

基于重构迁移子空间多视角领域 适应的脑电情感分类方法

韩少勇^{1,2}, 周国华^{3,4}, 殷新春⁴

(1. 铜陵学院数学与计算机学院, 安徽铜陵 244061; 2. 郑州银行博士后科研工作站, 河南郑州 450015;
3. 常州工业职业技术学院信息工程学院, 江苏常州 213164; 4. 扬州大学信息工程学院, 江苏扬州 225127)

摘 要: 情感识别是人机交互智能化的关键环节. 脑电(ElectroEncephaloGram, EEG)信号因其蕴含丰富的生物信息且难以伪装, 成为情感分析的重要载体. 然而, EEG 信号特征复杂多变, 且存在显著的个体间差异和时变性, 导致传统机器学习方法的情感分类准确率低、泛化能力差. 针对这一挑战, 本文提出了一种基于重构迁移子空间多视角领域适应(Reconstructed Transfer Subspace based Multi-View Domain Adaptation, RTS-MVDA)方法. 该方法将不同特征视为独立视角, 通过多视角学习探索各视角的独特性和重要性, 并探索其互补关系. 其核心在于将源域与目标域的多视角数据投影到一个带有低秩约束的重构迁移子空间. 在该子空间中, RTS-MVDA 一方面利用重构项恢复原始数据信息, 并通过低秩表示保留主要判别信息; 另一方面, RTS-MVDA 实施线性变换对齐源域和目标域, 减少领域间的分布差异. 此外, RTS-MVDA 构建多视角监督判别项和全局结构保持项, 多视角监督判别项利用源域标签信息增强类内紧凑性和类间分离性, 全局结构保持项保持数据在迁移子空间中的全局结构分布, 从而更有效地将源域的判别知识迁移至目标域. 在公开 DEAP(Database for Emotion Analysis using Physiological signals)数据集上的实验验证表明: 所提 RTS-MVDA 方法在唤醒度和效价维度上分别达到了 73.15% 和 72.91% 的平均准确率, 其 Precision、Recall 和 F_1 -score 指标均显著优于相关对比方法, 有效提升了跨被试 EEG 情感识别的准确性和泛化能力.

关键词: 多视角学习; 领域适应; 子空间; 低秩约束; 脑电(EEG); 情感分类

基金项目: 国家自然科学基金(No.62032005); 铜陵学院人才资助项目(No.2024tlxyrc020); 铜陵学院科研项目(No.2025tlxyxdz051)

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112(2025)08-2830-13

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20250486

Reconstructed Transfer Subspace Based Multi-View Domain Adaptation Method for Electroencephalogram Emotion Classification

HAN Shao-yong^{1,2}, ZHOU Guo-hua^{3,4}, YIN Xin-chun⁴

(1. School of Mathematics and Computer Science, Tongling University, Tongling, Anhui 244061, China;

2. Postdoctoral Scientific Research Workstation, Bank of Zhengzhou, Zhengzhou, Henan 450015, China;

3. Department of Information Engineering, Changzhou Vocational Institute of Industry Technology, Changzhou, Jiangsu 213164, China;

4. College of Information Engineering, Yangzhou University, Yangzhou, Jiangsu 225127, China)

Abstract: Emotion recognition is the key link of intelligent human-computer interaction. Electroencephalogram (EEG) has become an important carrier of emotion analysis because it contains rich biological information and is difficult to disguise. However, EEG signal features are complex and changeable, and there are significant individual differences and time variability, which lead to low accuracy and poor generalization ability of traditional machine learning methods. To address these challenges, this paper proposes a reconstructed transfer subspace based multi view domain adaptation (RTS-MVDA). This method regards different features as independent perspectives, explores the uniqueness and importance of each perspective through multi perspective learning, and mining their complementary relationship. Its core is to project the multi view data of the source domain and the target domain into a reconstruction migration subspace with low-rank constraints. In

this subspace, RTS-MVDA, on the one hand, uses the reconstructed items to restore the original data information, and retains the main discrimination information through the low-rank representation; on the other hand, RTS-MVDA implements linear transformation to align the source domain and target domain, reducing the distribution difference between domains. In addition, RTS-MVDA constructs multi view supervised discriminant and global structure preserving item. The former uses source domain label information to enhance intra class compactness and inter class separation, while the latter maintains the global structure distribution of data in the migration subspace, so as to more effectively migrate the discriminant knowledge of the source domain to the target domain. The experimental verification on the public database for emotion analysis using physiological signals (DEAP) dataset shows that the average accuracy of the proposed RTS-MVDA method in arousal and valence is 73.15% and 72.91%, respectively. Its precision, recall and F_1 -score are significantly better than the related comparison methods, effectively improving the accuracy and generalization ability of cross-subject EEG emotion recognition.

Key words: multi-view learning; domain adaptation; subspace; low-rank constraints; electroencephalogram (EEG); emotion classification

Foundation Item(s): National Natural Science Foundation of China (No.62032005); The Talents Subsidized Project of Tongling University under Grant (No.2024tlxyc020); The Research Project of Tongling University under Grant (No.2025tlxyxdz051)

1 引言

情感作为人类心理与生理活动的复杂体现,反映了主体对外界刺激的主观反应.随着情感计算理论的发展,研究者将其转化为可量化的数字模型,使计算机具备情感辨识与处理能力,为智能化人机交互提供精确的数据支持^[1].目前,情感计算已应用于智能交通、神经工程、医疗健康等多个领域^[2].用户情感数据来源主要包括语音、面部表情以及生理信号等.相较于语音和面部表情,生理信号[如脑电(ElectroEncephaloGram, EEG)、心电和肌电]因其丰富的生物信息更难以伪装,还能避免用户隐私泄露等潜在的问题.在各类生理信号中,EEG通过大脑皮层的电位变化不仅能够准确反映情绪相关的神经活动,还凭借其高时间分辨率、非侵入式采集方式和较低的实施成本,成为情感分析的重要载体^[3-5].

基于EEG的情感分类主要包含3个关键步骤:数据预处理、特征提取和特征分类.特征提取方法主要涵盖时域、频域、时频域以及非线性动力学等维度^[6-8].时域分析方法主要从EEG的几何特征入手,包括直方图分析法、Hjorth参数、分形维数、事件相关电位等^[9].频域分析方法将时域信号转换为多个频带,以分析和提取频域特征^[10].非线性神经动力学特征则研究EEG的复杂动态特性,如微分熵、谱熵、香农熵等熵特征^[11].

基于EEG情感分类的一大挑战是传统的机器学习方法往往局限于单一领域,且高度依赖大量标注数据.然而,在实际应用中,EEG信号易受年龄、心理状态等多种因素影响,具有很强的时变性和个体特异性.而标注EEG资源耗费大且耗时长.如果忽视这些差异直接训练通用模型,会直接影响模型的分类准确度,泛化能力受限.为此,研究者使用迁移学习,将源域中获取的

特征表示和分类知识迁移至目标域^[12-14].迁移学习常用的技术包括:采用最大均值差异或相关特征对齐等度量方法缩小域间分布差异;构建不同领域统一学习框架生成领域不变特征;开发基于集成学习的自适应分类器等.例如,文献[15]提出了一种多源域流形度量迁移学习方法,利用流形特征映射技术将多个领域数据投影到格拉斯曼流形上,并根据马氏距离选择源域,以及利用马氏距离,确保源域和目标域之间的分布相似.文献[16]提出了一种渐进接近引导的目标数据选择方法,根据目标域样本与源聚类的接近程度和模型预测它们的置信度,逐步选择可靠的目标域EEG样本进行训练.这种方法避免了由不同和不可靠的样本引起的负转移.文献[17]提出了一种联合领域不变特征学习和自适应图正则化标签传播方法.通过引入软标签的概念,该方法建立了一个领域联合分布测量模型,以同时减轻不同被试、会话之间的边缘和条件分布差异.此外,该方法还构建了一个自适应概率图模型,以提高EEG标签传播的鲁棒性.近年来,迁移学习在脑机接口(Brain Computer Interface, BCI)领域展现出广阔的应用前景.除情感分类外,迁移学习在运动想象任务^[18,19]、事件相关电位检测^[20,21]、疲劳驾驶检测^[22,23]、疾病检测^[24,25]等方面均展开了大量的研究.

尽管迁移学习在跨被试EEG情感分类任务中取得了显著成效,但当前研究仍存在明显的视角局限性.绝大多数研究仅关注单一特征的EEG信号分析,由于EEG波形的形态复杂且具有内在的非平稳、非线性和非高斯特征,单一特征信息往往不足以支持高精度的情感分类.多数多特征方法仅采用简单的特征级串联,未能深入挖掘不同EEG的时空关系.因此,如何在迁移学习中有效利用多维度特征是EEG情感分类中亟需解决的

问题. 针对上述问题, 本文提出了一种基于重构迁移子空间多视角领域适应 (Reconstructed Transfer Subspace based Multi-View Domain Adaptation, RTS-MVDA) 方法, 用于跨领域 EEG 情感分类. 其结构示意图如图 1 所示, 其中多视角监督判别项中的蓝色和红色箭头分别表示类内聚集和类间互斥; 全局结构保持项中的粉色箭头表示样本与其近邻的表示关系. RTS-MVDA 方法通过将源域与目标域的多视角数据映射至带有低秩约束的迁移子空间, 实现了多领域数据的重构与对齐. 具体而言, RTS-MVDA 方法一方面利用重构项恢复原始数据, 同时通过潜在表示低秩项保留数据的主要判别信息; 另一方面, 在迁移子空间内实施线性变换, 有效缩小源域与目标域之间的分布差异. 此外, RTS-MVDA 构建多视角监督判别项挖掘数据的判别信息, 使得同一类别中的子空间潜在表示在相互接近, 而不同类别的子空间潜在表示彼此远离; 构建全局结构保持项捕捉数据在迁移子空间中的全局结构分布信息. 公开 DEAP 数据集^[26]上进行 EEG 情感分类实验, RTS-MVDA

方法在唤醒度与效价上的 Accuracy、Precision、Recall 和 F_1 -score 均取得了最佳分类结果.

