

基于稀疏子空间迁移学习的跨域人脸表情识别

张雯婧¹, 宋 鹏¹, 陈栋梁¹, 郑文明², 赵 力³

(1. 烟台大学计算机与控制工程学院, 烟台 264005; 2. 东南大学儿童发展与学习科学教育部重点实验室, 南京 210096; 3. 东南大学信息科学与工程学院, 南京 210096)

摘 要: 针对实际场景中人脸表情识别训练和测试数据来自不同场景从而导致识别性能显著下降的问题, 提出了一种基于稀疏子空间迁移学习的跨域人脸表情识别方法。首先, 引入稀疏重构的思想来获得一个共同的投影矩阵, 同时对重构系数矩阵施加 $L_{2,1}$ 范数约束; 其次, 引入图拉普拉斯正则化项来保留数据的局部判别结构; 最后, 利用源域丰富的标签信息, 将样本投影到一个由标签信息引导的子空间中。在 3 个经典人脸表情数据集中进行了实验, 结果表明所提方法在人脸表情识别中优于其他几种经典的子空间迁移学习方法。

关键词: 人脸表情识别; 迁移学习; 子空间学习; 图正则; 回归

中图分类号: TN912.3 **文献标志码:** A

Cross-Domain Facial Expression Recognition Based on Sparse Subspace Transfer Learning

ZHANG Wenjing¹, SONG Peng¹, CHEN Dongliang¹, ZHENG Wenming², ZHAO Li³

(1. School of Computer and Control Engineering, Yantai University, Yantai 264005, China; 2. Key Laboratory of Child Development and Learning Science of Ministry of Education, Southeast University, Nanjing 210096, China; 3. School of Information Science and Engineering, Southeast University, Nanjing 210096, China)

Abstract: In practical facial expression recognition systems, recognition rates will drop significantly when the data are collected from different scenarios. To tackle this problem, in this paper, we propose a sparse subspace transfer learning for cross-domain facial expression recognition. Firstly, inspired by the idea of sparse reconstruction, we aim to learn a common projection matrix, and impose an $L_{2,1}$ -norm constraint on the reconstruction coefficient matrix. Secondly, we introduce the Laplacian regularization to preserve the local discriminative structure. Lastly, by utilizing the rich label information of source domain, we tend to project the source samples into a subspace guided by the label information. We conduct extensive experiments on three popular facial expression datasets. The results show that our proposed method can outperform several state-of-the-art subspace transfer learning methods in facial expression recognition.

Key words: facial expression recognition; transfer learning; subspace learning; graph regularization; regression

引 言

人脸表情识别是情感计算、模式识别、信号处理和人机交互等领域的一个非常热门的研究课题。它是将面部表情信息识别为愤怒、厌恶、恐惧、快乐、悲伤和惊讶等基本情感的一种技术^[1-2],近年来,因有着广泛的应用前景而获得大量的关注。如在线教育系统中,实时捕捉分析学生的表情,帮助教师及时掌握学生对课程内容的感兴趣程度和理解程度,有助于加强教学互动;在刑事案件侦破领域,及时准确捕捉到嫌犯细微的表情变化并标注,推测嫌疑人在审讯的过程中是否说谎;在智能驾驶领域,通过捕捉到的人脸表情数据分析驾驶员是否疲劳和精神分散,若发现驾驶员正处于疲劳或注意力不集中的驾驶状态,则发出报警,避免危险事故的发生。

在人脸表情识别的过程中,面部关键特征的提取与表情分类的方法显得尤为重要。对于前者,提出了许多流行的特征提取方法,包括局部二值模式(Local binary patterns, LBP)^[3-4]、Gabor变换^[5]、尺度不变特征变换(Scale invariant feature transform, SIFT)^[6]、局部梯度编码(Local gradient coding, LGC)^[7]、非负矩阵分解(Nonnegative matrix factorization, NMF)^[8]、稀疏编码(Sparse coding, SC)^[9]和深度特征^[10]等。对于后者,许多经典的分类方法被用来实现面部表情分类,如 k -最近邻(k -nearest neighbors, KNN)^[11]、支持向量机(Support vector machine, SVM)^[12]、AdaBoost分类器^[13]、极限学习机(Extreme learning machine, ELM)^[14]等。虽然这些方法都可以在一定程度上提高表情识别率,但大多依赖有监督学习,并且假设训练和测试数据是在单一人脸表情数据库上采集的。然而,在实际应用中,用于训练和测试表情通常是从不同的场景中进行采样的,如不同分辨率、光照、背景、种族、性别等,会引起源域和目标域数据服从不同的分布,造成识别率显著下降。

