

用异质迁移学习构建跨被试脑电情感模型

郑伟龙^{1),2),3),4)} 石振锋¹⁾ 吕宝粮^{1),2),3)}

¹⁾(上海交通大学计算机科学与工程系仿脑计算与机器智能研究中心 上海 200240)

²⁾(上海交通大学智能交互与认知工程上海高校重点实验室 上海 200240)

³⁾(上海交通大学脑科学与技术研究中心 上海 200240)

⁴⁾(哈佛医学院麻省总医院神经病学系 波士顿 02114 美国)

摘 要 由于脑电信号的个体差异性和非平稳特性对情感模型性能产生影响,如何构建跨被试脑电情感模型是情感脑-机接口领域的一个重要研究方向.本文提出一种新的从眼睛的扫视轨迹进行知识迁移的异质迁移学习方法,以提升跨被试脑电情感模型的性能.该方法的主要神经生理学依据是,被试的视觉注视诱发了大脑特定的神经活动,而这些神经活动产生的脑电信号可以为情绪识别提供重要的情境线索.为了量化不同被试之间的域差异,我们引入了基于扫视轨迹和基于脑电信号的核矩阵,并提出了改进的直推式参数迁移学习算法,以实现跨被试脑电情感模型的构建.该方法与传统方法相比,具有两个优点:一是利用了目标被试容易获取的眼动追踪数据进行被试迁移;二是在目标被试只有眼动追踪数据的情况下,仍然能够从其他被试的历史数据中学到脑电信号的情绪类别判别信息.为了验证所提方法的有效性,我们对本文提出的方法与已有的迁移方法在三类情绪识别的脑电和眼动数据集上进行了系统的对比实验研究.实验结果表明,基于眼动轨迹的迁移模型取得了与基于脑电信号的迁移模型相当的识别性能.相对于传统的通用分类器 50.46% 的平均准确率,基于眼动轨迹的迁移模型的平均准确率达到 69.72%.

关键词 情感脑-机接口;多模态情绪识别;跨被试情感模型;迁移学习;脑电信号;眼动信号;扫视轨迹

中图法分类号 TP18 **DOI号** 10.11897/SP.J.1016.2020.00177

Building Cross-Subject EEG-Based Affective Models Using Heterogeneous Transfer Learning

ZHENG Wei-Long^{1),2),3),4)} SHI Zhen-Feng¹⁾ LU Bao-Liang^{1),2),3)}

¹⁾(Center for Brain-like Computing and Machine Intelligence, Department of Computer Science and Engineering, Shanghai Jiao Tong University, Shanghai 200240)

²⁾(Key Laboratory of Shanghai Education Commission for Intelligent Interaction and Cognitive Engineering, Shanghai Jiao Tong University, Shanghai 200240)

³⁾(Brain Science and Technology Research Center, Shanghai Jiao Tong University, Shanghai 200240)

⁴⁾(Department of Neurology, Massachusetts General Hospital, Harvard Medical School, Boston 02114, USA)

Abstract Developing robust cross-subject EEG-based affective models is one of the key problems in affective brain-computer interfaces due to the challenges of individual differences and non-stationarity of EEG for building satisfactory affective models. In recent studies, transfer learning has been successfully applied to reducing the differences of feature distributions between source and target subjects. However, it is still necessary for users to acquire a moderately large amount of unlabeled EEG data from target subjects. Unlike the existing transfer learning frameworks solely on EEG, we propose an alternative approach to applying eye tracking data for calibration. In this paper, we propose a novel approach to leveraging heterogeneous knowledge from

spatiotemporal scanpath patterns to enhance the performance of cross-subject EEG-based affective models. The main ideas behind our approach are that what and where subjects are watching would elicit their specific neural activities in the brains and such useful information would provide important clues to emotion recognition. We introduce heterogeneous transfer learning to use the modified transductive parameter transfer (TPT) framework. The TPT approach consists of three main steps. First, multiple individual classifiers are learned on each training dataset of source subjects. Second, a regression function is trained to learn the relation between the data distributions and classifiers parameter vectors. Finally, target classifier is obtained using the target feature distribution and the distribution-to-classifier mapping. To quantify the domain discrepancy across subjects, the scanpath sequences under the same film clips from different subjects are encoded and compared as a measurement of domain discrepancy for subject transfer by using dynamic time warping. The scanpath patterns are used as guidance for what knowledge should be transferred and how to transfer relevant affective information. We calculate scanpath-based kernels and EEG-based kernels and construct the cross-subject affective models with the transductive parameter transfer algorithm. The proposed approach has two advantages in comparison with the existing approaches; (1) the easily accessed eye tracking data from target subjects is utilized for subject transfer; (2) with only eye tracking data for target subjects, the proposed heterogeneous knowledge transfer approach can utilize the discriminative properties of EEG from other subjects. For conventional framework, the calibration phase requires recording moderately a large amount of labeled EEG data. In our framework, the calibration phase for new subjects can record only eye tracking data instead and transfer discriminative information of EEG from potential source subjects. It is feasible in some scenarios where collecting eye tracking data is much easier, while adaptive models are still able to recycle the representational capacity of EEG recorded previously for emotion recognition taking the advantage of high performance of EEG. The performance of our proposed approach and the state-of-the-art subject transfer methods are evaluated on an EEG and eye tracking dataset of three affective states (positive, neutral, and negative). The experiential results demonstrate that the scanpath-based transfer models achieve comparative performance in comparison with the EEG-based models and the scanpath-based subject transfer models obtain the mean accuracy of 69.72% in comparison of the conventional generic classifiers with 50.46% in average. These experimental results demonstrate the effectiveness of our proposed approach.

Keywords affective brain-computer interface; multimodal emotion recognition; cross-subject affective models; transfer learning; EEG signal; eye movement signal; scanpath

1 引 言

情感脑-机接口 (Affective brain-computer interface) 研究如何从脑信号中解析和识别用户的情感状态,近年来受到了学术界和工业界的广泛关注^[1]. 特别是情感脑-机接口提供了一种对增强人-机情感交互和精神疾病辅助诊断与治疗的量化评价方法^[2-4]. 情绪是一种由感觉、思想与行为综合而成的复杂的心理和生理状态,它与大脑许多内部和外部活动相

关联. 越来越多的研究表明,不同模态的信号反映了情绪不同侧面的特征,具有一定的互补特性. 因此,研究多模态情感脑-机接口是目前脑-机接口和情感计算领域的一个重要研究方向. 多模态情感脑-机接口是指将中枢神经系统的神经活动与外部行为等不同类型的信号,按照某种策略进行融合的解决方案^[5-8]. 脑电和眼动信号分别对应人的神经生理活动和人的行为变化,并且这两种信号对情绪感知任务具有互补特性^[5-6]. 另外,相对于传统的基于视频图像的人脸表情识别,眼动信号不仅提供了生理信号,

比如瞳孔变化,而且还包含了重要的与情绪相关的情境信息.

现有的多模态情感脑-机接口框架需要在训练阶段花费大量时间进行系统标定(calibration),这限制了其在真实场景的应用.一种比较简单而直接的方法是重复利用之前采集的脑电数据(electroencephalography),直接训练一个通用分类器,而不考虑个体间的差异.但是,传统的机器学习算法建立在训练数据和测试数据独立同分布的假设之上.而这个假设对多模态情感脑-机接口往往难以成立,原因是脑电信号具有非平稳特性,存在个体差异以及信号采集受环境变化影响等.因此,这类通用分类器的性能对于新被试往往会急剧下降.如何减少系统标定成本,构建个性化的稳健的脑电情感模型是该领域当前研究的一个重要问题.

