doi:10.14132/j.cnki.1673-5439.2023.01.009

基于双支路核化群稀疏学习的微表情识别

魏金生[1],卢官明[1],彭 伟[2],陈浩侠[1],黄晓华[3],闫静杰[1]

(1.南京邮电大学 通信与信息工程学院,江苏 南京 210003
2.斯坦福大学 神经与行为科学学院,美国 加利福尼亚州 94305
3.南京工程学院 计算机工程学院,江苏 南京 211167)

摘要:在微表情识别系统中,常规的特征融合方法会引入冗余或干扰特征,因而会影响识别准确率和效率。针对上述问题,提出一种基于双支路核化群稀疏学习(Two-Branch Kernelized Groups Sparse Learning,TB-KGSL)的特征选择方法,并将其应用于微表情识别系统。首先,提取多个人脸区域的 3 个正交平面上局部二值模式(Local Binary Patterns from Three Orthogonal Planes,LBP-TOP)和多个方向上的单方向梯度直方图(Histogram of Single Direction Gradient,HSDG)两组不同类型的特征;然后,使用 TB-KGSL 模型从上述两组特征中分别选择有效区域的 LBP-TOP 特征和有效方向上的 HSDG 特征;最后,将选择的 LBP-TOP 和 HSDG 特征进行拼接融合,得到紧凑且可鉴别的特征,并使用基于支持向量机(Support Vector Machine,SVM)的分类器进行微表情分类。实验结果验证了 TB-KGSL 的可行性和有效性,并在 CASME II 和 SMIC 数据集上分别达到 68.63%和 75.95%的识别准确率,比基线方法分别高出 5.77 个百分点和 15.20 个百分点。

关键词:微表情识别;稀疏学习;特征融合;特征选择

中图分类号:TP391 **文献标志码**:A **文章编号**:1673-5439(2023)01-0070-010

Micro-expression recognition based on two-branch kernelized groups sparse learning

WEI Jinsheng[1], LU Guanming[1], PENG Wei[2], CHEN Haoxia[1],
HUANG Xiaohua[3], YAN Jingjie[1]

(1.School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China
2.Department of Psychiatry and Behavioral Sciences of Stanford Medicine, Stanford University, CA 94305, America
3.College of Computer Engineering, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: In the micro expression recognition system, the conventional feature fusion method will introduce redundant or interfering features and affect the recognition accuracy and efficiency. In this regard, a novel feature selection method based on two-branch kernelized groups sparse learning (TB-KGSL) is proposed and applied to the micro-expression recognition system. First, local binary patterns from three orthogonal planes (LBP-TOP) in multiple facial regions and histogram of single direction gradient (HSDG) in multiple directions are extracted. Second, the TB-KGSL model is used to select the LBP-TOP features in the effective facial regions and the HSDG features in the effective directions from the above two groups of features. Finally, the selected LBP-TOP and HSDG features are concatenated to obtain compact and distinguishable features, and a classifier based on the support vector machine (SVM)

收稿日期:2022-08-22;**修回日期**:2022-11-16 **本刊网址**:http://nyzr.njupt.edu.cn
基金项目:国家自然科学基金(72074038,62076122,61971236)和江苏省研究生科研与实践创新计划(KYCX19_0899)资助项目
作者简介:魏金生,男,博士研究生,讲师;卢官明(通信作者),男,博士,教授,博士生导师,lugm@ njupt.edu.cn
引用本文:魏金生,卢官明,彭伟,等.基于双支路核化群稀疏学习的微表情识别[J].南京邮电大学学报(自然科学版),2023,43(1):70-79.

is used for micro-expression classification. The experimental results demonstrate the effectiveness of TB-KGSL. The recognition accuracy on CASME II and SMIC datasets is 68.63% and 75.95%, respectively, which is improved by 5.77 and 15.20 percentage points compared with those of the baseline method.

Keywords: micro-expression recognition; sparse learning; feature fusion; feature selection

面部表情是人类表达内心情感的直观反映,在人际交流和沟通过程中起着非常重要的作用。情感识别作为情感计算系统的关键技术,是实现人机交互的基础[1]。与普通表情[2-3]不同,微表情(Micro-Expression)是一个人试图隐藏内心真实情感却又不由自主流露出的不易被察觉的自发式表情。微表情识别技术在测谎、刑事侦查、心理疾病的临床诊断以及公共安全等领域具有重要的应用价值[4-9]。

微表情识别主要包括预处理、特征提取和分类 3 个步骤,其中特征提取是关键步骤,也是研究的核心。如何提取能够表征微表情中面部微弱运动的特征对于微表情识别性能来说是至关重要的。现有的方法主要分为传统方法和深度学习方法[4,6-9]。传统方法采用人工设计的特征提取算子,从微表情视频中提取人工特征;而深度学习方法通过构建深度学习模型自适应地提取微表情视频中的深度特征。

与普通表情相比,由于微表情的持续时间非常短,面部肌肉运动强度弱,变化幅度小,采集微表情样本难度大,标注微表情的类别标签不仅需要由训练有素且具有丰富专业经验的心理专家来完成,而且耗时费力。因此,获取大量有类别标签的微表情样本比较困难。目前公开的一些微表情数据集,如 CASME II[10]、SMIC[11]等,其规模都比较小,这在一定程度上限制了深度学习在微表情识别中的有效应用。因为"端到端"的深度学习模型依赖大量有标签的样本数据来训练,其泛化能力备受质疑与挑战,样本数据不足、训练样本与真实样本分布不一致,均会导致算法性能急剧下降。另外,深度学习模型的计算代价较高,也缺乏一定的可解释性[4]。而传统方法有着计算代价小、可解释性强的优势,且可以有效地利用目前有限的微表情视频样本。因此,本文聚焦在传统方法中的特征选择技术,用于提升目前已有特征的可鉴别性和紧凑性,提高识别性能和效率。

常规的特征融合技术在引入更多特征信息的同时,也会增加特征的冗余度,引入更多干扰的特征信息,从而影响微表情识别的性能和效率。如果在融合前能够消除两种特征中的冗余或干扰信息,不仅可以降低特征维度,提高效率,还能得到更加可鉴别的特征,提高识别性能。为此,本文提出一种基于双支路核化群稀疏学习(Two-Branch Kernelized Groups Sparse Learning,TB-KGSL)的微表情识别方法,在融合两组不同类型的特征之前,采用核化群稀疏学习模型分别对两组特征进行选择,消除两组特征中的冗余及干扰信息,选择可鉴别的特征并进行拼接融合,从而得到更加紧凑且可鉴别的特征,提高识别性能和效率。

1　相关工作

目前,微表情识别领域的工作大多聚焦在特征提取上,且部分工作为了增强特征的表示能力,提出了一些特征选择方法。本文提出了一种基于双支路核化群稀疏学习的微表情识别方法,其主要涉及到特征提取及特征选择技术。

