

预动环境中基于协同信任的表情分析*

徐超⁺, 冯志勇, 王家昉

(天津大学 计算机科学与技术学院, 天津 300072)

Facial Expression Analysis Based on Synergetic Trust Model in Proactive Environment

XU Chao⁺, FENG Zhi-Yong, WANG Jia-Fang

(School of Computer Science and Technology, Tianjin University, Tianjin 300072, China)

+ Corresponding author: E-mail: chaoxu@tju.edu.cn

Xu C, Feng ZY, Wang JF. Facial expression analysis based on synergetic trust model in proactive environment. Journal of Software, 2012, 23(1): 21-31. <http://www.jos.org.cn/1000-9825/3981.htm>

Abstract: With the rapid development of affective computing and facial expression analysis, it is important to understand trusted facial expressions during human-computer interaction. This paper presents a novel approach for synergetic trust analysis of facial expression. Based on the cooperative mechanism between facial expression features and affective trust evidences, the synergy theory is applied to extend the evidences and to achieve the reasoning algorithm in a proactive environment. The resultant model from cooperative interaction and synergetic dependence evaluation is potentially capable of analyzing the trusted facial expression. Experiments have been conducted to evaluate the rationality of the approach. It is suggested that synergetic trust model can reduce the subjective impacts of overall analysis and perform at a higher credibility can allow the user to further comprehend affective computing with trust factors.

Key words: affective computing; facial expression feature; synergetic trust; affective feature evidence; proactive environment

摘要: 面向情感计算的面部表情研究得到快速发展,人机交互中得到表情的可信分析成为研究热点.提出预动环境中协同依赖的表情分析模型,设计协同信任算法,实现对表情的可信分析.首先,根据个体的表情结构与特征证据的关系提出预动环境中可协同交互的表情分析模型;然后,引入协同理论扩展特征证据,设计协同依赖的可信表情模型,阐述表情特征的证据推理算法;最后,通过实验验证协同信任模型对表情的实时可信分析,降低了分析模型主观因素对可信结果的影响.该研究有助于更好地认识信任因素对情感计算的影响.

关键词: 情感计算;表情特征;协同信任;情感证据;预动环境

中图法分类号: TP18 **文献标识码:** A

随着人工智能、机器视觉、模式识别等技术的快速发展,人们越来越多地依赖于人机交互技术,尤其是在

* 基金项目: 国家高技术研究发展计划(863)(2007AA01Z130)

收稿时间: 2009-07-06; 修改时间: 2010-04-22; 定稿时间: 2010-12-15

CNKI 网络优先出版: 2011-05-12 11:47, <http://www.cnki.net/kcms/detail/11.2560.TP.20110512.1147.004.html>

健康医疗领域,智能识别和分析得到了广泛应用^[1-4],为社会生活提供了极大便利.可穿戴的感知设备结合预动计算(proactive computing)^[5]技术,可以更加便捷地探测和获取用户的身体特征信息,同时还能减少对个体的干扰^[6].

预动计算以用户为中心,利用智能模型分析用户体征的日常状态信息^[7,8].21 世纪初,欧洲国家有研究者提出将预动计算应用到健康医疗服务^[9,10].例如,ProHeMon(proactive health monitoring)^[11]项目建立预动环境进行健康监测,以有效提高医疗服务的实时性和可预防性.虽然预动环境中的感知技术^[12]加强了对用户身体特征信号探测和收集的准确性,但是计算环境中大量未必可信的数据采集,对智能分析和决策也会造成错误的指导并产生扰乱影响.

可见,采集数据的分析应该涉及对信息可信度的建模和推理,增加预动环境中智能模型间的协作交互机制,提高模型间信息和知识交换的自适应性,以最小的干预代价实现可信的信息感知和预动计算.由于穿戴式感知属于接触式测量,会引起用户主观上改变身体特征的表达,因此本文将非接触式感知的面部表情数据作为身体信号的特征证据,并成为可信计算的基本证据元素^[13].