域适用(domain adaptation)是机器学习的一个子领域.该研究的目标是在降低不同域(domain)之间差异的同时,保持不同类别的判别信息^[9].假设 $X \in \mathcal{X}$ 和 $Y \in \mathcal{Y}$ 分别表示脑电特征和情绪标签, $\mathcal{D} = \{\mathcal{X}, \mathcal{Y}\}$ 表示一个域(domain),其中脑电特征和它们对应的情绪标签来自于同一名被试.域适用的目标是在没有任何目标域(target domain)标签数据的情况下,找到一个特征变换函数 $\phi(\cdot)$,使它们的边缘概率分布和条件概率分布满足 $P(\phi(X_S)) \approx P(\phi(X_T))$ 和 $P(Y_S | \phi(X_S)) \approx P(Y_T | \phi(X_T))$. 这里 $\{X_S, Y_S\}$ 和 $\{X_T, Y_T\}$ 分别表示源域(source domain)和目标域(target domain).

目前,研究者们已经将各种迁移学习(transfer learning)方法或域适用算法引入脑-机接口,以减少系统标定时间和解决跨被试的差异性问题^[10-12].尽管具体的实现策略不同,大多数已有方法仅仅考虑从单一脑电特征进行知识迁移.这类方法对于目标被试,尽管不需要采集带标签的脑电数据,但仍需要采集大量无标签的脑电数据进行系统标定.

大多数现有的迁移学习方法主要侧重于同质知识迁移(homogeneous knowledge transfer),这意味着源域和目标域数据均来自相同模态的信号.然而,实际的应用场景可能会根据不同需求采集不同模态的信号.例如多模态情感脑-机接口中的眼动信号,相对于脑电信号,更加方便佩戴和采集.因此,一种可行的方案是考虑如何结合脑电信号的高准确率和眼动信号的舒适性构建多模态跨被试情感模型.异质迁移学习(heterogeneous transfer learning)的目标是实现不同模态信号之间的知识迁移.但是,如何从不同类型的数据源里有效地提取异质知识是迁移

学习的一个挑战性问题.本文提出一种新的解决方案,利用具有时空特性的眼睛的扫视轨迹进行异质知识迁移,以提升跨被试脑电情感模型的性能.

在多模态情感脑-机接口研究中,应用迁移学习的一个主要目的是减少多模态情感脑-机接口系统的标定代价.然而,在实际应用中即使是采集无标签的脑电数据仍然需要大量的时间、人力和成本.理想的解决方案是,对于新被试,只需他们佩戴眼动追踪眼镜记录他们的眼动数据,同时能利用以往其他被试的脑电数据提高新被试的情感模型性能.该方案与已有方法相比具有两大优势:一是减少脑电信号的采集和对脑电信号的依赖,二是用户可以佩戴更少的设备,舒适性更好.

可穿戴眼动追踪技术能够很好地嵌入到以用户为中心的可穿戴设备上.从眼动信号中迁移情感信息到脑电情感模型,能够降低系统标定代价以及获得更高的跨被试识别准确率.例如,在高铁司机情绪预警的应用场景,高铁司机在培训阶段,在模拟驾驶环境下允许佩戴各种信号采集设备,包括干电极脑电信号采集设备和眼动仪眼镜等.但在实际驾驶环境下,现有的高铁司机岗位管理条例不允许高铁司机佩戴干电极脑电信号采集设备,而只允许使用非接触的固定式眼动仪设备采集眼动数据.这样,本文提出的新方法可以将高铁司机在培训阶段的脑电信号和培训后正式上岗的眼动信号结合起来,构筑更精确的跨被试情感模型,实现对高铁司机情绪状态更精确的识别和情绪预警,而传统的同质知识迁移学习方法则无法应用于这类场景.

本文提出了一种新的异质迁移学习方法,从具有时空特性的眼睛的扫视轨迹进行知识迁移,以提升脑电情感模型被试迁移的性能.该方法的优点是,在训练阶段对于新被试只需采集眼动追踪数据,然后通过眼动模式匹配标定,将其他被试的脑电信号的类别判别信息迁移到新被试,从而构建新被试的脑电情感模型.利用脑电信号在情绪识别中区分性高的优势,能够在更少的系统标定时间内获得识别性能更高的情感模型.更重要的是,在真实应用场景中,相对于脑电信号的采集与处理,通常更容易采集和处理眼动信号,而且眼动仪眼镜比脑电采集设备更便于用户佩戴和更易于使用.

2 相关工作

2.1 多模态情感脑-机接口

在人与人交流中,人的情感信息会通过多种信

息渠道进行表达和传递. 因此, 不同模态的信号, 例如表情, 语音和姿态等, 已经被用于情绪识别^[13-16]. 神经科学的许多发现揭示了大脑神经活动与情绪状态之间的关联^[17-18]. 因此, 在多模态情感脑-机接口中, 基于脑电信号的情绪识别被认为是一种有效的方法. Schirmer 和 Adolphs^[19]强调了情绪感知任务中不同模态信号的重要性, 他们总结了不同刺激特征和随后的行为以及大脑的神经活动反应, 指出语音和触摸不是简单地复制视觉机制. 他们发现, 每种模态都提供了一个独特的输入通道, 并使部分不重叠的神经系统具有不同的处理特性. 他们还提出了大脑中不同模态的信号融合机制. 虽然每个通道都采用特定模态的感知系统, 但这些系统中出现的感知表征很早就被整合了.

在实验室环境中, 情感电影片段是一种最普遍的用于情绪诱发的刺激素材^[20-21]. 有很多研究者对观看情感电影片段下的眼动信号进行了研究. 例如, Soleymani 等人^[7]提出了一种利用脑电、瞳孔变化和注视距离的情绪识别方法. 他们利用瞳孔变化和注视距离对被试观看情感电影片段时的情绪效价和激发程度进行了分类. 另外, 他们还探索了不同情绪状态和各种眼动参数之间的关系. 我们在前期研究中提取了眼动信号中与情绪变化相关的瞳孔直径、眨眼、扫视和注视等眼动参数. 我们的实验结果表明, 脑电信号与眼动信号融合能大大提升情绪识别的准确率. 同时, 我们还揭示了脑电信号和眼动信号在情绪识别上的互补特性^[5]. Chen 等人^[22]展示了在社交互动中眼睛注视能够传递情感信息. 我们在另一项前期工作中利用眼动信号评估脑电情绪实验中被试的注意力水平, 我们发现认真观看刺激影片的一组被试相对于另一组不认真观看的被试, 其眼睛的扫视轨迹更加相似, 脑电情绪识别准确率也更高^[23].

最近, 人们结合脑电和眼动特征构建多模态情感模型取得了一系列进展^[5-7, 24-25]. 这些研究的思路是直接将脑电特征与眼动特征融合后进行情绪识别. 因此, 在训练阶段和测试阶段都需要这两种模态的信号. 本研究采用一种与这些方法不同的策略, 我们不直接提取与情绪识别相关的眼动特征, 而是获取和比较不同被试观看相同电影片段时的眼睛的扫视轨迹序列, 引入基于扫视轨迹相似性的核矩阵作为衡量不同被试相似性的指标, 以实现脑电特征空间中的知识迁移.