1.1　微表情识别中的特征提取

在表情识别领域,局部二值模式(Local Binary Patterns,LBP)是一种常用的纹理特征描述算子,用于描述图像中每个像素值与其近邻点像素值之间的关系。2007 年,Zhao 等[2]针对动态图像序列的纹理特征描述,将 LBP 算子扩展到了三维空间,提出了 3 个正交平面上局部二值模式(Local Binary Patterns from Three Orthogonal Planes,LBP-TOP)。Li 等[11]将 LBP-TOP 应用于微表情识别系统。之后,一些研究人员对 LBP-TOP 进行了改进,提出各种特征描述算子,包括 LBP-MOP(Local Binary Patterns from Mean Orthogonal Planes)[12]、STCLQP(SpatioTemporal Completed Local Quantized Patterns)[13]、LBP-SIP (Local Binary Pattern from Six Intersecting Points)[14]、LBP-IP (Local Binary Pattern with Integral Projection)[15]及 LBP-FIP (Local Binary Pattern from Five Intersecting Planes)[16]等。

一些工作将 LBP-TOP 与其他特征进行融合,提升了微表情识别的准确率。Liong 等[17]结合光流特征和 LBP-TOP 特征,使用时域均值池化光流应变图加权 LBP-TOP 特征,提高了识别性能。Guo 等[18]将局部二阶信息引入到 LBP-TOP 特征中,实现二者拼接融合,得到 Extended LBP-TOP 特征。最近,Wei 等[19]研究了不同方向上运动特征的有效性,提取了单方向梯度直方图(Histogram of Single Direction

Gradient,HSDG)特征,并将其与 LBP-TOP 进行拼接,得到局部二值模型-单方向梯度(Local Binary Pattern-Single Direction Gradient, LBP-SDG)特征。该工作分别测试了 18 个方向上的 HSDG 与 LBP-TOP 拼接融合后的性能。结果表明,最优方向上的 HSDG 与 LBP-TOP 融合拼接后,取得了较好的识别性能。但是,该工作需要手动测试并确定 HSDG 的最优方向,不同方向上的 HSDG 存在巨大的性能差异,且只能将单个有效的 HSDG 与 LBP-TOP 进行拼接融合。针对上述问题,本文提出的基于 TB-KGSL 的特征选择方法,可以选择有效方向上的 HSDG 以及有效面部区域上的 LBP-TOP 特征,从而提高识别效率和性能。

1.2 微表情识别中的特征选择

微表情出现时仅激活面部小部分区域,且强度较小,因此,提取的特征存在冗余和干扰信息,特别是对于传统方法中的人工特征,由于缺乏自适应性,使得其存在大量的冗余及干扰信息。为了提高识别性能,采用特征选择算法消除特征中的冗余及干扰信息是一种有效的技术手段。

目前,微表情识别领域有部分工作涉及特征选择。卢官明等[20]结合 ReliefF 和局部线性嵌入(Locally Linear Embedding, LLE)流形学模型,对 LBP-TOP 进行降维,得到更加紧凑的动态纹理特征。基于主方向平均光流(Main Directional Mean Optical Flow, MDMO)[21]特征,Liu 等[22]从微表情视频片段中学习有效的字典,提出一个新的距离度量,并将新的距离度量与经典的图正则化稀疏编码结合得到稀疏的 MDMO 特征。张延良等[23]提出基于 Fisher 的特征选择算法,学习并选择更加可鉴别的微表情特征,降低特征维度,得到更加紧凑的特征表示。基于拉普拉斯算子,Huang 等[24]设计了一种新的特征选择算法用于分组的 LBP-IP 特征,该工作为每一组特征学习一个拉普拉斯分数,并根据分数选择特征。Zong 等[25]采用稀疏学习方法,建立 KGSL 从分层的 LBP-IP 特征中学习可鉴别的微表情特征。该工作将面部区域划分为多个尺度的区域,并提取这些区域上的 LBP-IP 特征,得到分层 LBP-IP 特征;然后,使用 KGSL 为每个 LBP-IP 特征学习能代表其对微表情分类的贡献度权重;最后,采用学习到的权重加权相应的 LBP-IP 特征,并使用优化后的 KGSL 模型预测微表情类别。以上这些工作提出的特征选择算法都是针对一组特征的选择。

受 KGSL 的启发,本文提出一种基于双支路核化群稀疏学习(TB-KGSL)的特征选择方法,通过双支路的方式,采用 KGSL 模型分别对来自不同面部区域的 LBP-TOP 特征以及不同方向的 HSDG 特征进行选择,并对选择后的两组特征进行拼接融合,得到更加紧凑且可鉴别的微表情特征。与 KGSL+分层 LBP-IP 的方法[25]不同的是:(1) 提出的方法采用双支路的方式分别对两组特征进行选择,并将选择的特征进行拼接融合,不仅引入更多的可鉴别信息,还能得到更加紧凑的特征表示,而 KGSL+分层 LBP-IP 方法只针对一组特征的选择,并未涉及两组特征的选择;(2) 提出的方法仅采用 KGSL 模型选择特征,分类器采用支持向量机(SVM)模型,而 KGSL+分层 LBP-IP 方法采用 KGSL 模型预测微表情类别;(3) 提出的方法在训练阶段学习了有效的面部区域以及方向,而实际识别微表情时,仅需提取有效区域及有效方向上的特征即可,降低了特征维度,提升了识别的性能和效率,而 KGSL+分层 LBP-IP 的方法需要将学习的权重加权每一个分层 LBP-IP 特征,实际识别微表情时,需要提取完整的分层 LBP-IP 特征。

2 基于双支路核化群稀疏学习的微表情识别

本文提出的基于双支路核化群稀疏学习(Two-Branch Kernelized Groups Sparse Learning,TB-KGSL)的微表情识别系统原理框图如图 1 所示。首先,通过两条支路从微表情视频序列中分别提取多个面部区域的 LBP-TOP 特征以及多个方向上的 HSDG 特征,其中,第一条支路处理多个面部区域的 LBP-TOP 特征,而第二条支路处理多个方向上的 HSDG 特征;然后,两条支路分别使用 KGSL 模型选择有效区域的 LBP-TOP 特征和有效方向上的 HSDG 特征;最后,将选择的 LBP-TOP 和 HSDG 特征进行拼接融合,得到紧凑且可鉴别的特征,并使用基于支持向量机(Support Vector Machine,SVM)的分类器进行微表情分类。

2.1 LBP-TOP 和 HSDG 特征的提取

为了研究不同方向上运动特征的有效性,Wei 等[19]提取 HSDG 特征表示单个方向上的运动信息,并将其与 LBP-TOP 进行拼接融合得到 LBP-SDG 特征。该工作分别测试了 18 个方向上的 HSDG,实验结果表明,有效方向上的 HSDG 与 LBP-TOP 拼接融合能够取得较好的识别准确率。但是,分别测试每个方向上 HSDG 的有效性耗费大量的时间,结论过

于依赖设定的特征参数,且手动测试单个 HSDG,不能同时考虑多个 HSDG 之间的关系。另外,LBP-TOP 采用了分块策略,将人脸划分为完备的多个区域,并提取每个区域的 LBP-TOP 特征。但是,微表情与面部少部分区域有关,提取的 LBP-TOP 包含了大量的冗余和干扰信息。因此,本文提取多个人脸区域的 LBP-TOP 特征和 18 个方向上的 HSDG 特征,并采用 KGSL 模型选择有效区域的 LBP-TOP 特征和有效方向上的 HSDG 特征。