预动环境中,对用户面部表情的识别分析和预测推理属于非确定性计算,应用可信计算对分析结果进行评价和决策是必要且有效的,进而降低了用户的隐藏表情对预动行为的干扰和影响.基于上述分析,我们在预动环境中提出应用协同信任模型进行面部表情特征分析的可信计算框架,引入协同学原理^[14,15]扩展证据理论^[16,17]和快速信任模型^[13].利用面部表情结构和特征证据的关系建立信任的推理机制,结合模型间协同依赖扩展的证据理论完成信任的量化,实现可信计算模型.

本文在预动环境中建立个体表情分析模型,给出模型间的协同交互机制,应用协同依赖的证据模型描述与可信表情推理相关的证据类型、元素关系、推理目标等,以表情特征作为证据输入元素,应用协同信任模型计算表情的分析可信度和推理结果.由此,在可信计算的层次上对表情分析进行预动决策.

本文首先介绍预动环境中个体表情分析模型及其协同交互原理;其次,基于证据理论构建协同信任的分析模型;再次,详细阐述基于特征证据的可信推理算法;最后,模拟预动环境设计协同依赖的可信表情分析实验并给出结论.

1 预动环境中表情分析模型及协同机制

个体的面部表情表达呈现多样性的特点,因此应对不同的个体建立个性化的分析模型.本节提出个体表情分析模型,给出预动环境中模型间的协同交互机制,论述个体模型间进行协同学习和实现表情认知的框架和机理.

首先给出面部表情的情感特征定义.情感偏重于长期效应,而情绪注重的是短期效应.在预动环境中,交互智能体(或模型)在理想状态下有类似于人的观察、理解和生成各种情感特征的能力,并能像人一样进行自然、和谐的交互.基于上述思想,将面部表情的情感特征定义为:交互智能体通过观察个体的面部表情,判断其内在情感感受的反应和反馈.由于表情的情感特征通常会以社会期望的方式进行表达和接受反馈,所以社会期望赋予智能体的规范是个体分析模型的内在基础,也是可信推理被引入计算模型的社会意义.

其次,对预动环境中的个体抽离出相似的情感特征,提出个性化表情特征模型.个体感知所处环境的信息,通过反复试错,逐渐给出对环境刺激的合理体验和反馈,完善面部表情的表达方式并符合社会规范的要求.个体对情感特征的表达方式是相似的,但是构成情感的内在要素略有不同,包括人格、身份、社会地位以及个人在环境中的权力和权威等^[18].可见,表情的情感特征表达是建立在个体内在与外在互动的基础之上的,是在个体交互过程中体现出来情感特征的具体而协调的表达方式,是实现可信表情分析的基础.

图 1 描述的是个体表情分析模型的框架设计.预动环境提供数据测量和传输设备,组成感知接口.表情的特征信号通过感知接口采集后,由认知接口进行分析,建立表情的情感特征库.同时,将识别的表情状态传递给情感特征体验接口进行基于特征证据的可信计算,分析用户当前的表情表达是否隐藏了情感特征.根据定量的可信分析结果,通过反馈接口进行有效调整,以达到社会期望赋予个体在表达情感时的表情特征约束.

面部表情特征经过认知接口的识别分析,给出个体的表情状态分布,找出情感特征表达和内在个体特征之间的差异和联系.研究发现,与情感特征表达有关的思维和行为因素包括:自身动机、情感共鸣、自我意识、冲动控制、坚持不懈和社交手段等^[18].认知过程仿照人类思维的理想过程,采取反复试错的方式,实现“感知→推理→反馈”的循环迭代.

不同个体表达相同情感的方式是相似的,但是面部表达在特征细节上有个性化差异,因为情感特征表达依赖于个体内在的体验交换和反馈联系^[19,20].对于环境中的个体而言,超出社会期望赋予的情感特征表达被视为隐藏情感特征,现有的认知接口中很难分析出此类特征.认知接口计算出表情特征的识别结果,建立情感特征库,通过分析得出用户的表情情感体验,即个体表达情感特征时的外在表述.根据情感体验结果对个体表情的特征表达进行实时反馈,找到循环认知中的平衡.