为了解决上述问题,近几年来随着迁移学习^[15-18]的发展,许多迁移学习的方法被提出用于跨域的图像分类。Yan等^[19]提出了一种无监督域自适应字典学习(Unsupervised domain adaptive dictionary learning, UDADL)方法;Zhang等^[20]提出了一种联合几何和统计对齐(Joint geometrical and statistical alignment, JGSA)方法,在学习到的低维子空间中减少几何和统计分布的差异。虽然上述方法可在一定程度上减少数据分布的差异,但忽略了源域丰富的标签信息,这已被证实对迁移学习非常重要^[21-22]。Xu等^[23]提出了一种判别迁移子空间学习(Discriminative transfer subspace learning, DTSL)方法,对重构系数矩阵联合施加低秩和稀疏约束,并引入了标签松弛回归项;Zhang等^[24]提出了一种无监督域自适应的引导子空间学习(Guide subspace learning, GSL)方法,该方法较之前的迁移学习方法有了明显的提高,但是高维特征中存在许多冗余或噪声数据,使得低秩约束可能无法很好地工作,另外并未考虑数据的局部判别结构,在一定程度上会影响迁移效果。

基于上述分析,受迁移学习和流形学习的启发,本文提出了一种基于稀疏子空间迁移学习的跨域人脸表情识别方法。首先,考虑到源域和目标域中数据分布的差异,通过迁移特征表示学习来学习一个公共子空间,同时对重构系数矩阵施加稀疏约束,使目标域数据能够由源域数据很好地线性表示;其次,在目标函数中考虑源域丰富的标签信息,引入图拉普拉斯正则化项,以充分考虑源域和目标域的局部判别几何结构,同时引入标签回归,从而可以获得不同域条件下的鲁棒情感特征表示,有效实现跨域条件下的人脸表情识别。

1 稀疏子空间迁移学习的跨域人脸表情识别

本文提出的基于稀疏子空间迁移学习的跨域人脸表情识别方法示意图如图1所示。

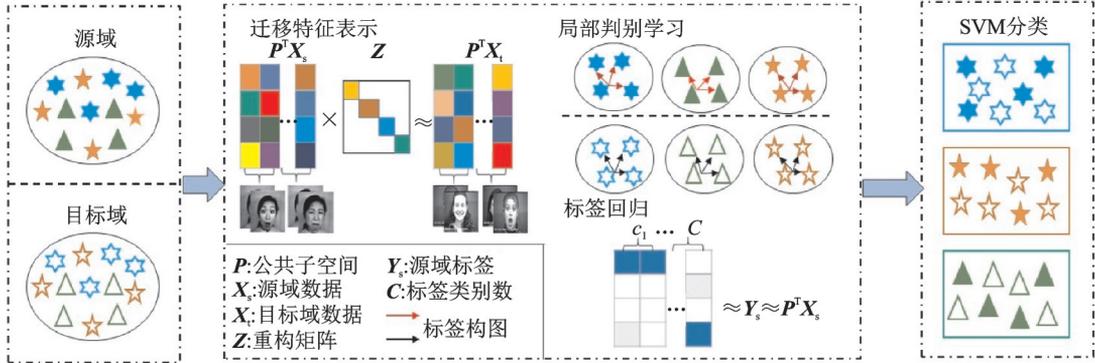


图1 稀疏子空间迁移学习示意图

Fig.1 Diagram of sparse subspace transfer learning

1.1 迁移特征表示

考虑到源域和目标域数据分布的差异,本文引入子空间数据重构^[23-24]的思想。目的是找到一个理想的投影矩阵 $P \in \mathbb{R}^{d \times c}$, 将源域的情感特征 $X_s \in \mathbb{R}^{d \times n_s}$ 和目标域情感特征 $X_t \in \mathbb{R}^{d \times n_t}$ 投影到一个公共子空间(源域和目标域数据的分布大致相同)中。通过学习一个重构的系数矩阵 $Z \in \mathbb{R}^{n_s \times n_t}$, 目标域中的数据可以由源域的数据进行线性表示。故该问题可以定义为