如图 1 所示,在本文提出的基于 TB-KGSL 的微表情识别系统中,第一条支路提取若干个人脸区域的 LBP-TOP 特征,第二条支路提取 18 个方向上的 HSDG 特征。具体地,第一条支路将人脸区域划分为若干个完备子区域,并提取每个子区域的 LBP-TOP 特征组成一组特征;第二条支路提取 18 个方向上的 HSDG 特征组成一组特征。LBP-TOP 和 HSDG 特征的提取可以参考文献[19]。

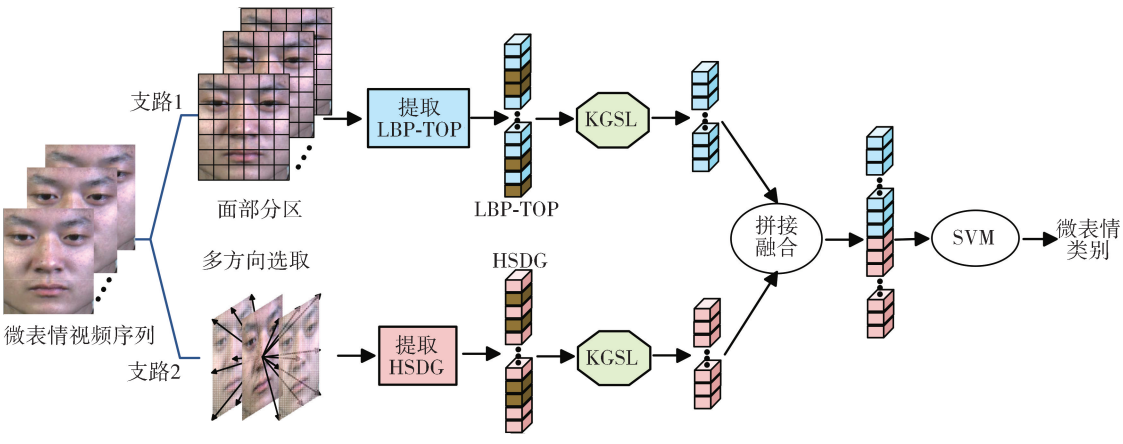


图 1　基于 TB-KSGL 的微表情识别系统原理框图

2.2　核化群稀疏学习模型的建立

假设训练集有 M 个微表情视频样本,输入特征为 $\boldsymbol{X}=[\boldsymbol{x}^1,\boldsymbol{x}^2,\cdots,\boldsymbol{x}^M]\in\mathbb{R}^{D*M}$,其中,$D$ 为总特征维度,$\boldsymbol{x}^m\in\mathbb{R}^{D*1}$ 表示第 m 个样本的输入特征。

为了能够采用群稀疏学习模型将特征空间映射到标签空间,数据集提供的离散标签被转换为 One-hot 标签。具体地,假设第 i 个视频样本的离散标签为 $dl_i(dl_i=1,2,\cdots,c)$,其中,c 为微表情类别数。那么,dl_i 对应的 One-hot 标签为 $\boldsymbol{I}_i=[l_{i,1},l_{i,2},\cdots,l_{i,c}]^{\mathrm{T}}\in\mathbb{R}^{c*1}$,其中

$$l_{i,j}=\begin{cases}1 & j=dl_i\\ 0 & \text{其他}\end{cases}\tag{1}$$

那么,M 个视频样本的 One-hot 标签表示为 $\boldsymbol{L}=[\boldsymbol{I}_1,\boldsymbol{I}_2,\cdots,\boldsymbol{I}_M]\in\mathbb{R}^{c*M}$。

由于所有样本的 One-hot 标签是一组包含标签信息的标准正交向量,所以这些 One-hot 标签能够展开成一个标签向量空间。具体地,采用映射矩阵 $\boldsymbol{U}\in\mathbb{R}^{D*c}$ 将特征向量空间映射到标签向量空间,即

$$\min_{\boldsymbol{U}}\|\boldsymbol{L}-\boldsymbol{U}^{\mathrm{T}}\boldsymbol{X}\|_{\mathrm{F}}^2\tag{2}$$

式中,$\|\cdot\|_{\mathrm{F}}$ 为 Frobenius 范数。

将每个样本提取的输入特征分为 N 个子特征,且每个子特征的维度为 d,即,$D=d*N$。那么,将 $\boldsymbol{U}$ 做相应的划分,则式(1)可转化为

$$\min_{\boldsymbol{U}_n}\left\|\boldsymbol{L}-\sum_{n=1}^{N}\boldsymbol{U}_n^{\mathrm{T}}\boldsymbol{X}_n\right\|_{\mathrm{F}}^2\tag{3}$$

式中,$\boldsymbol{X}_n\in\mathbb{R}^{d*M}$ 表示第 n 个子特征,$n=1,2,\cdots,N$。

为了学习能够表示每个子特征对微表情分类的贡献度权重,引入 N 个权重分别加权 N 个子特征,第 n 个子特征的权重为 $\boldsymbol{\alpha}_n$。由于这些权重表示每个子特征对微表情分类的贡献度,所以应该是非负的,另外,由于无效或干扰的特征应该尽量为 0,且理论上少量特征即可表示微表情相关的面部肌肉运动,因此,权重应该是稀疏的。本文中,建立的群稀疏学习模型引入 l_1 范数作为惩罚项对权重进行约束,以满足权重的稀疏性。所以,群稀疏学习模型的优化问题为

$$\min_{\boldsymbol{U}_n,\boldsymbol{\alpha}_n}\left\|\boldsymbol{L}-\sum_{n=1}^{N}\boldsymbol{\alpha}_n\boldsymbol{U}_n^{\mathrm{T}}\boldsymbol{X}_n\right\|_{\mathrm{F}}^2+\lambda\sum_{n=1}^{N}\boldsymbol{\alpha}_n\quad \text{s.t. } \boldsymbol{\alpha}_n\geqslant 0\tag{4}$$

式中,λ 为权衡系数(惩罚项系数),决定 $\boldsymbol{\alpha}_n$ 的稀疏程度。由于 $\boldsymbol{\alpha}_n\geqslant 0$,所以 $\boldsymbol{\alpha}_n$ 的 l_1 范数 $\sum_{n=1}^{N}\|\boldsymbol{\alpha}_n\|_1$ 表示为 $\sum_{n=1}^{N}\boldsymbol{\alpha}_n$。

为了提高群稀疏学习模型的学习能力,将其拓展为核化版本。本文采用一个非线性匹配算子 φ 将 $\boldsymbol{X}_n$ 和 $\boldsymbol{U}_n$ 映射到卡方核空间 CS,即,$\varphi:\mathbb{R}^d \rightarrow \mathrm{CS}$,$\boldsymbol{X}_n \rightarrow \boldsymbol{X}_n^{\varphi}$,$\boldsymbol{U}_n \rightarrow \boldsymbol{U}_n^{\varphi}$。那么,原始群稀疏学习模型的优化问题转化为

$$\min_{\boldsymbol{U}_n^{\varphi},\boldsymbol{\alpha}_n} \left\| \boldsymbol{L} - \sum_{n=1}^{N} \boldsymbol{\alpha}_n \boldsymbol{U}_n^{\varphi \mathrm{T}} \boldsymbol{X}_n^{\varphi} \right\|_{\mathrm{F}}^2 + \lambda \sum_{n=1}^{N} \boldsymbol{\alpha}_n \quad \text{s.t.} \quad \boldsymbol{\alpha}_n \geqslant 0 \tag{5}$$