本文的贡献在于:

(1) 针对 EEG 信号特征复杂多变及个体特异性导致的分类准确率低下问题, 本文提出了一种结合多视角学习与领域适应相结合的新方法, 通过迁移源域的判别知识至目标域, 有效缩减了 EEG 数据分布的差异, 从而提升在跨领域应用中的泛化能力与分类精度.

(2) RTS-MVDA 方法将每种特征视为独立视角, 迁移子空间中的多视角潜在表示不仅深入探索了每个视角的独特性与重要性, 还揭示了不同视角间的互补关系. 同时, RTS-MVDA 通过自适应权重机制, 灵活调整各视角的贡献度, 确保了模型的最优决策.

(3) RTS-MVDA 不仅将局部信息和全局信息结合起来得到更有意义的低维表示, 还充分挖掘源域的监督信息, 通过多视角监督判别项和全局结构保持项进一步提升了 EEG 的分类准确性.

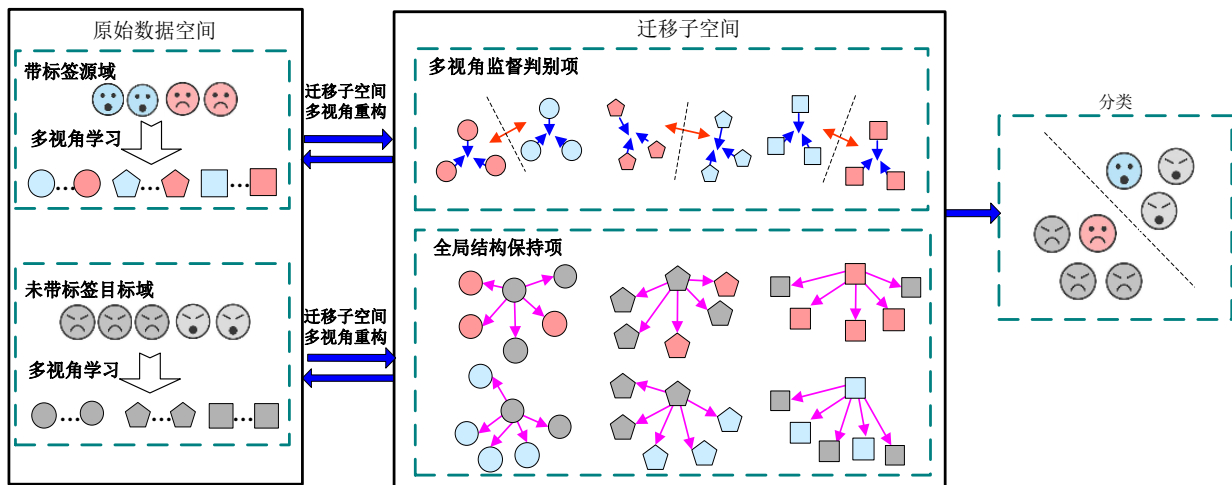


图 1 RTS-MVDA 方法结构示意图

2 相关工作

源域 X_s 和目标域 X_t 具有相同的特征空间和标签空间, 但特征分布不同. 迁移子空间学习的核心目标是通过投影矩阵将 X_s 和 X_t 映射到一个共同的特征空间, X_t 能够被 X_s 准确重构, 两个域的数据分布能够有效对齐, 从而实现跨域知识的有效迁移, 即 $PX_t = PX_s Z$, 其中 P 和 Z 分别为投影矩阵和重构系数矩阵. 对重构系数矩阵 Z 施加低秩约束, 不仅可以使每个目标域样本仅由最具代表性的少量源域样本进行重构, 还有利于发现潜在的类别信息. 因此, Z 具有块对角结构. 子空间迁移学习^[27,28]表示为

$$\begin{aligned} \min_{P, Z} \text{rank}(Z) \\ \text{s.t. } PX_t = PX_s Z \end{aligned} \quad (1)$$

由于秩最小化问题是非凸的, 式(1)是一个非确定性多项式时间 (Nondeterministic Polynomial time, NP) 难题, 难以直接优化. 为此, 使用核范数代替 $\text{rank}(\cdot)$ 运算. 为了增强 X_s 和 X_t 之间的相关性, 对 Z 施加 ℓ_1 -稀疏约束用于保持数据的局部流形结构. 因此, 式(1)表示为:

$$\begin{aligned} \min_{P, Z} \|Z\|_* + \alpha \|Z\|_1 \\ \text{s.t. } PX_t = PX_s Z \end{aligned} \quad (2)$$

其中, α 为平衡参数.

3 基于 RTS-MVDA 方法

3.1 迁移子空间的多视角重构项

设源域 X_s 和目标域 X_t 包括 V 个视角数据, 分别表示为 $\{X_s^v\}_{v=1}^V \in \mathbb{R}^{d_s \times n_s}$ 和 $\{X_t^v\}_{v=1}^V \in \mathbb{R}^{d_t \times n_t}$, V 个视角的 X_s^v 有一致的类别标签 $Y \in \mathbb{R}^{K \times n_s}$, 其中, n_s 和 n_t 分别为源域和目标域的样本数量, K 和 d_v 分别为样本类别数和第 v 个视角数据维数. 首先, RTS-MVDA 将每个视角的 X_s^v 和 X_t^v 投影到迁移子空间且目标域样本能够通过源域样本线性表示. 设 $\{P_s^v\}_{v=1,2,\dots,V} \in \mathbb{R}^{m_v \times d_s}$ 和 $\{P_t^v\}_{v=1,2,\dots,V} \in \mathbb{R}^{m_v \times d_t}$ 分别表示第 v 个视角 X_s^v 和 X_t^v 的投影矩阵, 根据子空间迁移学习思想可以得到 $P_t^v X_t^v = P_s^v X_s^v Z^v$, 其中 $\{Z^v\}_{v=1,2,\dots,V} \in \mathbb{R}^{m_v \times n_t}$ 为第 v 个视角数据的重构系数矩阵, m_v 为第 v 个视角子空间的维数. 与式(1)中不同领域共享同一个投影矩阵不同, RTS-MVDA 赋予 X_s^v 和 X_t^v 不同的投影矩阵, 能够得到更灵活的学习模型. 此外, 为了在迁移子空间对齐每个视角的不同领域数据, RTS-MVDA 构建投影对齐项并最小化投影矩阵之间的差异^[29], 即 $\|P_s^v - P_t^v\|_F^2$.

其次, RTS-MVDA 在迁移子空间中通过正则化来重构原始数据 X_s^v 和 X_t^v , 重构部分可以视为一个正则化项, 迁移子空间的潜在表示能够保留原始数据的本质信息. 在 EEG 情感分类中, 由于类别的数量小于训练样本的数量和潜在表示的维度, 因此潜在表示应该具有低秩特性. 设 $L_s^v \in \mathbb{R}^{m_v \times n_s}$ 和 $L_t^v \in \mathbb{R}^{m_v \times n_t}$ 分别表示 X_s^v 和 X_t^v 在迁移子空间的潜在表示, 潜在表示低秩项表示为 $\text{rank}(L_s^v) + \text{rank}(L_t^v)$.

再次, 对于多视角数据而言, 不同视角具有不同的模型贡献和判别能力. 同时, 不同视角之间也存在特征差异. 为此, RTS-MVDA 方法使用自适应权重矩阵 $\alpha = [\alpha^1, \alpha^2, \dots, \alpha^V]$ 自适应地学习每个视角的权重, 平衡不同视角的重要性.

基于上述思想, 迁移子空间的多视角重构项表示为

$$\begin{aligned} \min_{P, L, Z, \alpha} \sum_{v=1}^V (\alpha^v)^c \left\{ \|P_s^v X_s^v - L_s^v\|_F^2 + \|X_s^v - P_s^{vT} L_s^v\|_F^2 \right. \\ \left. + \|P_t^v X_t^v - L_t^v\|_F^2 + \|X_t^v - P_t^{vT} L_t^v\|_F^2 + \lambda \|P_s^v - P_t^v\|_F^2 \right\} \\ + \sum_{v=1}^V \left\{ \tau (\|Z^v\|_* + \|Z^v\|_1) + \eta (\text{rank}(L_s^v) + \text{rank}(L_t^v)) \right\} \quad (3) \\ \text{s.t. } P_t^v X_t^v = P_s^v X_s^v Z^v, \\ P_s^{vT} P_s^v = I, P_t^{vT} P_t^v = I, \\ \sum_{v=1}^V \alpha^v = 1, \alpha^v \geq 0 \end{aligned}$$

其中, 约束条件 $P_s^{vT} P_s^v = I$ 和 $P_t^{vT} P_t^v = I$ 确保投影矩阵是正交基变换矩阵; λ , τ 和 η 为平衡参数; c 为自适应权重因子.

令 $P^v = [P_s^v, P_t^v]$, $L^v = [L_s^v, L_t^v]$, $X^v = \begin{bmatrix} X_s^v & \mathbf{0} \\ \mathbf{0} & X_t^v \end{bmatrix}$, 根据矩阵低秩的基本原理 $\text{rank}(A+B) \leq \text{rank}(A) + \text{rank}(B)$. 若

$\text{rank}(A+B) = \text{rank}(A) + \text{rank}(B)$, 当且仅当: 矩阵 A 和 B 的行空间交集为 $\mathbf{0}$, A 和 B 的列空间交集为 $\mathbf{0}$. 显然, 源域和目标域的潜在表示没有交集, 可以得到 $\text{rank}(L_s^v) + \text{rank}(L_t^v) = \text{rank}(L^v)$. 与式(1)类似, 本文采用核范数对 $\text{rank}()$ 函数凸松弛近似. 因此, 式(3)可以简化为

$$\begin{aligned} \min_{P, L, Z, \alpha} \sum_{v=1}^V (\alpha^v)^c \left\{ \|P^v X^v - L^v\|_F^2 + \|X^v - P^{vT} L^v\|_F^2 + \lambda \|P_s^v - P_t^v\|_F^2 \right\} \\ + \sum_{v=1}^V \left\{ \tau (\|Z^v\|_* + \|Z^v\|_1) + \eta \|L^v\|_* \right\} \quad (4) \\ \text{s.t. } P_t^v X_t^v = P_s^v X_s^v Z^v, \\ P^{vT} P^v = I, \\ \sum_{v=1}^V \alpha^v = 1, \alpha^v \geq 0 \end{aligned}$$

3.2 多视角监督判别项

为了提升模型分类性能, RTS-MVDA 利用源域的监督信息捕捉数据的类间差异和类内相似, 由此构建多视角监督判别项. 源域的多视角监督判别项由 2 部分构成: 多视角线性判别分析 (Linear Discriminant Analysis, LDA) 项和多视角潜在表示一致项.