$$\min_{P, Z} \|P^T X_t - P^T X_s Z\|_F^2 \quad (1)$$

目前工作主要是利用 L_1 范数来对重构系数矩阵 Z 进行约束^[23], 这样做可以使矩阵中的大多数元素趋向于0, 但 L_1 范数没有旋转不变性^[25]。为提高算法针对不同数据库的鲁棒性, 本文利用 $L_{2,1}$ 范数来对重构系数矩阵进行约束, 使其保留少量的有价值的源域数据就可以对目标域数据进行重构, 因此, 可将问题定义为

$$\min_{P, Z} \|P^T X_t - P^T X_s Z\|_F^2 + \alpha \|Z\|_{2,1} \quad (2)$$

式中: $\|\cdot\|_F$ 为 F 范数, $\|\cdot\|_{2,1}$ 为 $L_{2,1}$ 范数, $L_{2,1}$ 具体表示为 $\|Z\|_{2,1} = \sum_{i=1}^{n_s} \sqrt{\sum_{j=1}^{n_t} Z_{ij}^2}$, α 为规整因子, 用于调整迁移特征表示项与稀疏表示项之间的平衡关系。

1.2 局部判别学习

迁移特征表示在一定程度上可以减少数据分布的差异, 但是只注重利用源域数据来对目标域数据进行拟合, 可能会破坏子空间中源域和目标域内固有的局部几何结构。同时, 在迁移学习的过程中, 来自同一类的样本在分布匹配过程中距离尽量保持足够的接近。因此, 本文在迁移特征表示的基础上引入图拉普拉斯正则化项^[26]。具体地, 鉴于目标域没有标签信息, 采用简单的 SVM 分类器获得目标域的初始伪标签 Y_t , 然后在目标子空间的迭代学习中更新伪标签。本文提出分别对源域和目标域数据利用标签构图, 最终将局部判别学习项表示成如下形式

$$\min_P \text{tr}(P^T X L X^T P) \quad (3)$$

式中: $\text{tr}(\cdot)$ 表示矩阵的迹, $X=[X_s, X_t]$, $L=D-W$ 为图拉普拉斯矩阵, 其中 $L=\begin{pmatrix} D_s-W_s & 0 \\ 0 & D_t-W_t \end{pmatrix}$, D_s 和 D_t 为对角矩阵, 具体表示为 $D_{ii}=\sum_{j=1}^n w_{ij}$, W 为一权重矩阵, 这里采用热核公式来计算 W_s 和 W_t , 即如果源域(或目标域)样本 x_i 和 x_j 相互连接, 它们之间的权重满足

$$W_{ij}=\begin{cases} \exp\left(-\frac{\|x_i-x_j\|^2}{2\sigma^2}\right) & i\neq j, y_{s_i}=y_{s_j} \text{ 或 } y_{t_i}=y_{t_j} \\ 0 & \text{其他} \end{cases} \quad (4)$$

1.3 标签回归

考虑到源域有丰富的标签信息, 引入传统的标签回归^[27]的思想, 将原始的源域样本映射到一个由源域标签信息引导的子空间中, 从而保证了在该子空间中源域和目标域数据具有相同或者相似的分布。具体表示为

$$\min_P \|Y_s - P^T X_s\|_F^2 \quad (5)$$

最终, 将式(2)中的迁移特征表示、式(3)中的局部判别学习、式(5)中的标签回归项相结合, 得到最终目标函数, 表示为

$$\begin{aligned} \min_{P,Z} & \|P^T X_t - P^T X_s Z\|_F^2 + \alpha \|Z\|_{2,1} + \beta \text{tr}(P^T X L X^T P) + \gamma \|Y_s - P^T X_s\|_F^2 \\ \text{s.t.} & P^T P = I \end{aligned} \quad (6)$$