2.2 脑-机接口中的迁移学习

近年来, 迁移学习方法已被广泛应用于脑-机接

口, 以解决系统标定和跨被试建模问题. 例如, Morioka 和同事^[10]提出了一种字典学习方法, 该方法通过多个被试数据学习他们共同的字典表达, 再利用新被试的静息状态下的数据作为标定数据来评估个体差异性, 而不是利用任务实验的数据进行标定. Krauledat 等人^[26]提出了一种零训练框架来提取那些具有更好的泛化特性的基本空间滤波器. Jayaram 等人^[12]的综述文章对脑-机接口中的迁移学习技术进行了回顾和总结. 然而, 这些方法大多侧重于同质迁移学习, 即仅仅考虑单一脑电特征的知识迁移问题. 在多模态脑-机接口中, 异质迁移学习能够充分利用不同模态信号的特点, 提高系统在实际应用场景的识别率和稳健性.

本研究利用异质迁移学习方法从具有时空特性的眼睛的扫视轨迹训练跨被试情感模型, 即利用其他被试带标签的脑电数据进行训练. 与传统的只使用脑电特征进行迁移的方法相比, 本文所提方法的主要创新点是利用眼睛的扫视轨迹序列作为源域和目标域之间域差异的度量. 在脑-机接口领域, 现有的许多迁移学习框架主要基于单一的脑电数据, 这些方法仍然要求目标域被试有相对较多的有标签或无标签脑电数据^[11]. 在异质迁移学习中, 源域和目标域来自于不同的特征空间. 大部分异质迁移学习方法集中在利用不同域之间的一些对应关系来学习同质特征表示^[27]. 本文提出的框架不同于已有的这些方法, 在我们的框架中, 眼睛的扫视轨迹的异质知识是作为域差异的核矩阵嵌入的, 而不是将脑电和眼动异质特征空间变换到新的共同特征空间.

3 方 法

本节详细介绍所提方法的技术细节. 首先介绍眼动信号与脑电信号关联的神经生物学基础, 然后介绍如何将眼睛的扫视轨迹进行时序编码和利用快速动态时间规划算法量化评估编码后的两两扫视轨迹序列之间的相似程度, 接着介绍改进的直推式参数迁移学习算法和实现脑电和眼动之间的异质迁移, 最后介绍基于脑电和基于眼睛扫视轨迹的被试迁移模型.

3.1 眼动信号与脑电信号关联的神经生物学基础

关于眼动的神经生物学基础, Eckstein 等人^[28]对瞳孔扩张和自发眨眼频率在认知发育和可塑性上的发现进行了详细地综述介绍. 瞳孔扩张由大脑蓝斑-去甲肾上腺素系统 (Locus Coeruleus-Norepi-

nephtrine system,LC-NE)调节,该系统控制生理唤醒和注意力,并且已被用作衡量主观任务难度,脑力(mental effort)和神经增益(neural gain)的量度.瞳孔系统和 LC-NE 脑区活动之间的关系已经有大量的成人和动物的解剖学和生理学研究.例如,蓝斑核神经元发射频率和猴子的瞳孔直径之间的时间耦合强度非常显著^[29-31].自发性眨眼频率与中枢神经系统中的多巴胺水平相关,可揭示学习过程和目标导向行为.视觉注视揭示了当前注意力焦点以及认知策略.

同时,相关研究发现这些眼动参数与功能核磁共振成像和脑电信号有着时间相关性. Eckstein 等人发现,瞳孔扩张,自发性眨眼频率以及视觉注视是三种非侵入性和互补的认知测量方法,具有高时间分辨率和易于理解的神经基础.人类行为测试,功能性神经影像学,动物神经生理学和神经解剖学的相关研究已经确定了几个涉及控制视觉注视和眼球运动的大脑区域,包括大脑皮层,基底神经节,丘脑区域,上丘,脑干网状结构和小脑等^[32-34].因此,眼动相关研究方法可以为认知方面的脑机制研究提供一种简单而有效的辅助手段.

神经生理学的研究发现,视觉注视与神经活动之间存在着关联.许多研究将眼动和脑电信号相结合,探索不同认知任务下的脑机制^[35-36]. Righart 和 De Gelder^[35] 设计了事件诱发电位实验,研究了情绪化场景在人脸表情编码中的影响.他们发现对于恐怖场景中的恐惧人脸相对于高兴场景中的恐惧人脸,N170 成分幅值显著增加.另外,N170 成分在左侧枕颞脑区存在差异. Noh 和 Isaacowitz^[36] 研究了人们在处理情绪面孔和背景语境一致和矛盾的情况下,识别准确率和视觉扫视模式在不同年龄层的差异.他们发现,与年轻人相比,老年人在情境信息一致情况下能获得更大的收益.另外,语境也影响了不同年龄组的情绪面孔的视觉扫视特征.

在情感处理的脑机制研究中,著名的 Cannon-Bard 理论认为,中央结构,包括大脑皮层,主要参与了在不同刺激下的情绪生成,从而激活自主神经系统^[37].而现在的观点认为,面对不同情景的强烈身体反应也会影响情绪状态,特别是强烈程度.我们的研究采用电影片段作为情绪刺激.一方面,被试观看这些电影片段,被试的视觉注视诱发了大脑中特定的神经活动,从而产生不同的情绪状态,这些大脑的神经活动被脑电信号所记录.而另一方面,相关脑区控制的眼动变化也被眼动仪眼镜所记录.外部视觉

刺激下产生的眼动和脑电信号具有关联性,从而为情绪识别提供了重要的情境线索.

3.2 时空扫视轨迹分析

3.2.1 扫视轨迹序列编码

扫视轨迹能够被定义为时序编码的眼动注视序列 $\{(x_0,y_0,t_0),(x_1,y_1,t_1),\cdots,(x_n,y_n,t_n)\}$,其中 x_i 和 y_i 表示注视位置, t_i 表示时间节点, $i=0,1,\cdots,n$.首先,我们将视觉场景平均划分成 30×40 的感兴趣区域(Regions Of Interest,ROI),利用一对唯一的数字指代每个区域.每个注视位置 x 和 y 用该区域对应的一对数字进行编码,根据注视开始时间的顺序将扫视轨迹编码为时间序列.图1给出了眼睛的扫视轨迹序列编码示意图.如图1所示,为了将注视时长考虑在内,我们在扫视轨迹序列中引入了时间分级(temporal binning),即重复眼动相应位置对应的数字对若干次,重复次数与注视时长成正比.在我们的实验中,我们设置时间采样为 50 ms ^[38].所以,我们对于每个 50 ms 时间窗口的注视点,重复或者插入数字对到扫视轨迹序列中.通过这种方法,从眼动数据中提取的扫视轨迹编码序列结合了空间位置信息、时间顺序信息以及注视时长信息.




图1 眼睛的扫视轨迹序列编码示意图(原始序列是ABCDEFGH.将注视时长考虑其中,我们引入时间分级(temporal binning)方法,原始序列可以重新编码为如下时间序列:ABBCDEEFFGH)

3.2.2 扫视轨迹序列比较

这一步的主要目的是为了定量地评估两个扫视轨迹序列的相似程度.不同被试即使是观看同一个视频段,他们的扫视轨迹序列长度也可能不相同.如何比较不同长度的时间序列相似程度是一个首先需要解决的问题.这里,我们引入序列对齐算法:快速动态时间规整算法(FastDTW).该算法是动态时间规整算法(Dynamic Time Warping,DTW)在线性时间和空间中的近似算法^[39].动态时间规整算法能够用于度量两个不同速度的时间序列的相似性,并给出某种类似距离的度量指标.它计算了两个给定的序列在某些约束条件下的最佳匹配.这些序列在

时间维度上进行非线性地规整,以确定它们的相似性的度量,而与时间维度中的某些非线性变化无关.动态时间规整算法一般利用动态规划算法进行求解,其计算复杂度为 $O(N^2)$. 因此,该算法在大数据集上求解需要大量的计算时间.快速动态时间规整算法采用了多级分层方法,递归地将规整路径从较粗糙的分辨率投影到当前分辨率并对其进行细化.