源域 X_s^v 的类内散度和类间散度分别为 S_w^v 和 S_b^v :

$$S_w^v = \sum_{k=1}^K \sum_{l_s^v \in L_s^v} (l_{si}^v - \bar{l}_{sk}^v)(l_{si}^v - \bar{l}_{sk}^v)^T \quad (5)$$

$$S_b^v = \sum_{k=1}^K n_{sk} (\bar{l}_{sk}^v - \bar{l}_s^v)(\bar{l}_{sk}^v - \bar{l}_s^v)^T \quad (6)$$

其中, \bar{l}_{sk}^v 为 X_s^v 中第 k 类样本的平均潜在表示; \bar{l}_s^v 为 X_s^v 中所有样本的平均潜在表示; n_{sk} 为 X_s^v 第 k 个类样本的数量.

源域多视角 LDA 项的目的是学习强判别力的投影矩阵, 使得不同类别的数据投影类内高度聚合和类间差异大. 源域多视角 LDA 项表示为

$$\min_{P_s} \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) \quad (7)$$

为了更深入地挖掘判别信息, RTS-MVDA 方法构建了多视角潜在表示一致项. 本文认为, 源域多视角的潜在表示尽管来自多个视角数据, 但相同类别的潜在表示应尽可能地紧密聚集, 而不同类别的潜在表示应尽可能地相互分离. 多视角潜在表示一致项表示为

$$\min_{L_s} \sum_{v=1}^V \|L_s^{vT} L_s^v - Y^T Y\|_F^2 \quad (8)$$

结合式(7)和式(8)并考虑视角的权重, 多视角监督判别项表示为

$$\begin{aligned} \min_{L_s, P_s} (\alpha^v)^c \left\{ \beta \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) \right. \\ \left. + \gamma \|L_s^{vT} L_s^v - Y^T Y\|_F^2 \right\} \quad (9) \end{aligned}$$

其中, β 和 γ 为平衡参数.

3.3 全局结构保持项

在迁移学习中, 如果不同领域数据被投影到子空间, 那么在这个子空间中两个领域的分布应趋于相同,

X^v 中每个样本的潜在表示均可以由其近邻的潜在表示组合来表示. 为此, 在每个视角内构建全局 k 近邻图 W^v, W^v 的元素 w_{ij}^v 定义为

$$w_{ij}^v = \begin{cases} 1, & I_i^v \in N_k(I_j^v) \text{ or } I_j^v \in N_k(I_i^v) \\ 0, & \text{otherwise} \end{cases} \quad (10)$$

其中, $N_k(x)$ 函数返回 x 的 k 个近邻.

传统 k 近邻图的构建使用原始样本, 而 RTS-MVDA 方法使用潜在表示, 这是因为经过迁移子空间投影, 潜在表示更能代表样本特征, 也更具鲁棒性. 直观地说, 当两个潜在表示 I_i^v 和 I_j^v 相似, 意味着当它们之间的距离很小时, 更有可能共享相同的类别. 因此, 与它们的连接相对应的权重 w_{ij}^v 应当较大. 相反, 若 I_i^v 和 I_j^v 不同, 则 w_{ij}^v 应当较小, 以表明它们的无关性. 每个视角的全局结构保持项表示为

$$\min_L \sum_{i,j=1}^n w_{ij}^v \|I_i^v - I_j^v\|_2^2 = \text{Tr}(L^v D^v L^{vT}) \quad (11)$$

其中, 拉普拉斯矩阵为 $D^v = M^v - W^v$; M^v 为对角线矩阵, 其对角元素是矩阵 W^v 的各行元素之和.

3.4 目标函数及参数优化

将迁移子空间的多视角重构项、多视角监督判别项和全局结构保持项结合, RTS-MVDA 的目标函数 J 表示为

$$\begin{aligned} \min_{P, L, Z, \alpha} \sum_{v=1}^V (\alpha^v)^c \left\{ \|P^v X^v - L^v\|_F^2 + \|X^v - P^{vT} L^v\|_F^2 + \lambda \|P_s^v - P_t^v\|_F^2 \right. \\ \left. + \beta \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) + \gamma \|L_s^{vT} U_s^v - Y^T Y\|_F^2 \right\} \\ + \sum_{v=1}^V \left\{ \tau (\|Z^v\|_* + \|Z^v\|_1) + \eta \|L^v\|_* + \mu \text{Tr}(L^{vT} D_s^v L^v) \right\} \\ \text{s.t. } P_s^v X_s^v Z^v = P_t^v X_t^v \\ P_s^{vT} P_s^v = I, P_t^{vT} P_t^v = I \\ \sum_{v=1}^V \alpha^v = 1, \alpha^v \geq 0 \end{aligned} \quad (12)$$

其中, μ 为平衡参数.

本文使用交替方向乘子法方法, 通过交替方向迭代的策略来实现目标函数的最小化. 引入辅助变量 U_s^v, Z_1^v 和 Z_2^v , RTS-MVDA 的目标函数表示为

$$\begin{aligned} \min_{P, L, Z, \alpha} \sum_{v=1}^V (\alpha^v)^c \left\{ \|P^v X^v - L^v\|_F^2 + \|X^v - P^{vT} L^v\|_F^2 + \lambda \|P_s^v - P_t^v\|_F^2 \right. \\ \left. + \beta \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) + \gamma \|L_s^{vT} U_s^v - Y^T Y\|_F^2 \right\} \\ + \sum_{v=1}^V \left\{ \tau (\|Z_1^v\|_* + \|Z_2^v\|_1) + \eta \|L^v\|_* + \mu \text{Tr}(L^{vT} D_s^v L^v) \right\} \\ \text{s.t. } P_s^v X_s^v Z^v = P_t^v X_t^v \\ P_s^{vT} P_s^v = I, P_t^{vT} P_t^v = I \\ \sum_{v=1}^V \alpha^v = 1, \alpha^v \geq 0 \\ U_s^v = L_s^v, Z_1^v = Z^v, Z_2^v = Z^v \end{aligned} \quad (13)$$

式(13)的增广拉格朗日可以表示为

$$\begin{aligned} L = \sum_{v=1}^V (\alpha^v)^c \left\{ \|P_s^v X_s^v - L^v\|_F^2 + \|X^v - P^{vT} L^v\|_F^2 + \gamma \|P_s^v - P_t^v\|_F^2 \right\} \\ + \beta \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) + \gamma \|L_s^{vT} U_s^v - Y^T Y\|_F^2 \\ + \sum_{v=1}^V \left\{ \tau (\|Z_1^v\|_* + \|Z_2^v\|_1) + \eta \|L^v\|_* + \mu \text{Tr}(L^{vT} D_s^v L^v) \right\} \\ \cdot \left\langle \Theta_1, P_t^v X_t^v - P_s^v X_s^v Z^v + \frac{\Theta_1}{\xi_1} \right\rangle + \langle \Theta_2, L_s^v - U_s^v \rangle \\ + \langle \Theta_3, Z^v - Z_1^v \rangle + \langle \Theta_4, Z^v - Z_2^v \rangle + \frac{\xi_1}{2} \|P_t^v X_t^v - P_s^v X_s^v Z^v\|_F^2 \\ + \frac{\xi_2}{2} \left(\sum_{v=1}^V (\alpha^v - 1) + \frac{\xi_3}{2} (\|L_s^v - U_s^v\|_F^2 + \|Z^v - Z_1^v\|_F^2 + \|Z^v - Z_2^v\|_F^2) \right) \\ \text{s.t. } P_s^{vT} P_s^v = I, P_t^{vT} P_t^v = I, v=1, 2, \dots, V \end{aligned} \quad (14)$$

其中, $\Theta_1, \Theta_2, \Theta_3$ 和 Θ_4 为拉格朗日乘子; ξ_1, ξ_2 和 ξ_3 为惩罚参数.

(1) 更新投影矩阵 P^v

对于源域 X_s^v 的投影矩阵 P_s^v , 其目标函数为

$$\begin{aligned} \min_{P_s^v, P_t^v} (\alpha^v)^c \left\{ \|P_s^v X_s^v - L^v\|_F^2 + \|X_s^v - P_s^{vT} L^v\|_F^2 \right. \\ \left. + \beta \text{Tr}(P_s^v (S_w^v - S_b^v) P_s^{vT}) \right\} \\ + \lambda \|P_s^v - P_t^v\|_F^2 + \frac{\xi_1}{2} \left\| P_t^v X_t^v - P_s^v X_s^v Z^v + \frac{\Theta_1}{\xi_1} \right\|_F^2 \end{aligned} \quad (15)$$

对 P_s^v 一阶求导, 可得, $P_s^v A^v + B^v P_s^v = C^v$, 其中, $A^v = 2(\alpha^v)^c (\beta(S_w^v - S_b^v) + X_s^v X_s^{vT}) - \xi_1 X_s^v Z^v Z^v X_s^{vT}$, $B^v = 2((\alpha^v)^c L_s^v L_s^{vT} + \lambda I)$, $C^v = 4(\alpha^v)^c L_s^v X_s^{vT} - (\xi_1 P_t^v X_t^v + \Theta_1) Z_s^{vT} X_s^{vT} + 2\lambda P_t^v$. 式(15)是典型的西尔维斯特方程, P_s^v 可以通过 Bartels-Stewart 算法^[30]求解.