2 优化求解

式(6)目标函数涉及一个 $L_{2,1}$ 范数的求解, 虽然 $L_{2,1}$ 范数是个凸函数, 但由于它是不光滑的, 很难直接优化求解^[25]。为了解决这一优化问题, 本文提出了一种迭代优化求解的方法, 当一个变量被求解时其他变量保持不变。主要包括2个优化过程, 具体如下:

(1) 固定重构系数 Z , 求解投影矩阵 P 。则目标函数(6)可以转化为拉格朗日函数的形式如下

$$L(P) = \|P^T X_t - P^T X_s Z\|_F^2 + \gamma \|Y_s - P^T X_s\|_F^2 + \beta \text{tr}(P^T X L X^T P) + \text{tr}(\phi(P^T P - I)) \quad (7)$$

为便于求解, 令 $V = X_t - X_s Z$, 对 P 求偏导可得

$$\frac{\partial L(P)}{\partial P} = \gamma X_s X_s^T P + 2V V^T P + 2X L X^T P + \phi P - \gamma X_s Y_s^T \quad (8)$$

(2) 固定 P , 对 Z 进行求解

$$L(Z) = \text{tr}((P^T X_t - P^T X_s Z)^T (P^T X_t - P^T X_s Z)) + \alpha \|Z\|_{2,1} \quad (9)$$

对于式(9)中的 Z 求偏导可得

$$\frac{\partial L(Z)}{\partial Z} = \alpha Q Z + X_s^T P P^T X_s Z - X_s^T P P^T X_t \quad (10)$$

式中: Q 为对角矩阵, $Q = \frac{1}{2\|z_i\|}$, z_i 为 z 的第 i 行。

对上述过程(1), (2)进行迭代求解, 直到收敛。

3 实验结果与分析

3.1 实验环境

为证明所提方法的有效性, 选择表情识别中广泛使用的3个人脸表情数据集进行实验, 分别是CK+数据库^[28]、JAFPE数据库^[29]和TFEID数据库^[30]。并与多个相关经典子空间学习和子空间迁移

学习算法进行了对比,包括主成分分析(Principal component analysis, PCA)^[31],迁移成分分析(Transfer component analysis, TCA)^[32],联合领域适配(Joint distribution adaptation, JDA)^[33],DTSL^[23],JG-SA^[20],域不变和类判别(Domain invariant and class discriminative, DICD)^[34]特征学习方法及GSL^[24]等。接下来将详细介绍数据库以及相关的实验设置。

CK+数据库^[28]是对Cohn-Kaneda数据集的扩展,由美国卡内基梅隆大学于2010年发布。包括由123名受试者的593个视频姿势序列,被采集者的年龄从18岁到50岁之间。每个序列都是完全FACS编码的,选择每个序列中表情强度最强的最后1~3帧作为该表情的样本。该数据库中包含了愤怒、厌恶、恐惧、快乐、悲伤和惊讶等6种基本情绪,本文选择210幅图像进行对比实验。

日本女性面部表情(JAFFE)数据集^[29]是由日本ATR建立的,该数据集中包含了10名日本女性的213张图片,由七种基本表情组成,分别为愤怒、厌恶、恐惧、快乐、悲伤、惊讶和中性。从中选择183幅图像进行实验。

TFEID数据集^[30]是由来自台湾的40名被试者的7200张图片组成,包括20名男性和20名女性。有8种面部表情,即中性、愤怒、蔑视、厌恶、恐惧、快乐、悲伤和惊讶。每种面部表情有2种强度:轻微强度和高强度。选择210幅轻微强度的图像进行实验。

3.2 实验设置

可以注意到,在这些数据库中面部表情类别是不尽相同的。为进行公平比较,首先,选择3个数据集共有的6种基本表情(愤怒、厌恶、恐惧、快乐、悲伤和惊讶)进行实验。其次,将图像进行灰度化处理并将大小调整为60像素×60像素。然后,对每个人脸图像进行LBP特征提取,并将特征向量的维数设置为2304维。最终,选择一个简单的线性SVM进行表情分类。