进一步,由于卡方核空间 CS 是无限维的,因此,$\boldsymbol{U}_n^{\varphi}$ 的每一列 $\boldsymbol{u}_{n,i}^{\varphi}$ 都能被 $\boldsymbol{X}_n^{\varphi}$ 通过线性系数 $\boldsymbol{p}_n$ 表示,其中,$\boldsymbol{u}_{n,i}^{\varphi}$ 是 $\boldsymbol{U}_n^{\varphi}$ 的第 i 列。因此,$\boldsymbol{U}_n^{\varphi}$ 被表示为

$$\boldsymbol{U}_n^{\varphi} = [\boldsymbol{u}_{n,1}^{\varphi}, \boldsymbol{u}_{n,2}^{\varphi}, \cdots, \boldsymbol{u}_{n,c}^{\varphi}] = \boldsymbol{X}_n^{\varphi} \boldsymbol{P} \tag{6}$$

式中,$\boldsymbol{P} = [\boldsymbol{p}_1, \boldsymbol{p}_2, \cdots, \boldsymbol{p}_c]$。那么,将式(5)代入式(4)中,得到

$$\min_{\boldsymbol{U}_n^{\varphi},\boldsymbol{\alpha}_n} \left\| \boldsymbol{L} - \sum_{n=1}^{N} \boldsymbol{\alpha}_n \boldsymbol{P}^{\mathrm{T}} \boldsymbol{X}_n^{\varphi \mathrm{T}} \boldsymbol{X}_n^{\varphi} \right\|_{\mathrm{F}}^2 + \lambda \sum_{n=1}^{N} \boldsymbol{\alpha}_n \quad \text{s.t.} \quad \boldsymbol{\alpha}_n \geqslant 0 \tag{7}$$

核空间的高度线性化使得 $\boldsymbol{u}_{n,i}^{\varphi}$ 只需要 $\boldsymbol{X}_n^{\varphi}$ 中少数列向量就能够重构。因此,引入 $\boldsymbol{P}$ 的惩罚项 $\|\boldsymbol{P}\|_1$ 保证 $\boldsymbol{P}$ 的稀疏性,且能够防止过拟合。因此,核化群稀疏学习模型的优化为

$$\min_{\boldsymbol{P},\boldsymbol{\alpha}_n} \left\| \boldsymbol{L} - \sum_{n=1}^{N} \boldsymbol{\alpha}_n \boldsymbol{P}^{\mathrm{T}} \boldsymbol{K}_n \right\|_{\mathrm{F}}^2 + \lambda \sum_{n=1}^{N} \boldsymbol{\alpha}_n + \xi \sum_{n=1}^{N} \boldsymbol{P} \quad \text{s.t.} \ \boldsymbol{\alpha}_n \geqslant 0 \tag{8}$$

式中,$\boldsymbol{K}_n = \boldsymbol{X}_n^{\varphi \mathrm{T}} \boldsymbol{X}_n^{\varphi}$,为格拉姆矩阵;$\xi$ 为权衡系数(惩罚项系数)。

2.3 基于核化群稀疏学习模型的特征选择

如图 1 所示,TB-KGSL 中的两条支路分别使用 KGSL 模型从不同人脸区域的 LBP-TOP 特征和不同方向的 HSDG 特征中学习其对微表情分类的贡献度权重。具体地,在第一条支路中,将 $B*B$ 个人脸区域的 $B*B$ 个 LBP-TOP 特征作为 KGSL 模型的输入,并对 KGSL 模型的参数进行优化,从 $B*B$ 个人脸区域的 LBP-TOP 特征中学习其对微表情分类的贡献度权重;相似地,在第二条支路中,将 18 个方向上的 HSDG 特征作为 KGSL 模型的输入,并对 KGSL 模型的参数进行优化,从 18 个方向上的 HSDG 特征中学习其对微表情分类的贡献度权重。然后,设定阈值,选择出权重大于阈值的重要特征。考虑到两组特征对微表情识别的有效性差异,两条支路可以设置不同的阈值。具体地,在第一条支路中,选择权重大于阈值 T_1 的有效区域的 LBP-TOP 特征;而在第二条支路中,选择权重大于阈值 T_2 的有效方向上的 HSDG 特征。最后,将筛选出的 LBP-TOP 特征和 HSDG 特征进行拼接融合,得到更加紧凑且可鉴别的微表情特征。

上述步骤中,两条支路上的 KGSL 模型需要进行参数优化,优化问题的描述如式(8)所示,$\boldsymbol{P}$ 和 $\boldsymbol{\alpha}$ 为主要的优化参数,其中,$\boldsymbol{\alpha} = [\boldsymbol{\alpha}_1, \boldsymbol{\alpha}_2, \cdots, \boldsymbol{\alpha}_N]$。针对此优化问题,采用方向交替法(ADM)[26] 交替地更新优化 $\boldsymbol{P}$ 和 $\boldsymbol{\alpha}$ 这两个参数。算法 1 显示了整个优化过程,主要包括 4 个步骤,其中,步骤 2 和步骤 4 是该算法的两个子优化问题。

算法 1 将核化群稀疏学习模型的优化问题转化为两个常规的优化问题,即,步骤 2 中对 $\boldsymbol{P}$ 的优化问题和步骤 4 中对 $\boldsymbol{\alpha}$ 的优化问题。具体地,步骤 2 的目标是求解最优的参数 $\boldsymbol{P}$,采用不精确的增广拉格朗日乘子法求解[25,27];步骤 4 的目标是求解最优的权重 $\boldsymbol{\alpha}$。由于该优化问题属于非负 Lasso 问题,所以直接调用 SLEP 包[28] 进行求解。

算法 1 核化群稀疏学习模型的优化

输入:特征 $\boldsymbol{X}$,训练标签 $\boldsymbol{L}$,核函数 $\varphi(x,y)$,最大迭代次数 $k_{\max}$,权衡系数 λ 和 ξ。

输出:最优 $\boldsymbol{P}$ 和 $\boldsymbol{\alpha}$。

初始化:迭代次数 $k=0$,$\boldsymbol{\alpha} = 0$,$\boldsymbol{K}_n = \varphi(\boldsymbol{x}_n, \boldsymbol{x}_n)$。

While 目标函数 $< \varepsilon$ 或 $k < k_{\max}$ do:

1.固定 $\boldsymbol{\alpha}^k$,计算 $\widehat{\boldsymbol{K}}^{k+1}$:

$$\widehat{\boldsymbol{K}}^{k+1} = [\boldsymbol{\alpha}_1^k \boldsymbol{K}_1^{\mathrm{T}}, \boldsymbol{\alpha}_2^k \boldsymbol{K}_2^{\mathrm{T}}, \cdots, \boldsymbol{\alpha}_N^k \boldsymbol{K}_N^{\mathrm{T}}]^{\mathrm{T}}$$

2.固定 $\boldsymbol{\alpha}^k$,更新 $\boldsymbol{P}^{k+1}$:

$$\boldsymbol{P}^{k+1} = \arg\min_{\boldsymbol{P}} \|\boldsymbol{L} - \boldsymbol{P}^{\mathrm{T}} \widehat{\boldsymbol{K}}^{k+1}\|_{\mathrm{F}}^2 + \xi \|\boldsymbol{P}\|_1$$