对于目标域 X_t^v 的投影矩阵 P_t^v , 其目标函数为

$$\begin{aligned} \min_{P_s^v, P_t^v} (\alpha^v)^c \left\{ \|P_t^v X_t^v - L^v\|_F^2 + \|X_t^v - P_t^{vT} L^v\|_F^2 \right\} \\ + \lambda \|P_s^v - P_t^v\|_F^2 + \frac{\xi_1}{2} \left\| P_t^v X_t^v - P_s^v X_s^v Z^v + \frac{\Theta_1}{\xi_1} \right\|_F^2 \end{aligned} \quad (16)$$

对 P_t^v 一阶求导, 可得

$$P_t^v E^v + F^v P_t^v = G^v \quad (17)$$

其中, $E^v = 2(\alpha^v)^c - \xi_1 X_t^v X_t^{vT}$, $F^v = 2((\alpha^v)^c L_t^v L_t^{vT} + \lambda I)$, $G^v = 4(\alpha^v)^c L_t^v X_t^{vT} - (\xi_1 P_s^v X_s^v Z^v + \Theta_1) X_t^{vT} + 2\lambda P_s^v$.

同样, 式(17)也是一个西尔维斯特方程, P_t^v 可以通过 Bartels-Stewart 算法求解.

(2) 更新重构系数 Z^v

对目标函数中的 Z^v 相关项合并, 关于 Z^v 的目标式为

$$\begin{aligned} \min_{Z^v} \frac{\xi_1}{2} \|P_t^v X_t^v - P_s^v X_s^v Z^v\|_F^2 \\ + \langle \Theta_1, P_t^v X_t^v - P_s^v X_s^v Z^v \rangle \\ + \langle \Theta_3, Z^v - Z_1^v \rangle + \langle \Theta_4, Z^v - Z_2^v \rangle \\ + \frac{\xi_3}{2} (\|Z^v - Z_1^v\|_F^2 + \|Z^v - Z_2^v\|_F^2) \end{aligned} \quad (18)$$

对 Z^v 一阶求导, 可得

$$\mathbf{Z}^v = (\zeta_1 \mathbf{X}_s^{vT} \mathbf{P}_s^v \mathbf{P}_s^v \mathbf{X}_s^v + 2\zeta_3 \mathbf{I})^{-1} \left(\mathbf{Z}_1^v - \frac{\boldsymbol{\Theta}_3}{\zeta_3} + \mathbf{Z}_2^v - \frac{\boldsymbol{\Theta}_3}{\zeta_3} - \mathbf{X}_s^{vT} \mathbf{P}_s^{vT} \left(\mathbf{P}_t^v \mathbf{X}_t^v + \frac{\boldsymbol{\Theta}_1}{\zeta_1} \right) \right) \quad (19)$$

(3)更新潜在表示 \mathbf{L}^v

对于源域 \mathbf{X}_s^v 的潜在表示 \mathbf{L}_s^v , 其目标函数为

$$\min_{\mathbf{L}_s^v} \sum_{v=1}^V (\alpha^v)^c \left\{ \left\| \mathbf{P}_s^v \mathbf{X}_s^v - \mathbf{L}_s^v \right\|_F^2 + \left\| \mathbf{X}_s^v - \mathbf{P}_s^{vT} \mathbf{L}_s^v \right\|_F^2 + \gamma \left\| \mathbf{L}_s^{vT} \mathbf{U}_s^v - \mathbf{Y}^T \mathbf{Y} \right\|_F^2 \right\} + \left\{ \eta \left\| \mathbf{L}_s^v \right\|_* + \mu \text{Tr}(\mathbf{L}_s^{vT} \mathbf{D}_s^v \mathbf{L}_s^v) \right\} + \left\langle \boldsymbol{\Theta}_2, \mathbf{L}_s^v - \mathbf{U}_s^v \right\rangle + \frac{\zeta_3}{2} \left\| \mathbf{L}_s^v - \mathbf{U}_s^v \right\|_F^2 \quad (20)$$

根据核范数定义, 可得 $\left\| \mathbf{L}_s^v \right\|_* = \text{Tr}(\mathbf{L}_s^{vT} (\mathbf{L}_s^v \mathbf{L}_s^{vT})^{-1/2} \mathbf{L}_s^v) = \text{Tr}(\mathbf{L}_s^{vT} \bar{\mathbf{L}}_s^v - 1/2 \mathbf{L}_s^v)$, 其中 $\bar{\mathbf{L}}_s^v = (\mathbf{L}_s^v \mathbf{L}_s^{vT})^{-1/2}$. 对 \mathbf{L}_s^v 一阶求导, 可得 $\mathbf{L}_s^v = ((2(\alpha^v)^c + \zeta_3) \mathbf{I} + 2(\alpha^v)^c (\gamma \mathbf{U}_s^v \mathbf{U}_s^{vT} + \mathbf{P}_s^v \mathbf{P}_s^{vT}) + \eta \bar{\mathbf{L}}_s^v + \mu \mathbf{D}_s^v)^{-1} (4(\alpha^v)^c \mathbf{P}_s^v \mathbf{X}_s^v + \zeta_3 \mathbf{U}_s^v - \boldsymbol{\Theta}_2 + 2\gamma(\alpha^v)^c \mathbf{U}_s^v \mathbf{Y}^T \mathbf{Y})$ (21)

对于目标域 \mathbf{X}_t^v 的潜在表示 \mathbf{L}_t^v , 其目标函数为

$$\min_{\mathbf{L}_t^v} \sum_{v=1}^V (\alpha^v)^c \left\{ \left\| \mathbf{P}_t^v \mathbf{X}_t^v - \mathbf{L}_t^v \right\|_F^2 + \left\| \mathbf{X}_t^v - \mathbf{P}_t^{vT} \mathbf{L}_t^v \right\|_F^2 \right\} + \sum_{v=1}^V \left\{ \eta \left\| \mathbf{L}_t^v \right\|_* + \mu \text{Tr}(\mathbf{L}_t^{vT} \mathbf{D}_t^v \mathbf{L}_t^v) \right\} \quad (22)$$

对 \mathbf{L}_t^v 一阶求导, 可得

$$\mathbf{L}_t^v = (2(\alpha^v)^c (\mathbf{I} + \mathbf{P}_s^v \mathbf{P}_s^{vT}) + \eta \bar{\mathbf{L}}_t^v + \mu \mathbf{D}_t^v)^{-1} (4(\alpha^v)^c \mathbf{P}_s^v \mathbf{X}_s^v) \quad (23)$$

(4)更新权重矩阵 α . 关于 α^v 的目标函数为

$$\min_{\alpha^v} \sum_{v=1}^V (\alpha^v)^c \left\{ \left\| \mathbf{P}^v \mathbf{X}^v - \mathbf{L}^v \right\|_F^2 + \left\| \mathbf{X}^v - \mathbf{P}^{vT} \mathbf{L}^v \right\|_F^2 + \lambda \left\| \mathbf{P}_s^v - \mathbf{P}_t^v \right\|_F^2 + \beta \text{Tr}(\mathbf{P}_s^v (\mathbf{S}_w^v - \mathbf{S}_b^v) \mathbf{P}_s^{vT}) + \gamma \left\| \mathbf{L}_s^{vT} \mathbf{U}_s^v - \mathbf{Y}^T \mathbf{Y} \right\|_F^2 \right\} + \frac{\zeta_2}{2} \left(\sum_{v=1}^V \alpha^v - 1 \right) \quad (24)$$

对 α^v 一阶导数, 经过整理可以得到

$$\alpha^v = (\mathbf{W}^v)^{\frac{1}{1-c}} / \sum_{v=1}^V (\mathbf{W}^v)^{\frac{1}{1-c}} \quad (25)$$

其中, $\mathbf{W}^v = \left\| \mathbf{P}^v \mathbf{X}^v - \mathbf{L}^v \right\|_F^2 + \left\| \mathbf{X}^v - \mathbf{P}^{vT} \mathbf{L}^v \right\|_F^2 + \lambda \left\| \mathbf{P}_s^v - \mathbf{P}_t^v \right\|_F^2 + \beta \text{Tr}(\mathbf{P}_s^v (\mathbf{S}_w^v - \mathbf{S}_b^v) \mathbf{P}_s^{vT}) + \gamma \left\| \mathbf{L}_s^{vT} \mathbf{U}_s^v - \mathbf{Y}^T \mathbf{Y} \right\|_F^2$.

(5)更新辅助变量 \mathbf{U}_s^v , \mathbf{Z}_1^v 和 \mathbf{Z}_2^v

关于 \mathbf{U}_s^v 的目标函数为

$$\min_{\mathbf{U}_s^v} \sum_{v=1}^V (\alpha^v)^c \left\{ \left\| \mathbf{L}_s^{vT} \mathbf{U}_s^v - \mathbf{Y}^T \mathbf{Y} \right\|_F^2 + \left\langle \boldsymbol{\Theta}_2, \mathbf{L}_s^v - \mathbf{U}_s^v \right\rangle + \frac{\zeta_3}{2} \left\| \mathbf{L}_s^v - \mathbf{U}_s^v \right\|_F^2 \right\} \quad (26)$$

对 \mathbf{U}_s^v 一阶求导, 可得

$$\mathbf{U}_s^v = (\gamma(\alpha^v)^c \mathbf{L}_s^v \mathbf{L}_s^{vT} + \zeta_3 \mathbf{I})^{-1} (\gamma(\alpha^v)^c \mathbf{L}_s^{vT} \mathbf{Y}^T \mathbf{Y} + \zeta_3 \mathbf{L}_s^v + \boldsymbol{\Theta}_2) \quad (27)$$

将目标函数中的 \mathbf{Z}_1^v 相关项合并, 关于 \mathbf{Z}_1^v 的目标函数为

$$\min_{\mathbf{Z}_1^v} \tau \left\| \mathbf{Z}_1^v \right\|_* + \left\langle \boldsymbol{\Theta}_3, \mathbf{Z}^v - \mathbf{Z}_1^v \right\rangle + \frac{\zeta_3}{2} \left\| \mathbf{Z}^v - \mathbf{Z}_1^v \right\|_F^2 \quad (28)$$

对 \mathbf{Z}_1^v 一阶求导, 可得

$$\mathbf{Z}_1^v = S_{\tau/\zeta_3}(\mathbf{Z}^v + \boldsymbol{\Theta}_3/\zeta_3) \quad (29)$$

其中, $S_{\zeta}(\cdot)$ 是软阈值算子.