基于上述3个表情数据库,任选其中2个,其中一个作为源域,另一个作为目标域,共有6种组合(J→C:源域为JAFFE,目标域为CK+;J→T:源域为JAFFE,目标域为TFEID;C→J:源域为CK+,目标域为JAFFE;C→T:表示源域为CK+,目标域为TFEID;T→C:源域为TFEID,目标域为CK+;T→J:源域为TFEID,目标域为JAFFE),其中源域数据集是有类别标签的,而目标域数据集是没有标签信息的。标签回归项的系数 γ 在 $\{0.1, 0.5, 1, 2, 3, 4, 5, 10\}$ 中进行选择,判别几何结构约束项系数 λ 在 $\{0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1\}$ 中进行选择,稀疏表示项系数 α 在 $\{0.001, 0.005, 0.01, 0.05, 0.1, 0.5, 1\}$ 中进行选择,对于参与对比的几种方法,本文也选择最优参数值得到的实验结果进行比较。

3.3 结果与分析

在表1中,本文给出了不同数据集实验对比下,7种基线方法及本文所提出方法的识别率。从表1可以看出,所提出的方法与传统PCA方法相比提高了8.19%。传统方法识别率低是因为忽略了不同人脸数据库之间的数据分布差异。在跨域人脸表情识别中,源域和目标域数据往往是从不同的场景中收集的,例如不同的种族、环境、设备等,它们遵循不同的特征分布,直接使用传统方法可能会导致识别性能差。与6种迁移子空间学习算法相比较,本文所提出的方法获得了最佳的平均识别性能,平均分类精度为48.55%,与第二最佳方法GSL^[24]方法相比提高了1.41%。这表明,本文所提出的方法可以获得更有效的迁移特征表示空间,并且能够充分利用源域的标签判别子空间及数据的局部判别结构,从而有效地解决跨域人脸表情识别任务。

图2分别给出了6组对比实验在取得最高识别率情况下所得到的混淆矩阵(其中纵轴表示实际类别,横轴表示识别出的类别)。可以发现,首先,混淆矩阵的大多数对角线元素明显优于其他元素,这意味着本文所提出的方法是有效的。其次,无论是高兴还是惊讶,都取得了较高的识别率,这表明本文所

表1 不同算法的分类结果

Table 1 Classification accuracies of different methods

%

数据库	各类算法的分类结果							
	传统方法	TCA	JDA	DTSL	JGSA	DICD	GSL	Ours
J→C	41.43	37.62	45.71	49.52	45.71	48.57	50.00	51.43
J→T	33.71	29.05	37.14	42.86	39.52	38.10	43.33	42.86
C→J	37.70	36.61	37.70	44.81	36.61	42.62	43.17	41.53
C→T	40.95	42.86	47.62	48.10	43.81	47.62	45.71	50.48
T→C	46.19	41.90	52.86	54.76	57.14	50.48	55.24	58.57
T→J	42.08	36.61	37.16	42.62	43.17	43.72	45.36	46.45
平均值	40.36	37.44	43.03	47.11	44.33	45.19	47.14	48.55