3.固定 $\boldsymbol{P}^{k+1}$,计算 $\boldsymbol{Z}^{k+1}$:

$$\boldsymbol{Z}^{k+1} = [z_1, z_2, \cdots, z_N]$$

其中 $z_n = \mathrm{vec}(\boldsymbol{P}^{\mathrm{T}} \boldsymbol{K}_n)$,且 $\mathrm{vec}(\boldsymbol{V})$ 表示将矩阵 $\boldsymbol{V}$ 拉成向量。假设 $\boldsymbol{V} = [\boldsymbol{v}_1, \boldsymbol{v}_2, \cdots, \boldsymbol{v}_o]$,且 $\boldsymbol{v}_i$ 是列向量,则 $\mathrm{vec}(\boldsymbol{V})$ 被定义为:

$$\mathrm{vec}(\boldsymbol{V}) = [\boldsymbol{v}_1^{\mathrm{T}}, \boldsymbol{v}_2^{\mathrm{T}}, \cdots, \boldsymbol{v}_o^{\mathrm{T}}]^{\mathrm{T}}$$

4.固定 $\boldsymbol{P}^{k+1}$,更新 $\boldsymbol{\alpha}^{k+1}$:

$$\boldsymbol{\alpha}^{k+1} = \arg\min_{\boldsymbol{\alpha}} \|\boldsymbol{I} - \boldsymbol{Z}^{k+1} \boldsymbol{\alpha}\|_{\mathrm{F}}^2 + \lambda \|\boldsymbol{\alpha}\|_1 \ \text{s.t.} \ \boldsymbol{\alpha} \geqslant 0$$

其中,$\boldsymbol{I} = \mathrm{vec}(\boldsymbol{L})$。

5. $k = k + 1$。

End while

3 实验结果与分析

为了验证所提出的 TB-KGSL 特征选择算法的有效性,本文选用 CASME II 和 SMIC 微表情数据集对不同的特征提取和选择方法进行对比实验。实验时,使用基于支持向量机(SVM)的分类器,并采用主流的留一交叉验证(Leave-One-Subject-Out Cross

Validation,LOSO-CV)方法,比较平均识别准确率和 F1 得分。

3.1 实验设置

CASME II 微表情数据集[10]由中科院傅小兰团队创建,包括了 26 个受试者的 255 个微表情视频样本,且受试者全部来自中国。该数据集将微表情分为 7 类:高兴、厌恶、惊讶、压抑、悲伤、恐惧和其他。由于恐惧和悲伤类别的样本数量较少,本实验中删除了这两类的视频样本,只使用高兴、厌恶、惊讶、压抑和其他 5 类微表情的 246 个视频样本。SMIC 微表情数据集[11]由奥卢大学机器视觉与信号分析中心的赵国英团队创建。SMIC 包括了 3 个子集:SMIC-HS、SMIC-VIS 和 SMIC-NIR,分别采用高速相机、可见光摄像机和近红外摄像机采集。由于 SMIC-HS 的样本量最大,且帧率最高,因此,本实验使用 SMIC-HS 数据集。SMIC-HS 数据集包含了 16 个受试者的 164 个样本,且受试者来自 3 个不同的国家。此数据集中,微表情样本分为 3 类:积极、消极和惊讶。

由于特征提取并不是本文的核心工作,因此,两组特征的提取采用文献[19]中的最优设置。在第一支路中,CASME II 数据集上的每个微表情视频序列被划分为 5 * 5 * 1 个视频块,而 SMIC-HS 数据集上的每个微表情视频序列被划分为 8 * 8 * 2 个视频块,即,分别从 CASME II 和 SMIC-HS 数据集上的每个微表情视频序列中提取 25 个和 128 个 LBP-TOP 子特征。在第二支路中,分别从 CASME II 和 SMIC-HS 数据集上的每个微表情视频序列中提取 18 个方向上的 HSDG 子特征。

对于 KGSL 模型,最大迭代次数 $k_{\max}$ 设置为 100;ε 设置为 $1 * 10^{-4}$,且若连续 3 次迭代 ε 不下降,则迭代停止;权衡系数 ξ 为 1。λ 决定着权重 $\boldsymbol{\alpha}$ 的稀疏性,在区间[0.01,0.10]中以 0.02 为间隔选择 λ 并对其进行测试。从文献[19]的实验结果可知,LBP-TOP 特征比 HSDG 特征能够提供更加有效的可鉴别信息,且某些方向上的 HSDG 特征甚至会存在干扰信息。因此,应当适当地保留更多的 LBP-TOP 特征,而着重筛选 HSDG 特征。本实验将阈值 T_1 设置为 0,即,选择权重大于 0 的 LBP-TOP;而对于阈值 T_2 的设置,由于 CASME II 和 SMIC-HS 两个数据集上 HSDG 特征的特征维度及特征分布的差异,使得学习到的权重范围有差异,因此,对于 CASME II 数据集,在区间[0.1,0.3]中以 0.05 为间隔选择 T_2 并对其进行测试;对于 SMIC-HS 数据集,在区间[1,3] 中以 0.5 为间隔选择 T_2 并对其进行测试。

3.2 特征选择性能的评估

本节通过消融实验对提出的 TB-KGSL 特征选择算法进行性能评估。表 1 列出了不同方法在 CASME II 和 SMIC 数据集上识别准确率和 F1 得分的比较,其中,LBP-TOP 表示采用传统的 LBP-TOP 特征,且不做特征选择;LBP-TOP + HSDG 表示对 LBP-TOP 和 HSDG 两组特征不做特征选择而直接进行拼接融合,视为基线方法;LBP-SDG 表示文献[19]提出的方法,通过手动测试将人工选择的最优方向的 HSDG 特征与完整的 LBP-TOP 特征进行拼接融合;KGSL 表示文献[25]提出的原始 KGSL,对 LBP-TOP 和 HSDG 两组特征一起进行选择。

表 1　特征选择性能的评估结果

方法	CASME II		SMIC-HS	
	准确率/%	F1 得分	准确率/%	F1 得分
LBP-TOP[2]	66.68	0.630 5	64.97	0.593 5
LBP-TOP+HSDG	62.86	0.593 0	60.75	0.575 0
LBP-SDG[19]	71.32	0.663 0	67.86	0.613 6
KGSL[25]	67.14	0.641 1	59.56	0.589 0
提出的 TB-KGSL	68.63	0.657 9	75.95	0.667 0

与 LBP-TOP 相比,LBP-TOP+ HSDG 的性能反而下降,这表明直接将 18 个方向上的 HSDG 特征与 LBP-TOP 特征拼接融合,不仅不会提升性能,反而会恶化性能。与 LBP-TOP 和 LBP-TOP + HSDG 对比,提出的 TB-KGSL 算法有着更加优秀的性能,这表明 TB-KGSL 能够有效地从两组特征中选择可鉴别特征。与 KGSL 对比,提出的 TB-KGSL 特征选择算法也有优势,这表明对 LBP-TOP 和 HSDG 两组特征分开单独进行特征选择优于对两组特征一起进行特征选择,其主要原因在于:LBP-TOP 和 HSDG 两组特征在特征维度和特征数量等方面存在差异,导致 KGSL 模型偏向于某一组特征而无法公平地衡量两组特征的贡献度。将 LBP-SDG 与 TB-KGSL 进行对比,在 CASME II 数据集上,LBP-SDG 取得较好的