将目标函数中的 \mathbf{Z}_2^v 相关项合并, 关于 \mathbf{Z}_2^v 的目标函数为

$$\min_{\mathbf{Z}_2^v} \left\| \mathbf{Z}_2^v \right\|_1 + \left\langle \boldsymbol{\Theta}_4, \mathbf{Z}^v - \mathbf{Z}_2^v \right\rangle + \frac{\zeta_3}{2} \left\| \mathbf{Z}^v - \mathbf{Z}_2^v \right\|_F^2 \quad (30)$$

根据 shrinkage 算子^[30], 对 \mathbf{Z}_2^v 一阶求导, 可得

$$\mathbf{Z}_2^v = \text{shink}(\mathbf{Z}^v + \boldsymbol{\Theta}_4/\zeta_3, 1/\zeta_3) \quad (31)$$

其中, $\text{shink}(\Omega, A) = \text{sign} \max(|\Omega| - A, 0)$.

(6)更新拉格朗日乘数 $\boldsymbol{\Theta}_1$, $\boldsymbol{\Theta}_2$, $\boldsymbol{\Theta}_3$ 和 $\boldsymbol{\Theta}_4$

$$\begin{cases} \boldsymbol{\Theta}_1 = \boldsymbol{\Theta}_1 + \bar{\mu}(\mathbf{P}_t^v \mathbf{X}_t^v - \mathbf{P}_s^v \mathbf{X}_s^v \mathbf{Z}^v) \\ \boldsymbol{\Theta}_2 = \boldsymbol{\Theta}_2 + \bar{\mu}(\mathbf{L}_s^v - \mathbf{U}_s^v) \\ \boldsymbol{\Theta}_3 = \boldsymbol{\Theta}_3 + \bar{\mu}(\mathbf{Z}^v - \mathbf{Z}_1^v) \\ \boldsymbol{\Theta}_4 = \boldsymbol{\Theta}_4 + \bar{\mu}(\mathbf{Z}^v - \mathbf{Z}_2^v) \\ \bar{\mu} = \min(\rho \bar{\mu}, \bar{\mu}_{\max}) \end{cases} \quad (32)$$

其中, ρ 和 $\bar{\mu}_{\max}$ 分别为迭代步长和 $\bar{\mu}$ 的最大值.

对于测试样本 \mathbf{x}_{test} , 它的第 v 个视角加权投影为

$$\sum_{v=1}^V (\alpha_v)^c \mathbf{P}_t^v \mathbf{x}_{\text{test}}, \text{ 决策函数可以表示为 } \mathbf{y}_{\text{test}} =$$

$\text{sign} \left(f \left(\sum_{v=1}^V (\alpha_v)^c \mathbf{P}_t^v \mathbf{x}_{\text{test}} \right) \right)$, 其中 $f(\cdot)$ 可以是任意的分类器, 本文使用最近邻分类器.

RTS-MVDA 方法的优化过程如算法 1 所述.

算法 1 RTS-MVDA 方法

输入: 具有 V 个视角的源域 \mathbf{X}_s^v 和目标域 \mathbf{X}_t^v ; \mathbf{X}_s^v 的类别标签 \mathbf{Y} ; 平衡参数 β , γ , λ , τ 和 η ; 自适应权重因子 c ; 最大循环次数 maxIter , 收敛阈值 ϵ

输出: 投影矩阵 \mathbf{P}^v , 潜在表示 \mathbf{L}^v , 重构系数 \mathbf{Z}^v , 权重矩阵 α

初始化: 随机初始化 \mathbf{P}^v , 全局 k 近邻图 \mathbf{W}^v , 类内散度和类间散度 \mathbf{S}_w^v 和 \mathbf{S}_b^v , 设置 $\alpha_v = 1/v$

while $t < \text{maxIter}$ or $\|J(t) - J(t-1)\| < \epsilon$ do

1. 根据式(15)和(17)更新投影矩阵 \mathbf{P}^v ;
2. 根据式(19)更新重构系数 \mathbf{Z}^v ;
3. 根据式(21)和式(23)更新潜在表示 \mathbf{L}^v ;
4. 根据式(10)构建全局 k 近邻图 \mathbf{W}^v , 根据式(5)和式(6)构建类内散度和类间散度 \mathbf{S}_w^v 和 \mathbf{S}_b^v ;
5. 根据式(25)更新权重矩阵 α ;
6. 根据式(27)、式(29)和式(31)更新辅助变量 \mathbf{U}_s^v , \mathbf{Z}_1^v 和 \mathbf{Z}_2^v ;
7. 根据式(32)更新拉格朗日乘数 $\boldsymbol{\Theta}_1$, $\boldsymbol{\Theta}_2$, $\boldsymbol{\Theta}_3$ 和 $\boldsymbol{\Theta}_4$;

end while

4 实验

4.1 数据集和实验设置

DEAP数据集^[26]作为情感分类领域广泛使用的公开数据库,包含了32名被试者观看40段时长为1 min音乐视频时的EEG记录.实验过程中,每位被试者在观看视频后,从唤醒度(arousal)和效价(valence)等多个维度对视频内容进行1~9分的评分.原始EEG通过32导联电极采集,采样频率为512 Hz.在数据预处理阶段,首先将采样频率降采样至128 Hz,随后采用带通滤波器(4.0~45.0 Hz)去除眼电伪迹等噪声干扰.经过预处理的数据被分割为60 s的片段,并剔除了前3 s的基线数据.本文从arousal和valence两个维度进行情绪状态分类.设定阈值为5,将两个维度分别进行二值化处理:评分高于5的被归类为高arousal/高valence,低于5的则归为低arousal/低valence.实验采用留一法交叉验证策略,即每次实验选取1名被试者作为测试集,其余31名被试者的EEG作为训练集.

本文采用长度为9 s且无重叠的滑动窗口对EEG进行分割,使得每次实验可产生7个数据点,从而为每位被试者构建280个数据点.考虑到训练样本数量较大,本文采用随机抽样策略,每次从训练集中抽取1/10的数据用于领域自适应算法和分类器训练.为确保样本的代表性,抽样过程重复进行10次,以保证训练数据能够充分覆盖整个数据集的特征空间.最终,实验构建的训练集包含源域868个样本和目标域40个样本,测试集样本240个.多视角EEG特征来自4类特征:6种时域特征(峰-峰均值、均方值、方差、Hjorth参数分量:活动性、移动性和复杂度)^[31]、3种频域特征(最大功率谱频率、最大功率谱密度、功率)^[31]、3种时-频域特征(最大功率谱频率、最大功率谱密度、功率)^[31]和平滑伪维格纳-维尔(Smooth Pseudo-Wigner-Ville, SPWV)分布^[32,33]和段参数(段范围、分段矩和分段差距)^[34]和4种动态系统特征(近似熵、香农熵、功率谱熵、奇异熵)^[35-37].实验计算4种节律[Theta(4~7 Hz)、Alpha(8~15 Hz)、Beta(16~31 Hz)和Gamma(32~45 Hz)]的特征,然后采用从这些滑动窗口中提取的特征值的平均值作为实验特征,特征数量分别为(6, 3, 4, 4) × 32 × 4 = (768, 384, 512, 512).由于多视角特征的数值范围不一致,实验中对多视角特征实施了规范化处理.

为验证RTS-MVDA方法的分类效果,实验对比了多种不同类型的方法,包括:

支持向量机到核方法(Support Vector Machine to Kernel, SVM2K)^[38]:基于支持向量机的多视角学习方法,通过多视角一致性约束提升分类性能.

多视角判别分析学习(Multi-view Learning for Discriminant Analysis, MULDA)^[39]:结合多种特征视角,利

用协同训练和协同正则化方法的多视角学习方法.

鲁棒潜在公共子空间学习(Robust Latent Common Subspace Learning, RLCSL)^[40]:基于公共子空间的迁移学习方法,通过低秩和稀疏约束联合学习跨域数据的可迁移判别特征表示,能够将分类器学习与特征学习统一优化.

领域不变自适应图正则化标签传播(Domain-Invariant Adaptive Graph regularized Label Propagation, DIAGLP)^[17]:联合域不变特征学习与自适应图正则化标签传播方法的迁移学习方法,通过软标签和自适应概率图优化跨领域识别任务,在减少域间分布差异的同时增强标签传播鲁棒性.

多视角集成投影-迁移表示学习-模糊系统(Multiview Integrated Projection-Transfer Representation Learning-Fuzzy System, MIP-TRL-FS)^[41]:基于Takagi-Sugeno-Kang模糊系统的多视角迁移学习方法,通过多视角特征提取和信息保持技术减少迁移信息损失.

稀疏子空间联合概率判别分析(Sparse Subspace Joint Probabilistic Discriminant Analysis, SSJPDA)^[42]:基于子结构联合概率域适应算法,通过双投影矩阵优化跨领域特征映射和子结构匹配提高迁移学习的能力.

模型训练时,非迁移学习方法通过在不同域的样本混合进行训练,非多视角学习方法通过将多种特征串联进行训练.本文在 $\{1 \times 10^{-3}, 0.5 \times 10^{-3}, \dots, 1 \times 10^3\}$ 内搜索支持向量机的核参数和所有方法的平衡参数,在 $\{10, 20, \dots, 70\}$ 内搜索子空间的维数,自适应权重因子设为2,其他参数的设置使用文献中的默认设置.本文采用Accuracy、Precision、Recall和 F_1 -score作为分类性能的衡量指标.