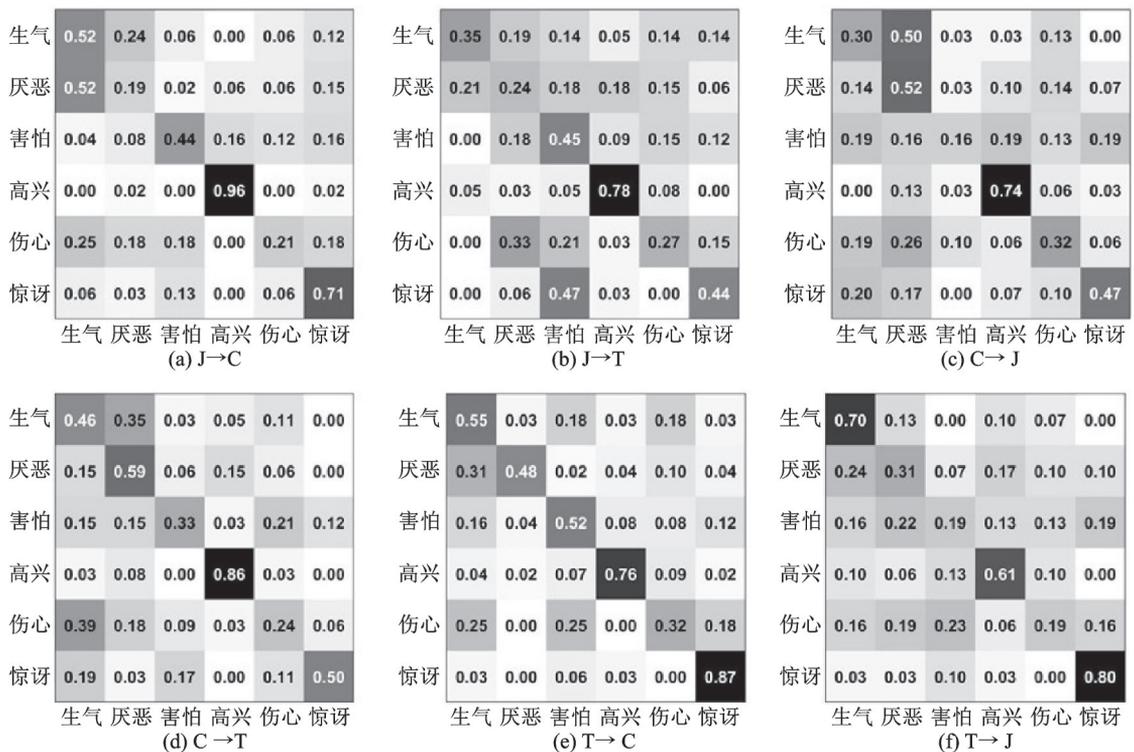


图2 不同情况下的混淆矩阵

Fig.2 Confusion matrixes in different cases

提出的方法可以很好地区分这两种情感,此外,也可以发现厌恶和生气的表情相比其他表情混乱的多,伤心表情识别率相对较低。

为了进一步验证本文提出方法的有效性,分别考虑了2种特殊情况,即 $Ours_a$ (忽略源域标签引导项, $\gamma = 0$)、 $Ours_b$ (忽略局部判别学习项, $\beta = 0$) 以及本文所提出的方法,消融实验结果如图3所示。从图中可以发现,无论是忽略局部判别学习项还是源域标签引导项,都会导致识别的性能下降,而本文提出方法总是可以获得最佳的识别性能,从而验证了本文所提模型在解决跨域人脸表情识别过程中的有效性。

4 结束语

本文提出了一种基于稀疏子空间迁移学习的跨域人脸表情识别方法。首先,通过特征表示学习解决跨域知识迁移问题;其次,为了避免破坏判别子空间中源域和目标域内固有的局部几何结构,分别对源域和目标域构造类内紧度图;同时,通过引入一个标签回归项,将源域样本映射到一个由源域标签信息引导的子空间中。实验结果表明,本文的算法优于对几种较先进子空间迁移学习算法。近几年来深度学习取得了巨大突破,但是需要对训练数据进行大量人工标注,为了缓解深度学习存在的这一问题,零样本学习^[35]的出现得到了研究者的广泛关注,下一步将把工作扩展到零样本学习中,来解决训练人脸表情数据量小的问题。

参考文献:

- [1] 叶继华,祝锦泰,江爱文,等. 人脸表情识别综述[J]. 数据采集与处理, 2020, 35(1): 21-34.
YE Jihua, ZHU Jintai, JIANG Aiwen, et al. Facial expression recognition: A survey[J]. Journal of Data Acquisition and Processing, 2020, 35(1): 21-34.
- [2] EKMAN P, FRIESEN W V. Constants across cultures in the face and emotion[J]. Journal of Personality and Social Psychology, 1971, 17(2): 124.
- [3] ZHAO G, PIETIKAINEN 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.
- [4] SHAN C, GONG S, MCOWAN P W. Facial expression recognition based on local binary patterns: A comprehensive study [J]. Image and Vision Computing, 2009, 27(6): 803-816.
- [5] GU W, XIANG C, VENKATESH Y V, et al. Facial expression recognition using radial encoding of local Gabor features and classifier synthesis[J]. Pattern Recognition, 2012, 45(1): 80-91.
- [6] SOYEL H, DEMIREL H. Localized discriminative scale invariant feature transform based facial expression recognition[J]. Computers & Electrical Engineering, 2012, 38(5): 1299-1309.
- [7] TONG Y, CHEN R, CHENG Y. Facial expression recognition algorithm using LGC based on horizontal and diagonal prior principle[J]. Optik International Journal for Light & Electron Optics, 2014, 125(16): 4186-4189.
- [8] ZHI R, FLIERL M, RUAN Q, et al. Graph-preserving sparse nonnegative matrix factorization with application to facial expression recognition[J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2010, 41(1): 38-52.
- [9] CHEN Y, ZHANG S, ZHAO X. Facial expression recognition via non-negative least-squares sparse coding[J]. Information, 2014, 5(2): 305-318.
- [10] 卢官明,朱海锐,郝强,等. 基于深度残差网络的人脸表情识别[J]. 数据采集与处理, 2019, 34(1): 50-57.
LU Guanming, ZHU Hairui, HAO Qiang, et al. Facial expression recognition based on deep residual network[J]. Journal of Data Acquisition and Processing, 2019, 34(1): 50-57.
- [11] SOHAIL A S M, BHATTACHARYA P. Classification of facial expressions using k -nearest neighbor classifier[C]// Proceedings of International Conference on Computer Vision/Computer Graphics Collaboration Techniques and Applications. Heidelberg, Germany: Springer, 2007: 555-566.
- [12] KHALIFA H, BABIKER B, GOEBEL R, et al. Facial expression recognition using SVM classification on mic-macro patterns