性能;而在 SMIC-HS 数据集上,TB-KGSL 取得更好的性能。虽然在 CASME II 数据集上 TB-KGSL 选择的特征不如人工选择的最优方向的 HSDG 特征,但是 TB-KGSL 占据了自动选择的优势,不需要通过大量的手动测试来确定最优方向的 HSDG 特征,且可以选择有效区域的 LBP-TOP 特征。此外,TB-KGSL 选择的特征具有较低的特征维度,如表 2 所示,这有利于后续的分类操作。在实际的微表情识别系统中,不必在提取所有区域的 LBP-TOP 特征和所有方向上的 HSDG 特征后再做特征选择和融合,而是根据 TB-KGSL 模型选择出的有效区域和有效方向,仅需提取有效区域上的 LBP-TOP 特征和有效方向上的 HSDG 特征,从而提高特征提取与分类识别的效率。

表 2 特征维度的对比

方法	CASME II	SMIC-HS
LBP-TOP[2]	4 425	6 144
LBP-TOP+HSDG	5 325	10 752
LBP-SDG[19]	4 475	6 400
提出的 TB-KGSL	4 067	4 064

TB-KGSL 模型用于选择对微表情识别贡献度较大的区域和方向上的特征,仅在训练时使用。在实际的微表情识别系统中,仅需要提取由 TB-KGSL 模型选择的有效区域和方向上的特征。另外,实际的微表情识别系统中,特征提取占用了主要的计算资源,而 SVM 仅占用了很少的计算资源。为了评估提出的 TB-KGSL 方法在计算代价方面的表现,表 3 列出了在不使用 TB-KGSL 和使用 TB-KGSL 进行特征选择后提取特征的计算复杂度。假设一个微表情视频序列的长度为 T 帧,每帧图像的分辨率为 $H\times W$,$Q=H\cdot W\cdot T$;LBP-TOP 采用 K_o 点 LBP,一组 HSDG 包含 D_o 个方向上的 HSDG 特征;使用 TB-KGSL 后,LBP-TOP 和 HSDG 的保留率分别为 R_1 和 R_2。从表 3 可以看出,只要保留率 R_1 和 R_2 小于 1,使用 TB-KGSL 进行特征选择后提取特征的计算复杂度总是小于不使用 TB-KGSL 特征选择直接提取 LBP-TOP+HSDG 特征的计算复杂度。为了更直观地分析,以在 SMIC-HS 数据集上的实验结果为例,LBP-TOP 采用 4 点 LBP,保留率 R_1 为 45.31%,HSDG 子特征数 D_o 为 18,保留率 R_2 为 27.78%,那么,提取 TB-KGSL 所选特征的计算复杂度 $O(12.25Q)$ 小于提取 LBP-TOP + HSDG 的 $O(34Q)$。因此,使用 TB-KGSL 进行特征选择后,能够降低计算复杂度,提高识别效率。

表 3 提取不同特征的计算复杂度比较

特征	计算复杂度
LBP-TOP+HSDG	$O(2^{K_o}Q + D_oQ)$
TB-KGSL 选择的特征	$O(2^{K_o}QR_1 + D_oQR_2)$

为了更详细地评估人工选择的特征与 TB-KGSL 自动选择的特征对不同类别微表情的可鉴别性,图 2 和图 3 分别给出了在 CASME II 和 SMIC-HS 数据集上基于人工选择的 LBP-SDG 特征与基于 TB-KGSL 所选特征的分类混淆矩阵。在 CASME II 数据集上,基于 LBP-SDG 特征的方法能够有效地识别压抑类别的微表情,基于 TB-KGSL 所选特征的方法在开心和惊讶类别的识别上更胜一筹,而两种方法在识别厌恶和其他类别的微表情上有着相似的性能;在 SMIC-HS 数据集上,TB-KGSL 选择的特征在 3 种类别的微表情上都更具可鉴别性。虽然在 CASME II 上,基于 LBP-SDG 的方法在识别压抑类别的微表情上更有优势,但基于 LBP-SDG 特征的方法需要大量实验人工地选择单个最优 HSDG,且结论过于依赖提取特征时的参数[19],而基于 TB-KGSL 所选特征的方法不仅占据自动选择的优势,而且可以对 LBP-TOP 和 HSDG 都进行选择。因此,整体来说,TB-KGSL 选择的特征更具可鉴别性。

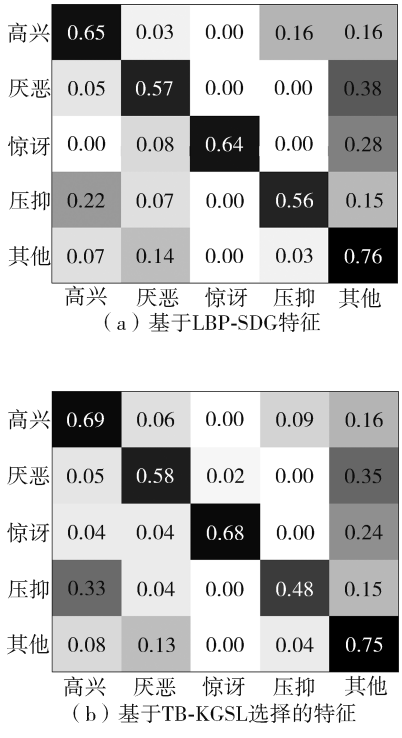
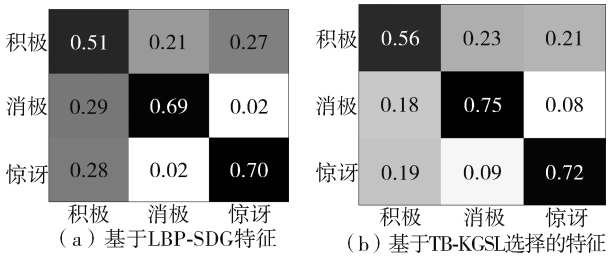


图 2 CASME II 数据集上基于不同特征的分类混淆矩阵对比



(a) 基于LBP-SDG特征　(b) 基于TB-KGSL选择的特征

图 3　SMIC-HS 数据集上基于不同特征的分类混淆矩阵对比

3.3　参数选取

为了确定合适的 λ 和 T_2 参数的取值,实验中采取了由粗到精的测试策略,即先在较大取值范围内粗略地测试参数值对识别准确率的影响情况,然后在选定的较小取值区间内精细地测试识别准确率随参数值的变化情况。具体地,对于参数 λ,先在[0,1]取值范围内以 0.1 为间隔测试 λ 的取值对识别准确率的影响情况,通过比较分析选定[0.01,0.10]为进一步测试的取值区间,然后再以 0.02 为间隔选取 λ 值并对其进行测试,得到如图 4 所示的识别准确率随参数 λ 的变化曲线。整体来说,当 λ 在[0.01,0.10]区间取值时,对识别准确率的影响不大,TB-KGSL 对参数 λ 是比较鲁棒的。在本文的对比实验中,设定 $\lambda=0.01$。对于参数 T_2,在 CASME II 和 SMIC-HS 两个数据集上的测试范围与间隔存在差异。具体地,在 CASME II 数据集上,选定[0.1,0.3]取值区间以 0.05 为间隔选取 T_2 值并对其进行测试;在 SMIC-HS 数据集上,选定[1,3]取值区间以 0.5 为间隔选取 T_2 值并对其进行测试,得到如图 5 所示的识别准确率随参数 T_2 的变化曲线。在图 5 中,横轴刻度用 A/B 形式表示,其中 A 和 B 分别表示在 SMIC-HS 和 CASME II 数据集上 T_2 的取值。在本文的对比实验中,对于 SMIC-HS 数据集,设定 $T_2=2$;对于 CASME II 数据集,设定 $T_2=0.2$。