基于快速动态时间规整算法,我们计算了在相同视频片段下的每对扫视轨迹序列的相似性,用做衡量域差异的距离矩阵.基于扫视轨迹的核矩阵定义如下:

$$\kappa(S_i, S_j) = \frac{1}{k} \sum_{p=1}^k FastDTW(s_{pi}, s_{pj}) \quad (1)$$

其中, S_i 和 S_j 分别表示被试 i 和被试 j 的扫视轨迹序列, k 表示视频片段数目.算法 1 详细描述了计算基于扫视轨迹的核矩阵的步骤.

算法 1. 基于扫视轨迹的核矩阵计算.

输入: 不同被试 $1, 2, \dots, N$ 的原始眼动数据集 $F_1, \dots, F_N$, 其中包含注视位置, 注视时长和时间戳信息
输出: 基于扫视轨迹的和矩阵: K

- 1. 利用感兴趣区域编码和时间分级方法构建扫视轨迹序列编码: $S_i = Encoding(F_i)$;
- 2. 比较不同被试之间的扫视轨迹编码序列: 利用式 (1) 计算 $\kappa(S_i, S_j)$;
- 3. 计算核矩阵 K : $K_{ij} = \kappa(S_i, S_j)$;
- 4. 返回: K .

3.3 异质迁移学习

本节介绍利用改进的直推式参数迁移学习方法进行异质迁移学习. 最初的直推式参数迁移学习算法由 Sangineto 和同事^[40]提出, 该算法被用于行动单位检测和自发痛觉识别. 本文所提出的改进的直推式参数迁移学习算法如图 2 所示, 它由 3 个主要步骤构成. 为了直观地理解上述 3 个步骤以及它们之间的相互关系, 图 2 用虚线标注了它们所对应的 3 个区域, 分别是左上部分、右上部分和下方部分. 首先, 对每一个训练集 D_i 学习不同的个体分类器. 其次, 训练回归函数以学习数据分布与分类器分离超平面参数向量之间的关系. 最后, 利用目标特征分布和数据分布到分类器超平面参数的映射函数构建目标分类器.




图 2 本文提出的多模态直推式参数迁移(Transductive Parameter Transfer)学习框架(利用具有时空特性的眼睛的扫视轨迹进行异质知识迁移,以提升跨被试脑电情感模型的性能. 该框架由三部分构成,它们各自的作用和相互关系分别表示为虚线分割的三个区域:左上方部分、右上方部分和下方部分. 首先利用脑电数据构建源域被试的各自不同的分类器,接着分别计算基于脑电和基于扫视轨迹的核矩阵以量化不同被试之间的域差异,然后训练一个回归函数学习特征分布到分类器分离超平面参数之间的映射关系,最后分别得到基于脑电和基于扫视轨迹的迁移模型并给出最终情绪标签的预测值)

根据 3.1 节介绍的眼动信号与脑电信号关联的神经生理学基础,我们提出了如下假设:(1)在不同源域被试情感模型中,脑电特征分布和情绪识别分类器分离超平面参数之间存在着映射关系;(2)通过衡量目标域被试与源域被试之间的相似性,可以估计目标分类器的超平面参数,从而将情绪识别信息迁移到目标域被试。如何衡量目标域被试与源域被试之间的相似性是本文所提方法的关键。同质迁移学习方法主要利用不同度量指标来计算脑电分布相似性。在这里,根据眼动与神经活动的相关性,我们认为眼睛的扫视轨迹也可以量化域差异,即被试之间相似性。在提取眼睛的扫视轨迹序列和利用动态时间规整进行比较后,我们可以得到与基于脑电方法类似的核矩阵,利用参数迁移方法得到跨被试情感模型。

本文改进了直推式参数迁移框架,其主要思想是将原始特征空间中基于脑电的度量和从眼动信号中提取的基于扫视轨迹的度量进行统合,从而对不同被试的数据分布实现了域适用,达到情感模型的个性化。通过引入基于扫视轨迹的核矩阵,可以从眼动追踪数据中迁移异质知识来构建基于脑电的跨被试情感模型。这意味着一方面在系统标定以及模型训练过程中,目标域被试可以不需要采集任何脑电数据。另一方面,源域被试和目标域被试的无标签脑电数据可以用于计算基于脑电的核矩阵,进行同质知识迁移。这部分是传统情感脑-机接口中被试迁移的典型范式。

下面对本文所提的异质迁移学习方法进行详细地描述。首先我们在每个源域数据集 $D_i^s = \{(x_i^s, y_i^s)\}_{i=1}^{n_i}$ 上分别训练相应的个体分类器。这里,我们用线性支持向量机(Support Vector Machine, SVM)作为分类器, $\theta_i = [\omega_i', b_i]$ 定义了特征空间中的超平面参数。目标函数如式(2)所示:

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + \lambda_L \sum_{j=1}^{n_i} l(\omega' x_j^s + b, y_j^s) \quad (2)$$

其中 $l(\cdot)$ 是损失函数(hinge loss)。

在第 2 步,训练一个回归函数 f 来学习源域数据分布中 $D \rightarrow \Theta$ 的映射关系。由于数据分布和对应的最优分离超平面是相关的,通过学习这种映射关系,就能在没有标签信息的目标数据中预测分离超平面参数,进而构建分类器,再利用函数 $\kappa(X_i, X_j)$ 量化两个数据集 X_i 和 X_j 之间的相似性。这里使用了两种核函数:基于密度估计(Density Estimation, DE)

的核矩阵^[41]和基于陆地移动距离(Earth Mover's Distance, EMD)的核矩阵^[42]。基于密度估计的核矩阵定义如下:

$$\kappa_{DE}(X_i, X_j) = \frac{1}{nm} \sum_{p=1}^n \sum_{q=1}^m \kappa_{\mathcal{X}}(x_p, x_q) \quad (3)$$

其中, n, m 分别是 X_i, X_j 的基数, $\kappa_{\mathcal{X}}(\cdot)$ 是高斯核。

为了计算 X_i 和 X_j 之间的陆地移动距离 EMD, 使用 k -means 算法计算每个集合 $\mathcal{I} = \{(v_1^i, w_1^i), \dots, (v_Q^i, w_Q^i)\}$ 和 $\mathcal{J} = \{(v_1^j, w_1^j), \dots, (v_Q^j, w_Q^j)\}$ 的特征集(signatures), 其中 v_q^i 和 v_q^j 分别是 X_i 和 X_j 的聚类质心, 而 w_q^i, w_q^j 是每个聚类相应的权值。利用交叉验证方法确定聚类数目为 5, 每个聚类的基数被用作聚类的权重。这样 X_i 和 X_j 之间的陆地移动距离 EMD 可以定义为

$$D_{\text{EMD}}(X_i, X_j) = \min_{f_{pq} \geq 0} \sum_{p,q=1}^Q d_{pq} f_{pq} \quad (4)$$

s. t. $\sum_{p=1}^Q f_{pq} = w_q^i, \sum_{q=1}^Q f_{pq} = w_p^j$

其中, f_{pq} 是流动变量(flow variable), d_{pq} 是地距离(ground distance), 定义为 $d_{pq} = \|v_p^i - v_q^j\|$ 。从而, 基于 EMD 的核矩阵定义如下:

$$\kappa_{\text{EMD}}(X_i, X_j) = e^{-\rho D_{\text{EMD}}(X_i, X_j)} \quad (5)$$

其中, ρ 是一个参数。对于 EMD 算法的具体细节, 建议读者参考相关文献[40-42]。

在计算核矩阵后, 利用多输出支持向量回归模型(multiooutput support vector regression)^[43], 可以学习到映射函数 f 。在多输出支持向量回归模型中, 映射函数定义 $f: \mathcal{P} \rightarrow \Theta$ 定义为

$$\hat{f}(X) = \phi(X)'B + c' \quad (6)$$

$B = [\beta_1, \dots, \beta_{M+1}]$ 和 $c = [c_1, \dots, c_{M+1}]'$ 分别是权值和偏置项, $\phi(X)$ 是从数据 X 到一个高维空间的非线性映射。通过最小化以下目标函数, 我们可以估计参数 B 和 c :

$$\min_{B, c} \frac{1}{2} \sum_{i=1}^{M+1} \|\beta_i\|^2 + \lambda \sum_{i=1}^N l(\|\theta_i' - \hat{f}_{B, c}(X_i)\|) \quad (7)$$