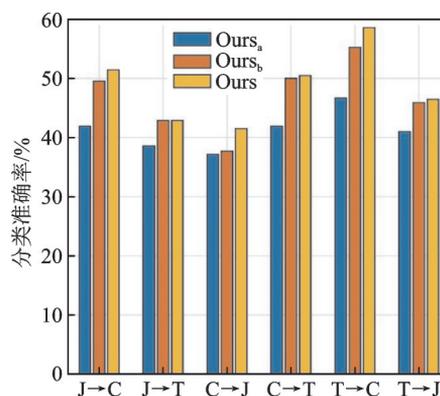


图3 不同情况下的分类准确率比较

Fig.3 Comparison of classification accuracy in different cases

- [C]// Proceedings of 2017 IEEE International Conference on Image Processing (ICIP). [S.l.]: IEEE, 2017: 1757-1761.
- [13] OWUSU E, ZHAN Y, MAO Q R. A neural-AdaBoost based facial expression recognition system[J]. *Expert Systems with Applications*, 2014, 41(7): 3383-3390.
- [14] CHEN C, JIANG B, CHENG Z, et al. Joint domain matching and classification for cross-domain adaptation via ELM[J]. *Neurocomputing*, 2019, 349: 314-325.
- [15] SHAO L, ZHU F, LI X. Transfer learning for visual categorization: A survey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(5): 1019-1034.
- [16] ZHANG J, LI W, OGUNBONA P, et al. Recent advances in transfer learning for cross-dataset visual recognition: A problem-oriented perspective[J]. *ACM Computing Surveys (CSUR)*, 2019, 52(1): 1-38.
- [17] 庄福振, 罗平, 何清, 等. 迁移学习研究进展[J]. *软件学报*, 2015, 26(1): 26-39.
ZHUANG Fuzhen, LUO Ping, HE Qing, et al. Survey on transfer learning research[J]. *Journal of Software*, 2015, 26(1): 26-39.
- [18] 刘建伟, 孙正康, 罗雄麟. 域自适应学习研究进展[J]. *自动化学报*, 2014, 40(8): 1576-1600.
LIU Jianwei, SUN Zhengkang, LUO Xionglin. Review and research development on domain adaptation learning[J]. *Acta Automatica Sinica*, 2014, 40(8): 1576-1600.
- [19] YAN K, ZHENG W, CUI Z, et al. Cross-database facial expression recognition via unsupervised domain adaptive dictionary learning[C]// Proceedings of International Conference on Neural Information Processing. Cham, Cambodia: Springer, 2016: 427-434.
- [20] ZHANG J, LI W, OGUNBONA P. Joint geometrical and statistical alignment for visual domain adaptation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. [S.l.]: IEEE, 2017: 1859-1867.
- [21] SONG P. Transfer linear subspace learning for cross-corpus speech emotion recognition[J]. *IEEE Transactions on Affective Computing*, 2019, 10(2): 265-275.
- [22] CHEN D, SONG P, ZHANG W, et al. Robust transferable subspace learning for cross-corpus facial expression recognition[J]. *IEICE Transactions on Information and Systems*, 2020(10): 2241-2245.
- [23] XU Y, FANG X, WU J, et al. Discriminative transfer subspace learning via low-rank and sparse representation[J]. *IEEE Transactions on Image Processing*, 2015, 25(2): 850-863.
- [24] ZHANG L, FU J, WANG S, et al. Guide subspace learning for unsupervised domain adaptation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019(31): 3374-3388.
- [25] NIE F, HUANG H, CAI X, et al. Efficient and robust feature selection via joint $L_{2,1}$ -norms minimization[C]// Proceedings of International Conference on Neural Information Processing Systems. [S.l.]: Curran Associates Inc, 2010.
- [26] LONG M, WANG J, DING G, et al. Transfer learning with graph co-regularization[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2014, 26(7): 1805-1818.
- [27] NASEEM I, TOGNERI R, BENNAMOUN M. Linear regression for face recognition[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2010, 32(11): 2106-2112.
- [28] LUCEY P, COHN J F, KANADE T, et al. The extended Cohn-Kanade dataset (CK+): A complete dataset for action unit and emotion-specified expression[C]// Proceedings of Computer Vision & Pattern Recognition Workshops. [S.l.]: IEEE, 2010.
- [29] LYONS M J, AKAMATSU S, KAMACHI M G, et al. Coding facial expressions with Gabor wavelets[C]// Proceedings of the 3rd IEEE International Conference on Automatic Face and Gesture Recognition. [S.l.]: IEEE, 2002.
- [30] CHEN L F, YEN Y S. Taiwanese facial expression image database[D]. Taipei, China: National Yang-Ming University, 2007.
- [31] VIDAL R, MA Y, SASTRY S. Generalized principal component analysis (GPCA)[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(12): 1945-1959.
- [32] PAN S J, TSANG I W, KWOK J T, et al. Domain adaptation via transfer component analysis[J]. *IEEE Transactions on Neural Networks*, 2010, 22(2): 199-210.

- [33] LONG M, WANG J, DING G, et al. Transfer feature learning with joint distribution adaptation[C]// Proceedings of the IEEE International Conference on Computer Vision. [S.l.]: IEEE, 2013: 2200-2207.
- [34] SHUANG L, SHIJI S, GAO H, et al. Domain invariant and class discriminative feature learning for visual domain adaptation [J]. IEEE Transactions on Image Processing, 2018, 27: 4260-4273.
- [35] 张鲁宁,左信,刘建伟. 零样本学习研究进展[J]. 自动化学报,2020,46(1): 1-23.
ZHANG Luning, ZUO Xin, LIU Jianwei. Research and development on zero-shot learning[J]. Acta Automatica Sinica, 2020, 46(1): 1-23.

作者简介:



张雯婧(1997-),女,硕士研究生,研究方向:人脸表情识别、迁移学习。



宋鹏(1983-),通信作者,男,副教授,研究方向:情感计算、模式识别等,E-mail: pengsongseu@gmail.com。



陈栋梁(1995-),男,硕士研究生,研究方向:人脸表情识别、迁移学习。



郑文明(1974-),男,教授,研究方向:情感计算、模式识别等。



赵力(1958-),男,教授,研究方向:语音信号处理。

(编辑:张彤)