4.2 实验结果分析

为验证所提方法的有效性,本文在DEAP数据集中展示了RTS-MVDA方法的EEG情感分类性能.各方法在arousal和valence的平均Accuracy、Precision、Recall和 F_1 -score结果如表1、表2所示,32个被试的arousal和valence的Accuracy结果如表3、表4所示.表中粗体表示实验最佳结果.由实验结果可知,本文提出的RTS-MVDA方法在DEAP数据集上均优于所有对比方法.具体来说,(1)与多视角方法SVM2K和MULDA相比,RTS-MVDA方法arousal的平均Accuracy分别提升了10.01个百分点和9.41个百分点;valence的平均Accuracy分别提升了10.00个百分点和9.43个百分点.这些结果表明个体差异对EEG情感分类有较大的负面影响,也表明了RTS-MVDA方法处理领域适应场景EEG情感分类的有效性,证明了迁移学习方法在跨受试者情感分类中的实用性.(2)提出的RTS-MVDA方法优于对比的迁移学习方法.与迁移学习方法RLCSL和DIAGLP相比,RTS-MVDA方法arousal的平均Accuracy分别提升了5.51个百分点和4.98个百

分点; valence 的平均 Accuracy 分别提升了 5.52 个百分点和 5.22 个百分点. RLCSL 和 DIAGLP 方法仅将多种 EEG 特征拼接在一起, 然而简单地拼接会产生冗余信息且不能挖掘多视角 EEG 特征的相关性. 提出的 RTS-MVDA 方法使用的多视角学习机制可以有效地探索不同特征的互补和一致信息. 此外, 每个视角自适应学习的权重使得各视角的重要性得到了平衡. (3) 与多视角迁移学习方法 MIP-TRL-FS 和 SSJPDA 相比, 所提方法仍具有相当的优势. 与这两种方法相比, RTS-MVDA 方法 arousal 的平均 Accuracy 分别提升了 3.52 个百分点和 2.45 个百分点; valence 的平均 Accuracy 分别提升了 3.50 个百分点和 2.63 个百分点. SSJPDA 将不同视角的源域和目标域数据以双投影矩阵的形式投影到子空间, 通过子结构联合

概率来预测 EEG 样本标签. 但是 SSJPDA 没有充分挖掘数据的结构信息和判别知识. MIP-TRL-FS 使用模糊系统作为基础模型, 将多个视角合并为单一视角进行训练, 并建立迁移学习策略的模糊规则后件学习方法来进行 EEG 分类. 然而, MIP-TRL-FS 模糊规则数和前件参数通过聚类获得, 模糊空间不能有效学习每个视角数据的判别几何结构. 而 RTS-MVDA 方法将多视角数据投影到重建低秩子空间, 原始数据的主要的判别信息得以充分保留, 源域和目标域数据通过线性变换对, 有效减少源域和目标域之间的分布差异. 此外, RTS-MVDA 方法中加入的几何结构保持项和判别项, 达到了促进领域迁移和提高 EEG 分类的效果. 因此, RTS-MVDA 方法在 EEG 情感分类中是有效的.

表 1 各方法在 DEAP 数据集 arousal 维度的分类性能比较

单位: %

参数	SVM2K	MULDA	RLCSL	DIAGLP	MIP-TRL-FS	SSJPDA	RTS-MVDA
Accuracy	63.14	63.74	67.64	68.17	69.63	70.70	73.15
Precision	64.17	65.46	67.76	67.10	68.92	70.64	72.95
Recall	71.98	72.45	76.45	77.91	78.36	81.57	84.13
F_1 -score	67.85	68.78	71.84	72.10	73.34	75.71	78.15

注: 加粗字体表示最佳结果.

表 2 各方法在 DEAP 数据集 valence 维度的分类性能比较

单位: %

参数	SVM2K	MULDA	RLCSL	DIAGLP	MIP-TRL-FS	SSJPDA	RTS-MVDA
Accuracy	62.91	63.48	67.39	67.69	69.41	70.28	72.91
Precision	63.63	63.91	66.97	67.25	68.85	70.17	71.85
Recall	71.70	72.44	76.07	76.41	79.18	80.15	85.18
F_1 -score	67.42	67.91	71.23	71.54	73.66	74.83	77.95

注: 加粗字体表示最佳结果.

4.3 视角权重分析

本节探讨了多视角学习对 RTS-MVDA 方法分类精确率的影响. 在 DEAP 数据集上使用了 4 种代表性特征: 时域特征、频域特征、时-频特征以及动态系统特征, 分别对应着视角 1 至视角 4. 图 2(a) 和图 2(b) 分别展示了 DEAP 数据集 arousal 和 valence 维度的视角权重情况. 从目标函数式 (12) 可知, RTS-MVDA 方法无需预先设定搜索范围, 可自适应地确定各视角的权重值. 这一结论可以直观地从图 2 看出, 不同特征所对应的视角权重存在明显差异. 动态系统特征对应的视角 4 权重最高, 这表明动态系统特征包含更为丰富和关键的 EEG 特征信息, 对 EEG 情感分类具有重要的影响. 视角 1 和视角 2 权重相对较小, 视角 3 权重居中, 说明单一的时域和频域对 EEG 分类的贡献相对较低, 而时-频特征能够综合时域和频域特征在 EEG 情感分类中相对有效. 这一结果充分表明, RTS-MVDA 方法通过将多个领域数据投影到重构迁移子空间, 不仅实现了领域分布差异的最小化, 还能够依据数据的内在特性, 自适应地找到最优的视角权重组合. 这种自适应能力使得模型在

不同视角的信息能够实现融合学习, 有效地提升了模型分类能力.

4.4 参数敏感性分析

为说明 RTS-MVDA 方法对平衡参数 $\beta, \lambda, \gamma, \tau, \eta$ 和 μ 的敏感性, 本节通过固定其他参数并调整一个参数以观察其对 arousal 和 valence 维度的影响. 各参数搜索范围为 $\{1 \times 10^{-3}, \dots, 1 \times 10^3\}$. 实验结果如图 3 所示. β 是调节多视角源域 LDA 项 $\text{Tr}(\mathbf{P}_s^v (\mathbf{S}_w^v - \mathbf{S}_b^v) \mathbf{P}_s^{vT})$ 的平衡参数. 从图 3(a) 可知, 当 $\beta < 1$ 时, RTS-MVDA 方法的分类准确度较高, 当 $\beta > 1$ 时, RTS-MVDA 方法的分类准确度随着 β 的增加而降低. 这可能是因为多视角源域 LDA 项的值大于其他项, 如果不设定一个较小的值, 会导致各项之间的不平衡. λ 是调节投影对齐项 $\|\mathbf{P}_s^v - \mathbf{P}_t^v\|_F^2$ 的平衡参数. 如图 3(b) 所示, RTS-MVDA 对该参数的敏感度较低, arousal 和 valence 的分类准确度仅在小范围内波动, 体现了 RTS-MVDA 对这一参数的鲁棒性. γ 是调节多视角潜在表示一致项 $\|\mathbf{L}_s^{vT} \mathbf{L}_s^v - \mathbf{Y}^T \mathbf{Y}\|_F^2$ 的平衡参数. 如图 3(c) 所示, RTS-MVDA 的分类性能先随 γ 的增加而提升, 随后趋于

表3 各方法在32个被试 arousal 维度的 Accuracy 比较

单位:%

被测 arousal 维度	SVM2K	MULDA	RLCSL	DIAGLP	MIP-TRL-FS	SSJPDA	RTS-MVDA
被试1	68.37	68.73	72.06	72.94	74.72	74.57	78.38
被试2	64.98	66.08	70.50	71.02	71.65	72.09	75.42
被试3	65.17	66.16	69.33	70.57	72.75	72.97	75.93
被试4	57.36	57.64	61.35	61.42	63.26	64.58	67.21
被试5	68.77	69.78	73.84	73.78	75.37	76.41	78.98
被试6	71.96	72.99	75.98	76.74	79.71	80.20	82.75
被试7	58.52	58.09	61.67	62.83	64.12	64.58	67.93
被试8	59.07	59.77	64.02	64.25	65.96	66.00	69.18
被试9	61.48	62.34	65.50	67.40	68.28	68.25	71.63
被试10	56.90	57.50	61.19	62.37	63.71	64.07	67.17
被试11	57.95	58.87	63.77	62.88	65.19	66.21	68.76
被试12	58.96	60.54	65.30	65.48	66.17	66.98	69.57
被试13	62.09	62.44	64.66	66.19	67.76	68.49	71.58
被试14	56.93	57.01	62.15	62.51	63.47	64.01	66.61
被试15	68.43	69.01	72.64	72.52	74.74	75.55	78.59
被试16	63.36	63.06	67.15	66.79	68.64	69.32	72.45
被试17	61.47	62.22	67.45	67.08	68.05	68.43	71.73
被试18	61.30	61.88	65.76	65.42	67.82	68.06	71.26
被试19	61.91	61.37	66.56	65.92	68.09	68.62	71.34
被试20	71.90	71.53	76.26	76.05	77.87	78.47	81.48
被试21	58.77	59.77	63.53	62.83	64.31	65.23	68.25
被试22	60.58	60.77	66.12	64.59	66.78	67.52	70.30
被试23	70.93	71.90	75.01	75.55	77.76	78.82	81.67
被试24	68.41	69.82	75.02	73.32	75.93	76.36	79.32
被试25	64.53	63.99	69.23	69.43	70.56	71.23	73.83
被试26	66.30	66.92	70.12	71.88	72.69	72.92	76.26
被试27	63.25	63.99	67.66	68.36	69.64	69.87	73.19
被试28	57.13	58.22	62.21	62.60	64.58	64.86	67.70
被试29	67.55	67.60	70.17	70.71	73.61	73.50	76.67
被试30	71.26	71.40	73.64	76.32	77.45	77.77	80.55
被试31	51.21	52.28	54.82	54.53	56.52	57.51	60.35
被试32	56.30	57.56	61.70	61.67	63.91	64.00	66.96

注:加粗字体表示最佳结果.