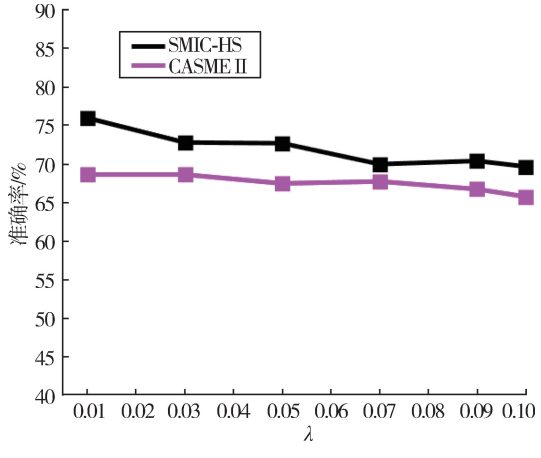


图 4　识别率随参数 λ 的变化图

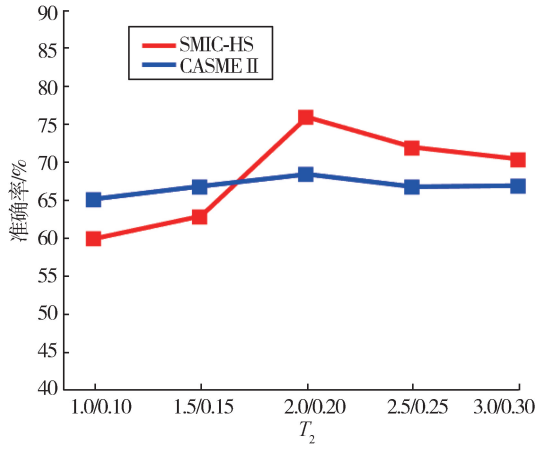


图 5　识别率随参数 T_2 的变化图

3.4　分类器选择

SVM 和 Softmax 分类器是最常用的两个分类器。SVM 是一种有坚实理论基础的小样本学习方法,SVM 的最终决策函数只由少数的支持向量所确定,计算的复杂性取决于支持向量的数目,而不是样本空间的维数,这在某种意义上避免了“维数灾难”,不但算法简单,而且具有较好的鲁棒性。SVM 分类器的输出是每个类别的分类评分,使用的是合页损失(hinge loss)函数。Softmax 是深度学习模型中用于多类分类问题的激活函数。与 SVM 分类器不同,Softmax 分类器的输出是归一化的分类概率,使用的是交叉熵损失(cross-entropy loss)函数。对于输入为基于 TB-KGSL 的融合特征,SVM 和 Softmax 分类器的性能比较如表 4 所示。从表 4 中可以看出,SVM 分类器的性能优于 Softmax 分类器。

表 4　SVM 和 Softmax 分类器的性能比较

分类器	CASME II		SMIC-HS	
	准确率/%	F1 得分	准确率/%	F1 得分
SVM	68.63	0.657 9	75.95	0.667 0
Softmax	63.63	0.601 1	63.33	0.589 7

3.5　与其他方法的对比

与现有的其他微表情识别方法相比,提出的基于 TB-KGSL 的方法在 CASME II 和 SMIC-HS 数据集上都取得了有竞争力的识别性能,如表 5 所示。LBP-IP+KGSL[25] 和 Discriminative LBP-IP[24] 是两种基于特征选择的方法,在 CASME II 数据集上,基于 TB-KGSL 的识别准确率比 LBP-IP + KGSL 和 Discriminative LBP-IP 分别高出 4.80 和 3.85 个百分点;在 SIMC-HS 数据集上,基于 TB-KGSL 的识别准确率比 LBP-IP+KGSL 和 Discriminative LBP-IP 分别高出 15.17 和 12.54 个百分点。与基于深度学习的

LGIL[29]相比,在 CASME II 数据集上,基于 TB-KGSL 的准确率和 F1 得分分别高出 3.61 个百分点和 0.017 9;在 SMIC-HS 数据集上,基于 TB-KGSL 的准确率和 F1 得分分别高出 12.54 个百分点和0.047 0。因此,整体来说,提出的方法在识别性能上超越了现有的其他方法。

表 5 与其他方法的对比

方法	CASME II		SMIC-HS	
	准确率/%	F1 得分	准确率/%	F1 得分
STCLQP[13]	58.39	0.580 0	64.02	0.640 0
LBP-IP+KGSL[25]	63.83	0.610 0	60.78	0.575 0
Discriminative LBP-IP[24]	64.78		63.41	
EVM+HIGO[30]	67.21		68.29	
CNN+LSTM[31]	60.98			
ELRCN-TE[32]	52.44	0.500 0		
LGIL[29]	65.02	0.640 0	63.41	0.620 0
提出的 TB-KGSL	68.63	0.657 9	75.95	0.667 0

4 结束语

本文提出一种基于双支路核化群稀疏学习(TB-KGSL)的特征选择方法,并将之应用于微表情识别系统。首先,提取多个人脸区域的 LBP-TOP 特征和多个方向上的 HSDG 特征,组成两组特征;然后,使用 TB-KGSL 模型从两组特征中分别选择有效区域的 LBP-TOP 特征和有效方向上的 HSDG 特征;最后,将选择的 LBP-TOP 和 HSDG 特征进行拼接融合,得到紧凑且可鉴别的特征,并使用 SVM 进行分类。实验结果表明,提出的 TB-KGSL 模型能够从 LBP-TOP 和 HSDG 两组特征中有效地选择可鉴别的特征,消除两组特征中的冗余及干扰特征,降低特征维度,在有效提高识别准确率的同时,还能有效提升特征提取与分类识别的效率。值得指出的是,本文提出的基于双支路核化群稀疏学习(TB-KGSL)的特征选择方法不仅仅局限于微表情识别任务,还可以应用于多模态情感识别等其他涉及到特征融合的机器学习任务中。

参考文献:

[1] 卢官明, 丛文康, 魏金生, 等. 基于 CNN 和 LSTM 的脑电信号情感识别[J]. 南京邮电大学学报(自然科学版), 2021, 41(1): 58-64.
LU Guanming, CONG Wenkang, WEI Jinsheng, et al. EEG-based emotion recognition using CNN and LSTM [J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2021, 41(1): 58-64.(in Chinese)

[2] ZHAO G Y, PIETIKÄINEN M. Dynamic texture recognition using local binary patterns with an application to facial expressions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6): 915-928.