通过引入核矩阵 $\mathbf{K}$, 映射函数可以表达为

$$\hat{f}(X) = \sum_{i=1}^N V_i \kappa(X_i, X) + c' \quad (8)$$

在之前的论文中^[43], Tuia 及其同事利用了迭代重加权最小二乘法计算 V 和 c 。从而, 我们得到了数据分布到分界面参数的映射函数。

最后, 目标分类器的参数向量可以在没有目标被试标签信息的情况下用 $\theta_i = f(X')$ 或者 $\theta_i = f(S')$ 预测得到。给定目标特征 x 和分类器参数 θ , 对应

的预测情绪标签可以由以下决策函数得到： $y = \text{sign}(w'_i x + b_i)$ 。算法 2 总结了同质和异质迁移学习的直推式被试迁移算法。对于 TPT 算法的更多细节，读者可以参考文献[40]。最后，通过上述计算，我们得到了两种被试迁移模型：基于脑电的跨被试迁移模型和基于扫视轨迹的跨被试迁移模型。

算法 2. 基于直推式参数迁移(TPT)的被试迁移学习方法。

- 输入：源域脑电数据集 $\mathcal{D}_1, \dots, \mathcal{D}_N$ 和扫视轨迹序列 $S_1, \dots, S_N$ 。目标域脑电数据集 X' 和扫视轨迹序列 S' ，以及支持向量机 SVMs 的正则化参数
- 输出：目标分类器的参数向量： $w_i^1, b_i^1, w_i^2, b_i^2$
1. 在源域中利用脑电数据对每个被试构建个体分类器： $\{\theta_i = (w_i, b_i)\}_{i=1}^N$ 。
 2. 建立新的训练集合： $\mathcal{T}^1 = \{X_i^1, \theta_i\}_{i=1}^N$ 和 $\mathcal{T}^2 = \{S_i^1, \theta_i\}_{i=1}^N$ 。
 3. 计算基于脑电和基于扫视轨迹的核矩阵 $\mathbf{K}^1$ 和 $\mathbf{K}^2$ ： $\mathbf{K}_{ij}^1 = \kappa(X_i^1, X_j^1), \mathbf{K}_{ij}^2 = \kappa(S_i^1, S_j^1)$ 。
 4. 给定 $\mathbf{K}^1, \mathbf{K}^2, \mathcal{T}^1$ 和 $\mathcal{T}^2$ ，利用多输出支持向量回归模型学习 $f^1(\cdot)$ 和 $f^2(\cdot)$ 。
 5. 计算 $(w_i^1, b_i^1) = f^1(X')$ 和 $(w_i^2, b_i^2) = f^2(S')$ 。
 6. 返回： w_i^1, b_i^1, w_i^2 和 b_i^2 。

4 实验设置

本节介绍实验的相关设置。首先介绍实验中使用的**情感脑电和眼动追踪数据集**，包括刺激素材、信号采集设备、被试信息以及实验设计等，接着介绍脑电和眼动信号的数据预处理和特征提取，最后介绍实验中采用的评价指标，包括训练集和测试集划分、基线方法以及各种方法的相关参数设置。

4.1 情感脑电和眼动追踪数据集

为了构建情感模型，在实验室环境中设计了情绪实验，采集了不同情绪状态下相应的脑电和眼动数据。通过前期研究评估，我们选择了情感电影片段作为情绪实验的刺激素材。因为电影片段同时包含听觉和视觉刺激，所以被普遍认为对情绪诱发具有良好的效果^[20-21]。因此，本研究采用电影片段作为情绪实验的刺激素材。

我们在前期的研究中收集了超过 150 个视频片段，招募了 20 名独立于被试的参与者对这些视频片段进行了评估。评估指标包括情绪关键字以及情绪的两个维度效价(valence)和激发程度(arousal)，分别进行了满分为 5 分的评价。最终，15 个电影片段被选为三类情绪的刺激素材：正面、中性和负面。每

种情绪均有 5 个电影片段，每个电影片段时长大约是 4 min。这些电影片段在不同参与者评价中获得了最高分数，表明这 15 个电影片段可以比较好地诱发被试的情绪。

每次实验包含 15 个阶段(session)，每个阶段播放其中一个电影片段。在每个电影片段播放前，有 5 s 时间作为开始提示。电影片段结束后有 45 s 时间让被试根据自我情绪诱发程度进行自我评价以及 15 s 的休息。表 1 汇总了在情绪实验中所采用的电影片段细节。

表 1 情绪实验中所采用的电影片段细节

情绪标签	电影片段来源	片段数目
负面	唐山大地震	2
负面	一九四二	3
正面	人再囧途之泰囧	2
正面	唐伯虎点秋香	1
正面	越光宝盒 2	2
中性	世界遗产在中国	5

我们招募了 13 名被试(7 名男性和 6 名女性，年龄范围在 18~30 岁)参与实验。他们在实验前都被告知了实验的目的和实验的相关流程。在实验中，被试要求在认真观看情感电影片段过程中，尽力诱发他们自己相应的情绪，并利用打分方式(1~5 分)报告他们自己的情绪反应作为实验反馈。大部分被试自我情绪诱发评价与电影情绪标签一致，且诱发程度较高。在实验过程中，我们利用 ESI Neuroscan 脑电采集系统，根据国际 10~20 系统电极位置记录 62 导脑电信号^①。原始脑电采样频率为 1000 Hz，每个电极的阻抗低于 5 kΩ。同时我们采用 SMI 眼动追踪眼镜记录眼动数据，再利用 SMI BeGaze 分析软件提取了各种眼动参数^②。相关数据集在本论文发表后将作为脑电情感数据集 SEED(SJTU Emotion EEG Dataset)子集向国内外科研机构和大学研究人员免费公开^③。

4.2 数据预处理和特征提取

为了进一步滤除由于脸部肌肉活动带来的噪声和伪迹干扰，在原始脑电信号上使用了 1~75 Hz 的带通滤波器。原始信号进行下采样到 200 Hz，以减少后期计算复杂度。对每个不重叠的时间窗口为 1 s 的脑电信号片段，提取相应的脑电特征。

在特征提取中采用了微分熵特征(Differential

① <http://www.neuroscan.com/>
② <http://eyetracking-glasses.com/>
③ <http://bcmi.sjtu.edu.cn/~seed>

Entropy, DE). 在之前的相关研究中, 我们发现微分熵特征比传统的功率谱密度特征 (Power Spectral Density, PSD) 表现出更好的性能^[6, 44-45]. 如果一个随机变量服从高斯分布 $N(\mu, \sigma^2)$, 那么它的微分熵可以根据式(9)计算:

$$\begin{aligned} h(X) &= - \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi\sigma^2}} \exp \frac{(x-\mu)^2}{2\sigma^2} \log \frac{1}{\sqrt{2\pi\sigma^2}} \\ &\quad \exp \frac{(x-\mu)^2}{2\sigma^2} dx \\ &= \frac{1}{2} \log 2\pi e \sigma^2 \end{aligned} \quad (9)$$

所以, 微分熵特征可以利用短时傅里叶变换 (Short-term Fourier transform), 在脑电分析中常用的 5 个频段 (δ : 1~3 Hz, θ : 4~7 Hz, α : 8~13 Hz, β : 14~30 Hz 和 γ : 31~50 Hz) 上计算得到. 因此, 62 导脑电片段的微分熵特征总维数是 310 维. 每一名被试大约有 3300 多脑电样本.