稳定. 当 $\gamma > 1$ 时, RTS-MVDA 对 arousal 和 valence 的分类表现最佳. τ 是重构系数低秩稀疏项 $\|Z^v\|_* + \|Z^v\|_1$ 的平衡参数. 由图 3(d) 所示, RTS-MVDA 的分类性能对参数 τ 的变化不敏感, 说明该参数的取值范围较广, 且在此范围内 RTS-MVDA 能保持较高的 arousal 和 valence 分类准确度. η 是潜在表示低秩项 $\|L^v\|_*$ 的平衡参数. 从图 3(e) 可以看出, 与参数 τ 相似, RTS-MVDA 方法对 η 也不敏感, 其数值的变化不会显著影响 arousal 和 valence 的分类效果. μ 是全局结构保持项 $\text{Tr}(L^{vT} D_s^v L^v)$ 的平衡参数. 从图 3(f) 可以看出, 当 $0.1 \leq \mu \leq 10$ 时, arousal 和 valence 能达到最佳值, 而当 μ 过大或过小时, RTS-MVDA 方法均无法取得理想的分类效果.

4.5 非参数统计分析

本节采用非参数统计检验方法评估不同实验方法的 arousal 性能表现差异. 通过在多个被试上进行重复交叉验证实验, 首先利用 Friedman 测试对不同方法的 arousal 性能表现进行排序, 其具体排序结果如表 5 所示. 实验结果表明, RTS-MVDA 方法在 arousal 性能上均呈现出明显的性能优势. 然后, 本小节进一步采用 Holm post-hoc 测试(置信水平设置为 95%)进行 arousal 维度的事后假设检验. 基于检验统计量 z 值的各方法性能排序情况如表 6 所示. 依据假设检验理论, 当计算得到的 p 值低于预设显著性阈值(设定为 0.05)时, 可以拒绝零假设, 表明方法间的性能差异具有统计显著性. 实验数据

表 4 各方法在 32 个被试 valence 维度的 Accuracy 比较

单位: %

被试 valence 维度	SVM2K	MULDA	RLCSL	DIAGLP	MIP-TRL-FS	SSJPDA	RTS-MVDA
被试 1	67.12	67.57	70.50	71.77	73.11	73.48	77.10
被试 2	54.58	54.83	59.89	59.65	60.81	61.64	64.07
被试 3	65.11	65.43	68.44	69.12	72.02	72.74	75.24
被试 4	61.66	61.52	63.93	64.96	67.22	67.94	70.73
被试 5	62.60	62.83	66.01	67.53	69.25	70.01	72.53
被试 6	67.93	68.37	72.14	71.74	74.30	74.78	77.38
被试 7	68.00	68.17	72.66	72.29	73.82	75.10	77.52
被试 8	60.23	61.63	64.53	66.47	67.30	67.90	70.88
被试 9	67.40	68.17	71.68	71.81	74.14	74.76	77.21
被试 10	58.57	60.18	64.05	64.61	65.73	66.83	69.25
被试 11	59.26	58.72	63.87	63.95	64.69	65.46	68.39
被试 12	65.88	66.57	70.00	72.08	72.56	73.33	76.34
被试 13	64.83	64.91	68.80	69.64	71.28	71.21	74.31
被试 14	52.62	52.80	57.21	58.05	59.11	59.30	62.42
被试 15	63.21	64.07	66.59	67.34	69.46	70.85	73.35
被试 16	66.89	66.83	71.84	71.20	72.75	73.62	76.36
被试 17	67.11	67.62	71.35	72.19	73.78	74.97	77.62
被试 18	68.30	69.70	73.29	74.04	75.25	75.88	78.76
被试 19	55.44	57.07	60.22	61.16	63.08	62.98	66.35
被试 20	63.99	65.06	68.88	70.32	71.28	72.45	74.87
被试 21	61.27	62.55	67.46	67.37	68.02	69.35	71.79
被试 22	63.39	65.16	69.37	68.83	70.75	71.06	74.34
被试 23	66.47	67.86	70.24	71.76	73.19	74.16	76.92
被试 24	69.86	69.41	72.83	73.61	75.98	75.64	79.01
被试 25	50.11	50.93	54.96	55.84	56.30	57.10	60.09
被试 26	64.04	63.95	69.38	68.73	70.68	71.07	73.83
被试 27	67.73	68.69	72.98	72.65	73.92	74.50	77.87
被试 28	66.30	66.94	70.79	71.88	72.70	72.91	75.94
被试 29	61.52	62.45	67.95	67.95	68.38	69.71	72.20
被试 30	63.89	64.66	69.18	67.78	70.49	71.47	73.88
被试 31	60.06	59.70	63.92	64.71	65.54	66.50	69.25
被试 32	65.00	65.25	69.61	70.37	71.17	72.10	74.98

注:加粗字体表示最佳结果.




图 2 RTS-MVDA 方法的视角权重

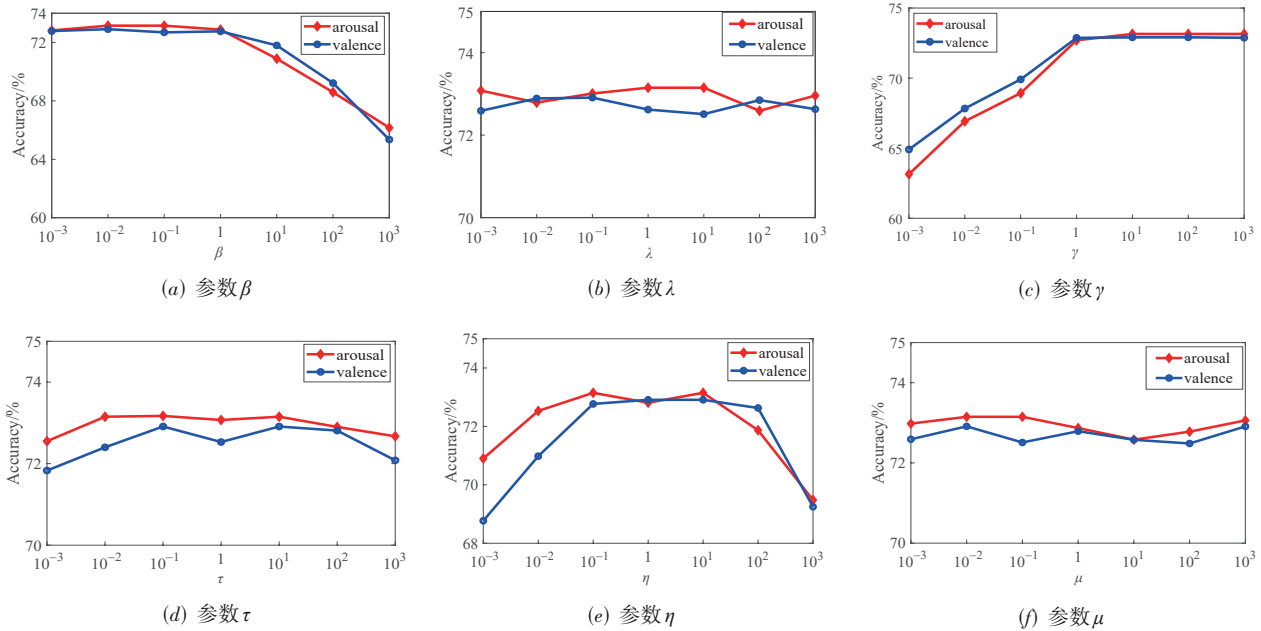


图3 RTS-MVDA方法的参数敏感性分析

表明, RTS-MVDA方法相较于其他对比方法均达到了统计显著性水平($p < 0.05$), 这一结果从统计学的角度充分验证了 RTS-MVDA方法在 DEAP数据集 arousal 维度的优势.

表5 Friedman 测试的排序结果

方法	Ranking
SVM2K	6.812 5
MULDA	6.187 5
RLCSL	4.703 1
DIAGLP	4.296 9
MIP-TRL-FS	2.906 2
SSJPDA	2.093 8
RTS-MVDA	1.000 0

表6 显著性阈值为 0.05 的 Holm post-hoc 测试

i	方法	z	p	Holm	假设
6	SVM2K	10.762 659	0	0.008 333	被拒绝
5	MULDA	9.605 384	0	0.010 000	被拒绝
4	RLCSL	6.856 855	0	0.012 500	被拒绝
3	DIAGLP	6.104 626	0	0.016 667	被拒绝
2	MIP-TRL-FS	3.529 689	0.000 416	0.025 000	被拒绝
1	SSJPDA	2.025 231	0.042 844	0.050 000	被拒绝

5 结论

在情感识别领域, EEG信号作为反映人类情感状态的关键载体, 其特征的复杂性以及个体差异成为了提升识别精度的主要障碍. 本文提出的 RTS-MVDA方法通过融合多视角学习和领域适应策略, 构建了重

构迁移子空间. 在该子空间内, RTS-MVDA不仅深入探索了各视角的重要性及其相互之间的互补性, 还通过线性变换和全局结构保持技术, 实现了源域与目标域之间的知识迁移和分布对齐. 此外, RTS-MVDA通过构建多视角监督判别项来利用源域的监督信息以提升分类性能. 实验结果表明: 该方法在 DEAP数据集上取得了较好的分类性能, 能够为感知用户情感提供了个性化和智能化的服务. 下一阶段, 本文将在更复杂场景的 EEG情感数据集中进行测试, 并探索其与其他情感表示数据的结合, 以研究其在多模态数据融合中的应用潜力. 此外, 如何进一步优化 RTS-MVDA方法的训练和寻参效率, 也将是后续研究的一个重要方向.