[3] 卢官明, 宋统帅, 楼亦墨, 等. 基于图的半监督深度学习及其在新生儿疼痛表情识别中的应用[J]. 南京邮电大学学报(自然科学版), 2022, 42(1): 53-61.
LU Guanming, SONG Tongshuai, LOU Yimo, et al. A graph-based semi-supervised deep learning method for recognition of neonatal facial expressions of pain[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2022, 42(1): 53-61.(in Chinese)

[4] BEN X Y, REN Y, ZHANG J P, et al. Video-based facial micro-expression analysis: a survey of datasets, features and algorithms[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(9): 5826-5846.

[5] 傅小兰, 王辉, 范伟. 抑郁症患者的面部表情识别研究[J]. 心理与行为研究, 2015, 13(5): 691-697, 720.
FU Xiaolan, WANG Hui, FAN Wei. Study on the recognition of facial expressions in patients with major depression [J]. Studies of Psychology and Behavior, 2015, 13(5): 691-697, 720.(in Chinese)

[6] 张人, 何宁. 微表情识别研究综述[J]. 计算机工程与应用, 2021, 57(1): 38-47.
ZHANG Ren, HE Ning. A survey of micro-expression recognition methods[J]. Computer Engineering and Applications, 2021, 57(1): 38-47.(in Chinese)

[7] TAKALKAR M, XU M, WU Q, et al. A survey: facial micro-expression recognition [J]. Multimedia Tools and Applications, 2018, 77(15): 19301-19325.

[8] LI S, DENG W H. Deep facial expression recognition: a survey[J]. IEEE Transactions on Affective Computing, 2022, 13(3): 1195-1215.

[9] 徐峰, 张军平. 人脸微表情识别综述[J]. 自动化学报, 2017, 43(3): 333-348.
XU Feng, ZHANG Junping. Facial microexpression recognition: a survey [J]. Acta Automatica Sinica, 2017, 43(3): 333-348.(in Chinese)

[10] YAN W J, LI X, WANG S J, et al. CASME II: an improved spontaneous micro-expression database and the baseline evaluation[J]. PLoS One, 2014, 9(1): e86041.

[11] LI X B, PFISTER T, HUANG X H, et al. A spontaneous micro-expression database: inducement, collection and baseline[C] // 10th IEEE International Conference and Workshops on Automatic Face and Gesture Recognition (FG). 2013: 1-6.

[12] WANG Y D, SEE J, PHAN R C W, et al. Efficient spatio-temporal local binary patterns for spontaneous facial

micro-expression recognition [J]. PLoS One, 2015, 10(5): e0124674.

[13] HUANG X H, ZHAO G Y, HONG X P, et al. Spontaneous facial micro-expression analysis using spatiotemporal completed local quantized patterns[J]. Neurocomputing, 2016, 175: 564-578.

[14] WANG Y D, SEE J, PHAN R C W, et al. LBP with six intersection points: reducing redundant information in LBP-TOP for micro-expression recognition [C] // Computer Vision(ACCV). 2015: 525-537.

[15] HUANG X H, WANG S J, ZHAO G Y, et al. Facial micro-expression recognition using spatiotemporal local binary pattern with integral projection[C] // Proceedings of the IEEE International Conference on Computer Vision Workshop (ICCVW). 2015: 1-9.

[16] WEI J S, LU G M, YAN J J, et al. Micro-expression recognition using local binary pattern from five intersecting planes[J]. Multimedia Tools and Applications, 2022, 81(15): 20643-20668.

[17] LIONG S T, SEE J, PHAN R C W, et al. Subtle expression recognition using optical strain weighted features [C]//Computer Vision(ACCV). 2015: 644-657.

[18] GUO C Y, LIANG J Y, ZHAN G, et al. Extended local binary patterns for efficient and robust spontaneous facial micro-expression recognition[J]. IEEE Access, 2019, 7: 174517-174530.

[19] WEI J S, LU G M, YAN J J. A comparative study on movement feature in different directions for micro-expression recognition[J]. Neurocomputing, 2021, 449: 159-171.

[20] 卢官明, 杨成, 杨文娟, 等. 基于 LBP-TOP 特征的微表情识别[J]. 南京邮电大学学报(自然科学版), 2017, 37(6): 1-7.
LU Guanming, YANG Cheng, YANG Wenjuan, et al. Micro-expression recognition based on LBP-TOP features[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2017, 37(6): 1-7.(in Chinese)

[21] LIU Y J, ZHANG J K, YAN W J, et al. A main directional mean optical flow feature for spontaneous micro-expression recognition[J]. IEEE Transactions on Affective Computing, 2016, 7(4): 299-310.

[22] LIU Y J, LI B J, LAI Y K. Sparse MDMO: learning a discriminative feature for micro-expression recognition [J]. IEEE Transactions on Affective Computing, 2021, 12(1): 254-261.

[23] 张延良, 卢冰, 蒋涵笑, 等. 基于 Fisher 特征选择的微表情识别[J]. 计算机应用与软件, 2020, 37(9): 68-74.
ZHANG Yanliang, LU Bing, JIANG Hanxiao, et al. Micro-expression recognition based on fisher feature selection[J]. Computer Applications and Software, 2020, 37(9): 68-74.(in Chinese)

[24] HUANG X H, WANG S J, LIU X, et al. Discriminative spatiotemporal local binary pattern with revisited integral projection for spontaneous facial micro-expression recognition[J]. IEEE Transactions on Affective Computing, 2019, 10(1): 32-47.

[25] ZONG Y, HUANG X H, ZHENG W M, et al. Learning from hierarchical spatiotemporal descriptors for micro-expression recognition [J]. IEEE Transactions on Multimedia, 2018, 20(11): 3160-3172.

[26] KANG R R, AI D N, QU G R, et al. Prior information constrained alternating direction method of multipliers for longitudinal compressive sensing MR imaging[J]. Neurocomputing, 2020, 376: 128-140.

[27] HU S L, WANG J, HUANG Z H. An inexact augmented Lagrangian multiplier method for solving quadratic complementary problems: an adapted algorithmic framework combining specific resolution techniques[J]. Journal of Computational and Applied Mathematics, 2019, 361: 64-78.

[28] LIU J, YE J P. Efficient Euclidean projections in linear time[C] // Proceedings of the 26th Annual International Conference on Machine Learning. 2009: 657-664.

[29] LI Y T, HUANG X H, ZHAO G Y. Joint local and global information learning with single apex frame detection for micro-expression recognition [J]. IEEE Transactions on Image Processing: a Publication of the IEEE Signal Processing Society, 2021, 30: 249-263.

[30] LI X B, HONG X P, MOILANEN A, et al. Towards reading hidden emotions: a comparative study of spontaneous micro-expression spotting and recognition methods [J]. IEEE Transactions on Affective Computing, 2018, 9(4): 563-577.

[31] WANG S J, LI B J, LIU Y J, et al. Micro-expression recognition with small sample size by transferring long-term convolutional neural network[J]. Neurocomputing, 2018, 312: 251-262.

[32] KHOR H Q, SEE J, PHAN R C W, et al. Enriched long-term recurrent convolutional network for facial micro-expression recognition[C]//13th IEEE International Conference on Automatic Face & Gesture Recognition (FG). 2018: 667-674.

(责任编辑:李小溪)