4.3 性能评价指标

这里我们采用留一交叉验证 (leave-one-subject-out cross validation) 方法进行性能评价. 也就是每次将其中一名被试的数据作为测试集 (目标域), 而其他 12 名被试的数据作为训练集 (源域). 对于在本文中指代的 *Generic* 基线方法 (baseline method), 我们将所有可用的被试数据混合一起作为训练数据, 再利用线性支持向量机训练一个通用分类器. 我们也选择了所有可用的被试数据的子集, 这些被试他们与目标被试有着更加相似的扫视轨迹, 这种方法在本文中我们称之为 *GenSub*. 通过交叉验证, 我们发现源域被试中最佳子集数目为 9, 即选取最相似的 9 名被试数据进行迁移.

我们比较了本文提出的被试迁移框架以及现有的只利用脑电数据进行迁移学习的方法. 其中, 迁移成分分析 (Transfer Component Analysis, TCA^[46]) 和核主成分分析 (Kernel Principle Component Analysis, KPCA) 的核心思想是学习一组在源域和目标域中共同的迁移成分, 找到源域和目标域之间一个低维特征子空间. 在这个低维特征子空间中, 两个域之间的特征分布差异性可以被缩小, 同时仍然保持不同类别的判别信息. 它们的目标是在没有任何目标域标签数据的情况下, 找到一个变换函数 $\phi(\cdot)$, 使得 $P(\phi(X_S)) \approx P(\phi(X_T))$ 和 $P(Y_S | \phi(X_S)) \approx P(Y_T | \phi(X_T))$. TCA 和 KPCA 的子空间维数利用交叉验证方法分别调节为 25 和 50, 两种方法都使用线性核进行比较.

进一步, 测地线流式核方法 (Geodesic Flow Kernel, GFK)^[47] 集成了无数个子空间, 这些子空间表征源域和目标域之间几何和统计属性的变化. 基于适配正则化的迁移学习算法 (Adaptation Regularization Based Transfer Learning, ARTL), 同时优化了结构风险函数 (structural risk function), 域之间的联合分布匹配 (joint distribution) 以及流形一致性 (manifold consistency)^[48]. 另外, 我们也引入了经典的核均值匹配算法 (Kernel Mean matching Algorithm, KMM) 作为比较. KMM 算法的思想是估计源域和目标域之间的密度比例. 由于计算存储以及计算时间限制, 对于 TCA 和 KPCA 算法, 我们指定一名被试的数据作为目标域之后, 随机选取其余 12 名被试训练数据的一个样本子集 (5000 个样本) 作为训练集. 之前相关研究^[11] 发现, 对于 TCA 和 KPCA, 模型性能在 5000 个训练样本时基本稳定. 为了与之前研究结果进行比较, 本文采用相同的 TCA 和 KPCA 训练方式. 在本文中, 我们采用一对一策略 (one vs. one) 解决多类别分类器问题.

5 实验结果分析

本节将系统地比较本文所提方法与已有迁移学习方法在脑电情绪识别上的性能. 这里我们采用了留一交叉验证方法.

图 3 展示了不同被试迁移方法的对比结果. 前 9 种方法只利用脑电数据进行被试迁移. 其中, 基线方法, 即利用 SVM 训练通用分类器, 取得了 50.46% 均值和 17.14% 的标准差. KMM 方法由于不能准确地估计源域和目标域之间的密度比例, 在所有方法中性能最差. 根据两两被试之间的时空扫视轨迹比较, 我们能够找到与目标被试相似的扫视轨迹, 再利用源域中这些被试的数据训练迁移模型, 即 *GenSub*. 如何有效地选择正确的源域数据, 从而达到自动的有效知识迁移仍然是一个尚未解决的问题^[49-50].

我们通常有很多潜在的源域数据可供选择, 但如果不能恰当地选取与我们目标域相关的集合, 可能会引起负迁移 (negative transfer). 所谓负迁移, 是指当源域和目标域的任务毫不相关, 这样源域的训练数据不仅没有用, 反而会在目标域上产生适得其反的效果. 这里, 我们探索了通过眼睛的时空扫视轨迹对比来选取潜在的源域数据实现被试迁移. 从实验结果上看, 我们发现 *GenSub* 的检测性能比使用了全部源域数据的 *Generic* 性能要稍微好些. 这

个结果表明,眼睛的扫视轨迹模式能在选取正确的源域数据上提供有效的信息.

从图 3 我们可以看出,TPT、TCA 和 ARTL 方法均能显著提升只使用脑电数据的被试迁移性能.同时 TPT 方法在所有基于脑电的同质迁移模型中表现最好.在 TPT 框架中,基于密度估计的核矩阵以及基于陆地移动距离的核矩阵的平均准确率和标准差分别是 69.85%/11.94%和 70.20%/10.87%.基于陆地移动距离的核矩阵取得了比基于密度估计




图 3 不同的迁移学习方法在脑电情绪识别上的分类准确率(前 9 种方法只使用了脑电数据构建被试迁移模型,DE 和 EMD 分别是采用 DE 核矩阵以及 EMD 核矩阵的 TPT 方法, Scanpath 表示本文提出的基于扫视轨迹核矩阵的改进的 TPT 方法)

的核矩阵稍好的准确率.与通用分类器(50.46%/17.14%)相比,TPT 算法表现出了更好的性能,也证明了不同域(被试)之间进行知识迁移的有效性.

异质迁移模型 Scanpath(如图 3 所示)利用了扫视轨迹提取的异质知识进行被试迁移,达到了可比的 69.72%/12.07% 的分类准确率(平均值/标准差).与传统的通用分类器相比,取得了 19.26% 分类准确率的显著提升(单因素方差分析,one way analysis of variance, $p<0.01$).更重要的是,与以上使用同质迁移学习方法不同的是,我们所提出的异质迁移学习方法在训练过程中,目标域被试不需要采集任何脑电数据.这在许多真实应用场景中非常重要,原因是采集眼动追踪数据比脑电数据更加容易更方便.而由本文提出的方法所构建的跨被试模型仍然能够利用之前的脑电数据的表征特性进行情绪识别.可比的性能表明在基于扫视轨迹的核矩阵迁移方法中,脑电信号对于情绪的判别信息已经迁移到目标被试.这些结果体现了我们所提异质迁移学习方法的优势.而其他传统的只利用脑电特征进行迁移的方法,并没有将情感处理过程中的其他有效信息加以利用.