参考文献

- [1] 揭丽琳, 刘勇, 王铭勋, 等. 基于改进 TCNN 算法的脑电动态连续情绪识别研究[J]. 电子学报, 2025, 53(4): 1347-1360. JIE L L, LIU Y, WANG M X, et al. Research on dynamic continuous emotional recognition of EEG based on improved TCNN algorithm[J]. Acta Electronica Sinica, 2025, 53(4): 1347-1360. (in Chinese)
- [2] 师硕, 覃嘉俊, 于洋, 等. 基于改进 ConvMixer 和动态焦点损失的视听情感识别[J]. 电子学报, 2024, 52(8): 2824-2835. SHI S, QIN J J, YU Y, et al. Improved ConvMixer and focal loss with dynamic weight for audio-visual emotion recognition[J]. Acta Electronica Sinica, 2024, 52(8): 2824-2835. (in Chinese)
- [3] 张晶, 王翌歆, 任永功. 统一全局空间表达的脑电信号跨被试情感识别[J]. 电子学报, 2023, 51(5): 1396-1404.

- ZHANG J, WANG Y X, REN Y G. Unified global spatial representation for EEG subject-independent emotion recognition[J]. *Acta Electronica Sinica*, 2023, 51(5): 1396-1404. (in Chinese)
- [4] HAMZAH H ALI, ABDALLA K K. EEG-based emotion recognition systems; Comprehensive study[J]. *Heliyon*, 2024, 10(10): e31485.
- [5] ROSHANA EI M, NOROUZI H, ONTON J, et al. EEG-based functional and effective connectivity patterns during emotional episodes using graph theoretical analysis[J]. *Scientific Reports*, 2025, 15: 2174.
- [6] GARG D, VERMA G K, SINGH A K. EEG-based emotion recognition using mobilenet recurrent neural network with time-frequency features[J]. *Applied Soft Computing*, 2024, 154: 111338.
- [7] 李明爱, 张圆圆. 基于连续小波变换和符号传递熵的脑功能网络构建方法[J]. *电子学报*, 2022, 50(7): 1600-1608. LI M A, ZHANG Y Y. A brain functional network based on continuous wavelet transform and symbolic transfer entropy[J]. *Acta Electronica Sinica*, 2022, 50(7): 1600-1608. (in Chinese)
- [8] 席旭刚, 王成浩, 汪婷, 等. 基于表面肌电分解的皮层肌肉耦合机理研究[J]. *电子学报*, 2024, 52(8): 2607-2617. XI X G, WANG C H, WANG T, et al. Mechanism of corticomuscular coupling based on surface electromyography decomposition[J]. *Acta Electronica Sinica*, 2024, 52(8): 2607-2617. (in Chinese)
- [9] SAMAL P, HASHMI M F. Role of machine learning and deep learning techniques in EEG-based BCI emotion recognition system: A review[J]. *Artificial Intelligence Review*, 2024, 57(3): 50.
- [10] CHEN C Q, LI Z C, 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: 2508215.
- [11] SOWMYA M, VARMA P, KATARAPU D. Feature extraction from EEG signals of the brain using spectral entropy feature extraction technique[J]. *Grenze International Journal of Engineering & Technology*, 2024, 15(6): 10.
- [12] LI C, BIAN N, ZHAO Z P, et al. Multi-view domain-adaptive representation learning for EEG-based emotion recognition[J]. *Information Fusion*, 2024, 104: 102156.
- [13] XIAO Y, ZHANG Y M, PENG X P, et al. Multi-source EEG emotion recognition via dynamic contrastive domain adaptation[J]. *Biomedical Signal Processing and Control*, 2025, 102: 107337.
- [14] AI Q S, WANG C H, CHEN K, et al. Multi-source domain separation adversarial domain adaptation for EEG emotion recognition[J]. *Biomedical Signal Processing and Control*, 2025, 109: 108016.
- [15] SHI X S, SHE Q S, FANG F, et al. Enhancing cross-subject EEG emotion recognition through multi-source manifold metric transfer learning[J]. *Computers in Biology and Medicine*, 2024, 174: 108445.
- [16] IMTIAZ M N, KHAN N. Enhanced cross-dataset electroencephalogram-based emotion recognition using unsupervised domain adaptation[J]. *Computers in Biology and Medicine*, 2025, 184: 109394.
- [17] TAO J W, YAN L D, HE T. Domain-invariant adaptive graph regularized label propagation for EEG-based emotion recognition[J]. *IEEE Access*, 2024, 12: 126774-126792.
- [18] LIU W C, GUO C J, GAO C. A cross-session motor imagery classification method based on Riemannian geometry and deep domain adaptation[J]. *Expert Systems with Applications*, 2024, 237: 121612.
- [19] CHEN P Y, LIU X F, MA C, et al. Unsupervised domain adaptation with synchronized self-training for cross-domain motor imagery recognition[J]. *IEEE Journal of Biomedical and Health Informatics*, 2025, 29(5): 3664-3677.
- [20] JALILPOUR S, MÜLLER-PUTZ G. A framework for Interpretable deep learning in cross-subject detection of event-related potentials[J]. *Engineering Applications of Artificial Intelligence*, 2025, 139: 109642.
- [21] HE R F, HUANG F, MA J S, et al. Few-shot cross domain event discovery in narrative text[J]. *Information Processing & Management*, 2025, 62(1): 103901.
- [22] CHEN H T, XIE J L. EEG-based TSK fuzzy graph neural network for driver drowsiness estimation[J]. *Information Sciences*, 2024, 679: 121101.
- [23] LUO Y, LIU W, LI H Q, et al. A cross-scenario and cross-subject domain adaptation method for driving fatigue detection[J]. *Journal of Neural Engineering*, 2024, 21(4): 046004.
- [24] KUMAR S, ALAWIEH H, RACZ F S, et al. Transfer learning promotes acquisition of individual BCI skills[J]. *PNAS Nexus*, 2024, 3(2): 76.
- [25] DARVISHI-BAYAZI M J, GHAEMI M S, LESORT T, et al. Amplifying pathological detection in EEG signaling pathways through cross-dataset transfer learning[J]. *Computers in Biology and Medicine*, 2024, 169: 107893.
- [26] KOELSTRA S, MUHL C, SOLEYMANI M, et al. DEAP: A database for emotion Analysis; Using physio-

- logical signals[J]. IEEE Transactions on Affective Computing, 2012, 3(1): 18-31.
- [27] XU Y, FANG X Z, WU J, et al. Discriminative transfer subspace learning via low-rank and sparse representation[J]. IEEE Transactions on Image Processing, 2016, 25(2): 850-863.
- [28] YANG L R, ZHOU Q H. Transfer subspace learning joint low-rank representation and feature selection[J]. Multimedia Tools and Applications, 2022, 81(27): 38353-38373.
- [29] LI S K, SONG P, ZHENG W M. Multi-source discriminant subspace alignment for cross-domain speech emotion recognition[J]. IEEE/ACM Transactions on Audio, Speech and Language Processing, 2023, 31: 2448-2460.
- [30] RICE J R, GARDINER J D, LAUB A J, et al. Solution of the sylvester matrix equation $AXB^T + CXD^T = E$ [J]. ACM Transactions on Mathematical Software, 1992, 18(2): 223-231.
- [31] YANG F, ZHAO X C, JIANG W G, et al. Multi-method fusion of cross-subject emotion recognition based on high-dimensional EEG features[J]. Frontiers in Computational Neuroscience, 2019, 13: 53.
- [32] AL-FAHOUM A S, AL-FRAIHAT A A. Methods of EEG signal features extraction using linear analysis in frequency and time-frequency domains[J]. International Scholarly Research Notices, 2014, 2014(1): 730218.
- [33] THIRUMARAI SELVI C, JAYASHEELA M, AMUDHA J, et al. An EEG-based thought recognition using pseudo-Wigner-kullback-leibler deep neural classification[J]. Circuits, Systems, and Signal Processing, 2023, 42(2): 1063-1082.
- [34] XIAO M H, BO S. Electroencephalogram emotion recognition via AUC maximization[J]. Algorithms, 2024, 17(11): 489.
- [35] PATEL P, R R, ANNAVAPU R N. EEG-based human emotion recognition using entropy as a feature extraction measure[J]. Brain Informatics, 2021, 8(1): 20.
- [36] LI J W, FENG G Y, LING C, et al. A resource-efficient multi-entropy fusion method and its application for EEG-based emotion recognition[J]. Entropy, 2025, 27(1): 96.
- [37] PAPPALETTERA C, CACCIOTTI A, NUCCI L, et al. Approximate entropy analysis across electroencephalographic rhythmic frequency bands during physiological aging of human brain[J]. GeroScience, 2023, 45(2): 1131-1145.
- [38] HUANG C Q, CHUNG F L, WANG S T. Multi-view L2-SVM and its multi-view core vector machine[J]. Neural Networks, 2016, 75: 110-125.
- [39] BARAJAS MONTIEL S E, MORALES E F, ESCALANTE H J. Multi-view learning for EEG signal classification of Imagined speech[C]//Pattern Recognition. Cham: Springer, 2022: 191-200.
- [40] ZHAN S H, SUN W J, KANG P P. Robust latent common subspace learning for transferable feature representation[J]. Electronics, 2022, 11(5): 810.
- [41] LI A D, DENG Z H, ZHANG W, et al. Multiview transfer representation learning with TSK fuzzy system for EEG epilepsy detection[J]. IEEE Transactions on Fuzzy Systems, 2024, 32(1): 38-52.
- [42] FU Z Z, ZHANG B N, HE X R, et al. Emotion recognition based on multi-modal physiological signals and transfer learning[J]. Frontiers in Neuroscience, 2022, 16: 1000716.

作者简介



韩少勇 男, 1982年10月生, 甘肃武威人, 博士. 现为铜陵学院数学与计算机学院副教授. 主要研究方向为智能信息处理研究.
E-mail: hsytl@126.com



周国华 男, 1977年7月生, 江苏东台人. 现为常州工业职业技术学院信息工程学院副教授. 主要研究方向为智能学习、模式识别研究.
E-mail: tidyyddd@sina.com.cn



殷新春 男, 1962年2月生, 江苏姜堰人, 博士. 现为扬州大学信息工程学院教授, 博士生导师. 主要研究方向为信息安全、软件质量保障、高性能计算.
E-mail: xcyin@yzu.edu.cn