnormal EEG signals using wavelet feature extraction and gradient boosting decision tree[J]. *Biomedical Signal Processing and Control*, 2021, 70: 1-9.
- [70] Zheng W L, Lu B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks[J]. *IEEE Transactions on autonomous mental development*, 2015, 7(3): 162-175.
- [71] Wu X, Zheng W L, Lu B L. Identifying functional brain connectivity patterns for EEG-based emotion recognition[C]//*2019 9th International IEEE/EMBS Conference on Neural Engineering (NER)*. San Francisco, CA, USA: IEEE, 2019: 235-238.
- [72] Li P, Liu H, Si Y, et al. EEG based emotion recognition by combining functional connectivity network and local activations[J]. *IEEE Transactions on Biomedical Engineering*, 2019, 66(10): 2869-2881.
- [73] Song T F, Zheng W M, Song P, et al. EEG emotion recognition using dynamical graph convolutional neural networks[J]. *IEEE Transactions on Affective Computing*, 2020, 11(3): 532-541.
- [74] Xu P, Zhu X T, Clifton D A. Multimodal learning with transformers: A survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(10): 12113-12132.
- [75] Zheng W L, Liu W, Lu Y F, et al. Emotionmeter: A multimodal framework for recognizing human emotions[J]. *IEEE transactions on cybernetics*, 2018, 49(3): 1110-1122.
- [76] Fdez J, Guttenberg N, Witkowski O, et al. Cross-subject EEG-based emotion

- recognition through neural networks with stratified normalization[J]. *Frontiers in neuroscience*, 2021, 15: 1-10.
- [77] Zhong P, Wang D, Miao C. EEG-based emotion recognition using regularized graph neural networks[J]. *IEEE Transactions on Affective Computing*, 2020, 13(3): 1290-1301.
- [78] Ganin Y, Ustinova E, Ajakan H, et al. Domain-adversarial training of neural networks[J]. *Journal of machine learning research*, 2016, 17(59): 1-35.
- [79] Li H, Jin Y M, Zheng W L, et al. Cross-subject emotion recognition using deep adaptation networks[C]//*Neural Information Processing: 25th International Conference*. Siem Reap, Cambodia , 2018: 403-413.
- [80] Li Y, Zheng W M, Zong Y, et al. A Bi-hemisphere Domain Adversarial Neural Network Model for EEG Emotion Recognition[J]. *IEEE Transactions on Affective Computing*, 2021, 12(2): 494-504.
- [81] Zhong P , Wang D, Miao C . EEG-based emotion recognition using regularized graph neural networks[J]. *IEEE Transactions on Affective Computing*, 2020, 13(3): 1290-1301.
- [82] Du G L, Su J S, Zhang L L, et al. A multi-dimensional graph convolution network for EEG emotion recognition[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-11.
- [83] Li D, Yang Z, Hou F, et al. EEG-based emotion recognition with haptic vibration by a feature fusion method[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 1-11.
- [84] 张学军, 黄婉露, 黄丽亚, 等. 公共空间模式算法结合经验模式分解的 EEG 特征提取[J]. *计算机工程与应用*, 2017, 53(13): 9-15.
- [85] 李明爱, 张梦, 孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法 [J]. *电子测量与仪器学报*, 2018, 32(1): 111-118.
- [86] 陈田, 陈占刚, 袁晓辉, 等. 基于脑电信号瞬时能量的情感识别方法[J]. *计算机工程*, 2019, 45(04): 196-204.

攻读学位期间参与的科研项目

- [1]安徽未来技术研究院企业合作项目，脑电数据处理方法研究，编号:2023qyhz13。
- [2]企业横向技术委托开发项目，脑电信号情感分析机器学习算法开发，编号:HX-2024-03-050。

攻读学位期间发表的学术成果

已发表或评审中的论文：

- [1]朱耀,陈乃金,罗桢. 自注意力机制混合神经网络脑电情绪分类算法[J].天津理工大学学报(自然科学版),已在线发表。(第一作者)
- [2] Naijin Chen, Yao Zhu, et al. EEG Data Classification Algorithm Based on the Fusion of DGCNN and Transformer[J]. IEEE TRANSACTIONS ON AFFECTIVE COMPUTING, review. (第二作者，评审中)
- [3] Naijin Chen, Zhen Luo , Yao Zhu. Depression Recognition based on Feature Fusion and Combined classifiers[J]. IEEE TRANSACTIONS ON AFFECTIVE COMPUTING, review.(第三作者，评审中)

已申请的专利：

- [1]陈乃金，朱耀等.一种自注意力机制混合神经网络脑电分类评估方法[P]. CN:发明专利已受理。

致 谢

行文至此，落笔为终。回首三载求学路，感慨良多。值此论文完成之际，谨向所有给予我指导、支持与关怀的师长、亲友致以最诚挚的谢意。

首先，衷心感谢我的导师陈乃金教授。从选题方向到框架搭建，从实验设计到论文修改，导师渊博的学识、严谨的治学态度与精益求精的科研精神令我受益匪浅。求学期间，导师不仅传授专业知识，更以言传身教。每当研究陷入瓶颈时，导师高屋建瓴的指点总能拨云见日，这份师恩学生将永志不忘。

感谢同门胡宇杨、李抗、王静、顾李铭和罗桢给予我的鼓励。在实验设备使用、数据采集与日常研讨中，你们无私分享经验、耐心答疑解惑，同门情谊为这段科研旅程增添了温暖。

深深感恩我的父母和家人。十余载求学路上，你们始终以包容之心尊重我的选择，用无声的支持化解我的焦虑。

最后，向参与论文评审与答辩的各位专家致以崇高敬意，感谢你们在百忙之中拨冗指导。文中不足之处，恳请批评指正。

纸短情长，唯有将感恩之心化为继续前行的动力。谨以此文献给所有照亮我学术之路的明灯。