图 4 展示了在 TPT 框架中用来度量不同被试之间的相似性的核矩阵,包括基于密度估计,基于陆地移动距离以及基于扫视轨迹的核矩阵.核矩阵中较高的数值表示两个被试之间的模式越相似.实验结果表明本文提出的异质迁移学习方法的有效性,它从一个全新的角度充分利用了具有时空特性的眼睛的扫视轨迹,进而实现了异质知识迁移.




图 4 TPT 框架中,基于密度估计、基于陆地移动距离以及基于扫视轨迹的核矩阵
(图中每个方块数值表示两两被试之间数据分布的相似性)

本文提出的框架能够自然地推广到任何利用电影片片段作为刺激素材的情感脑-机接口实验范式中.虽然眼睛的扫视轨迹可能决定于特定的刺激素材以及受到视觉感知处理(比如视觉属性中低层次,自下而上的显著性等)和任务理解(比如场景理解等)的

影响,眼动追踪能够在相同特定刺激中用来量化不同被试个体差异以及帮助解决在系统标定阶段脑电信号的对齐问题.在系统标定阶段,可以采集相同刺激素材下的眼动信号进行模型训练.这样可以减小视觉感知处理和任务理解带来的影响,同时保留情

感相关的眼动信息. 眼睛的扫视轨迹被用于指导在源域被试中迁移什么数据以及如何迁移这些情感信息. 利用眼睛的扫视轨迹进行系统标定后, 可以构建基于脑电的情绪识别模型, 并应用于其他场景.

对于传统情感脑-机接口框架, 标定阶段需要采集大量带有情感标签的脑电数据. 而在我们的框架中, 新被试的标定阶段只需要采集眼动追踪数据, 模型能从其他潜在的源域被试的脑电信号中进行具有情绪判别信息的迁移. 这种方法非常适用于那些便于采集眼动追踪数据的场景, 同时自适应模型仍然能够重复利用以往采集的具有情绪识别表征特性的脑电数据, 充分利用脑电信号在情绪识别任务中具有高区分性的优势.

6 结 论

本文提出了一种新的异质迁移学习方法. 该方法利用具有时空特性的眼睛的扫视轨迹进行异质知识迁移, 从而能够构建个性化的基于脑电的情感模型. 与脑-机接口领域已有的只使用脑电数据的同质迁移学习框架不同, 我们方法的主要创新点是利用眼动追踪数据进行系统标定. 本文系统地比较了所提方法与已有迁移学习方法的性能. 实验结果表明, 本文提出的方法取得了与只使用脑电的同质知识迁移可比的性能, 同时由于目标域被试在训练阶段不需要采集任何脑电数据, 缩短了目标域被试的系统标定时间, 有利于多模态情感脑-机接口的实用化和扩大多模态情感脑机接口的应用范围.

参 考 文 献

- [1] Muhl C, Allison B, Nijholt A, Chanel G. A survey of affective brain computer interfaces: Principles, state-of-the-art, and challenges. *Brain-Computer Interfaces*, 2014, 1(2): 66-84
- [2] Widge A S, Dougherty D D, Moritz C T. Affective brain-computer interfaces as enabling technology for responsive psychiatric stimulation. *Brain-Computer Interfaces*, 2014, 1(2): 126-136
- [3] Alghowinem S, Goecke R, Wagner M, et al. Multimodal depression detection: Fusion analysis of paralinguistic, head pose and eye gaze behaviors. *IEEE Transactions on Affective Computing*, 2016, 9(4): 478-490
- [4] Sani O G, Yang Y, Lee M B, et al. Mood variations decoded from multi-site intracranial human brain activity. *Nature Biotechnology*, 2018, 36(10): 954
- [5] Lu Y, Zheng W L, Li B, Lu B L. Combining eye movements and EEG to enhance emotion recognition//*Proceedings of the 24th International Joint Conference on Artificial Intelligence*. Buenos Aires, Argentina, 2015, 15: 1170-1176
- [6] Zheng W L, Liu W, Lu Y, et al. EmotionMeter: A multi-modal framework for recognizing human emotions. *IEEE Transactions on Cybernetics*, 2018, 49(3): 1110-1122
- [7] Soleymani M, Pantic M, Pun T. Multimodal emotion recognition in response to videos. *IEEE Transactions on Affective Computing*, 2012, 3(2): 211-223
- [8] Zheng W L, Dong B N, Lu B L. Multimodal emotion recognition using EEG and eye tracking data//*Proceedings of the 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*. Chicago, USA, 2014: 5040-5043
- [9] Pan S J, Yang Q. A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 2010, 22(10): 1345-1359
- [10] Morioka H, Kanemura A, Hirayama J I, et al. Learning a common dictionary for subject-transfer decoding with resting calibration. *NeuroImage*, 2015, 111: 167-178
- [11] Zheng W L, Lu B L. Personalizing EEG-based affective models with transfer learning//*Proceedings of the 25th International Joint Conference on Artificial Intelligence*. New York, USA, 2016: 2732-2738
- [12] Jayaram V, Alamgir M, Altun Y, et al. Transfer learning in brain-computer interfaces. *IEEE Computational Intelligence Magazine*, 2016, 11(1): 20-31
- [13] Calvo R A, D'Mello S. Affect detection: An interdisciplinary review of models, methods, and their applications. *IEEE Transactions on Affective Computing*, 2010, 1(1): 18-37
- [14] Alagarai S H, Indurkha B, Lee E, Bae Y. Towards multi-modal affective feedback: Interaction between visual and haptic modalities//*Proceedings of the 33rd Annual ACM Conference on Human Factors in Computing Systems*. Seoul, Korea, 2015: 2043-2052
- [15] Nasoz F, Lisetti C L, Vasilakos A V. Affectively intelligent and adaptive car interfaces. *Information Sciences*, 2010, 180(20): 3817-3836
- [16] Zhao M, Adib F, Katabi D. Emotion recognition using wireless signals//*Proceedings of the 22nd Annual International Conference on Mobile Computing and Networking*. New York, USA, 2016: 95-108
- [17] Kragel P A, LaBar K S. Advancing emotion theory with multivariate pattern classification. *Emotion Review*, 2014, 6(2): 160-174
- [18] Saarimaki H, Gotsopoulos A, Jaaskelainen I P, et al. Discrete neural signatures of basic emotions. *Cerebral Cortex*, 2015, 26(6): 2563-2573
- [19] Schirmer A, Adolphs R. Emotion perception from face, voice, and touch: Comparisons and convergence. *Trends in Cognitive Sciences*, 2017, 21(3): 216-228
- [20] Schaefer A, Nils F, Sanchez X, Philippot P. Assessing the effectiveness of a large database of emotion-eliciting films: A new tool for emotion researchers. *Cognition and Emotion*, 2010, 24(7): 1153-1172

- [21] Koelstra S, Muhl C, Soleymani M, et al. Deap: A database for emotion analysis using physiological signals. *IEEE Transactions on Affective Computing*, 2012, 3(1): 18-31
- [22] Chen T, Helminen T M, Hietanen J K. Affect in the eyes: Explicit and implicit evaluations. *Cognition and Emotion*, 2017, 31(6): 1070-1082
- [23] Shi Z F, Zhou C, Zheng W L, Lu B L. Attention evaluation with eye tracking glasses for EEG-based emotion recognition// *Proceedings of the 8th International IEEE/EMBS Conference on Neural Engineering*. Shanghai, China, 2017: 86-89
- [24] Du C, Du C, Wang H, et al. Semi-supervised deep generative modelling of incomplete multi-modality emotional data// *Proceedings of ACM Multimedia Conference on Multimedia*. New York, USA, 2018: 108-116
- [25] Qiu J L, Liu W, Lu B L. Multi-view emotion recognition using deep canonical correlation analysis// *Proceedings of the International Conference on Neural Information Processing*. Siem Reap, Cambodia, 2018: 221-231
- [26] Krauledat M, Tangermann M, Blankertz B, Müller K R. Towards zero training for brain-computer interfacing. *PLOS One*, 2008, 3(8): e2967
- [27] Zhou J T, Pan S J, Tsang I W, Yan Y. Hybrid heterogeneous transfer learning through deep learning// *Proceedings of the 28th AAAI Conference on Artificial Intelligence*. Québec City, Québec, Canada, 2014: 2213-2220
- [28] Eckstein M K, Guerra-Carrillo B, Singley A T M, Bunge S A. Beyond eye gaze: What else can eyetracking reveal about cognition and cognitive development? *Developmental Cognitive Neuroscience*, 2017, 25: 69-91
- [29] Costa V D, Rudebeck P H. More than meets the eye: The relationship between pupil size and locus coeruleus activity. *Neuron*, 2016, 89(1): 8-10
- [30] Rajkowski J. Correlations between locus coeruleus (LC) neural activity, pupil diameter and behavior in monkey support a role of LC in attention// *Proceedings of Society for Neuroscience Abstract*. Washington, USA, 1993: 974
- [31] Joshi S, Li Y, Kalwani R M, Gold J I. Relationships between pupil diameter and neuronal activity in the locus coeruleus, colliculi, and cingulate cortex. *Neuron*, 2016, 89(1): 221-234
- [32] Pierrot-Deseilligny C H, Ploner C J, Müri R M, et al. Effects of cortical lesions on saccadic eye movements in humans. *Annals of the New York Academy of Sciences*, 2002, 956(1): 216-229
- [33] Sparks D L. The brainstem control of saccadic eye movements. *Nature Reviews Neuroscience*, 2002, 3(12): 952
- [34] Munoz D P, Everling S. Look away: The anti-saccade task and the voluntary control of eye movement. *Nature Reviews Neuroscience*, 2004, 5(3): 218
- [35] Righart R, De Gelder B. Rapid influence of emotional scenes on encoding of facial expressions: An ERP study. *Social Cognitive and Affective Neuroscience*, 2008, 3(3): 270-278
- [36] Noh S R, Isaacowitz D M. Emotional faces in context: Age differences in recognition accuracy and scanning patterns. *Emotion*, 2013, 13(2): 238
- [37] Dowling J E. *Neurons and Networks: An Introduction to Behavioral Neuroscience*. Second Edition. Cambridge, USA: Harvard University Press, 2001
- [38] Cristino F, Mathot S, Theeuwes J, Gilchrist I D. ScanMatch: A novel method for comparing fixation sequences. *Behavior Research Methods*, 2010, 42(3): 692-700
- [39] Salvador S, Chan P. Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis*, 2007, 11(5): 561-580
- [40] Sangineto E, Zen G, Ricci E, Sebe N. We are not all equal: Personalizing models for facial expression analysis with transductive parameter transfer// *Proceedings of the 22nd ACM International Conference on Multimedia*. New York, USA, 2014: 357-366
- [41] Blanchard G, Lee G, Scott C. Generalizing from several related classification tasks to a new unlabeled sample// *Proceedings of the Advances in Neural Information Processing Systems*. Granada, Spain, 2011: 2178-2186
- [42] Ricci E, Zen G, Sebe N, Messelodi S. A prototype learning framework using EMD: Application to complex scenes analysis. *IEEE Transactions Pattern Analysis and Machine Intelligence*, 2013, 35(3): 513-526
- [43] Tuia D, Verrelst J, Alonso L, et al. Multioutput support vector regression for remote sensing biophysical parameter estimation. *IEEE Geoscience and Remote Sensing Letters*, 2011, 8(4): 804-808
- [44] Duan R N, Zhu J Y, Lu B L. Differential entropy feature for EEG-based emotion classification// *Proceedings of the 6th International IEEE/EMBS Conference on Neural Engineering*. San Diego, USA, 2013: 81-84
- [45] Zheng W L, Lu B L. Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development*, 2015, 7(3): 162-175
- [46] Pan S J, Tsang I W, Kwok J T, Yang Q. Domain adaptation via transfer component analysis. *IEEE Transactions on Neural Networks*, 2011, 22(2): 199-210
- [47] Gong B, Shi Y, Sha F, Grauman K. Geodesic flow kernel for unsupervised domain adaptation// *Proceedings of the Computer Vision and Pattern Recognition*. Providence, USA, 2012: 2066-2073
- [48] Long M, Wang J, Ding G, et al. Adaptation regularization: A general framework for transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 2014, 26(5): 1076-1089
- [49] Xiang E W, Pan S J, Pan W. Source-selection-free transfer learning// *Proceedings of the International Joint Conference on Artificial Intelligence*. Barcelona, Spain, 2011, 22(3): 2355
- [50] Chu W S, De la Torre F, Cohn J F. Selective transfer machine for personalized facial action unit detection// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Portland, USA, 2013: 3515-3522



ZHENG Wei-Long, Ph.D. His research interests focus on affective computing, brain-computer interaction, machine learning.

SHI Zhen-Feng, M. S. His research interests focus on brain-computer interaction.

LU Bao-Liang, Ph.D., professor. His research interests include neural network, machine learning, brain-computer interaction, and affective computing.

Background

Affective brain-computer interfaces (aBCIs) have received considerable attention in recent years due to their assessment of users affective states from brain signals. In particular, it provides a quantitative evaluation for enhancing human-computer interactions and treating psychiatric diseases. However, building a robust affective brain-computer interface is still challenging and the existing frameworks for aBCIs require a time-consuming training phase to calibrate, which limits their generalization in real-world applications. An intuitive approach is to recycle previously recorded electroencephalography (EEG) data across sessions and subjects and train a generic classifier without taking individual differences into account. Unfortunately, the performance of generic classifiers is dramatically degraded for new subjects due to many factors such as non-stationary nature of EEG, large variations between subjects and changing environments.

Many research groups have introduced various transfer learning or domain adaptation techniques to help reduce calibration time and tackle the differences across sessions and subjects. While the detailed implementations vary, most of the existing methods considered transfer information solely from EEG features. It is still necessary for users to acquire a moderately large amount of unlabeled EEG data from target subjects. Moreover, most current transfer learning methods focus on homogeneous knowledge transfer, which means data from source domain and target domain are from the same modality. In contrast, heterogeneous transfer learning aims

to transfer knowledge across different modalities. How to efficiently extract heterogeneous knowledge from different types of sources is still challenging.

The goal of transfer learning is to reduce the calibration time in aBCIs. However, sometimes even collecting the unlabeled EEG is still annoying, time consuming, and higher cost. In contrast, it is attracting for new subjects to wear an eye tracking glasses for recording eye movements and improve the performance of affective models by reusing previous EEG from other subjects. EEG and eye movements have complementary information for affective sensing in terms of neuro-physiological and behavioral changes, respectively. Transferring affective knowledge from eye movements to EEG helps reduce calibration costs and obtain high recognition performance across subjects.

In this paper, we have proposed a novel subject transfer approach by leveraging the heterogeneous knowledge from spatiotemporal scanpath patterns for building personalized EEG-based affective models. We have compared our proposed approach with the state-of-the-art methods, which has achieved comparable performance with the homogeneous knowledge transfer while reducing much calibration time without requiring to acquire EEG.

This work was supported in part by the National Key Research and Development Program of China under Grant 2017YFB1002501, in part by the National Natural Science Foundation of China under Grant 61673266.