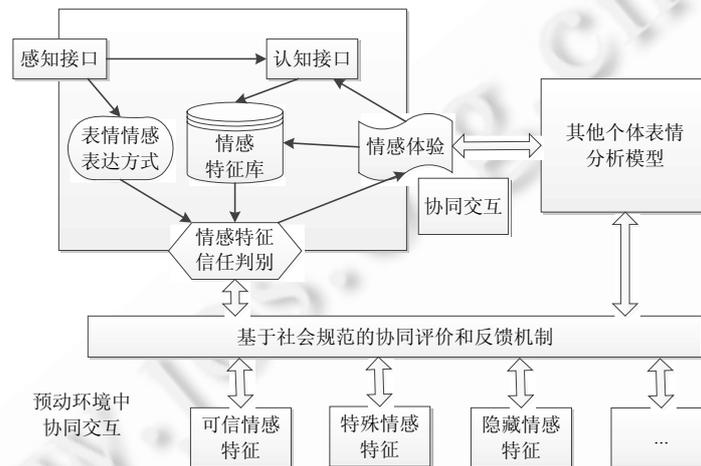


Fig.1 Framework of affective facial feature and cooperative interaction in proactive environment

图 1 预动环境中表情情感特征的分析框架及协同交互

在预动环境中,应用协同机制实现不同个体模型间情感特征体验的交互学习.环境中的个体在表达自身表情特征时基于相似的情感特征,如果抽离这些表达方式,即构成抽象的元模型.在此基础上,个体模型间彼此交互,建立模型间的自适应学习机制.即模型间进行协同证据交互的基础,也是协同信任计算的基本框架.图 1 中个体模型均使用相同的社会规范评价机制作为模型间实现协同学习的基础,展示了模型间正方向上的相互依赖关系.模型的协同学习依赖于预动环境中其他的个体模型,而模型之间不存在竞争关系.通过协同交互,个体模型学习其他模型所分析用户在表达表情特征时的情感体验分布特点,以此指导模型本身完成更符合社会规范的情感特征推理,即协同依赖的可信表情分析.

2 表情情感特征的可信模型分析

应用预动环境中,个体表情分析框架和模型间的协同交互机制,获取表情特征并建立情感特征库,给出相应的情感体验.在此基础上,将个体模型分析的表情特征定义为情感特征证据,设计协同信任的情感特征分析接口.该接口在快速信任模型^[13]的基础上,结合预动环境中模型间交互,实现协同依赖的可信表情分析模型.

从认知的角度来看,表情特征的可信计算有助于研究者定性和定量地找出情感特征在表达过程中出现的不一致现象,这种隐藏情感特征的表达称为情感表述的信息不对称.预动环境中,个体表情分析模型的协同交互是虚拟的临时系统,由于缺乏产生交互经验的客观因素,协同的基础仅为表情的情感特征状态、情感特征表达以及分析得出的情感特征体验,将此 3 类元素定义为协同信任的情感特征证据,由此得到的可信分析称为协同依赖信任.

表情的情感特征证据是证据理论^[16,17]的扩展,其协同信任分析依赖于模型间交互,基于可信度函数和似真度函数的推理通过概率形式量化可信度.通过组合不同的证据元素信息(如情感特征状态、情感特征表达和情感特征体验等),计算表情分析结果的可信度.虽然可信分析是不确定性的计算,但是在计算模型中加入了客观的证据信息,由此做出的信任决策是相对可信的^[21].根据上述描述,协同信任接口是结合情感特征分类迭代计算信任的模型,基于层次分析和整合推理的框架结构,用以分析个性化情感特征模型中用户表达的面部表情是否为真实的情感体验,或表情的表达是否可信.

图 2 是协同信任接口的设计描述.基于个体表情分析模型,该接口从模型中得到所需要的协同证据参数,结合模型在预动环境中通过协同交互得到的证据信息,应用基于证据的信任推理方法,计算出情感特征结果的可信度.通过反馈机制对个体模型中的情感特征体验做出调整,以此降低由隐藏情感的信息不对称而产生的对面部特征分析所造成的影响.

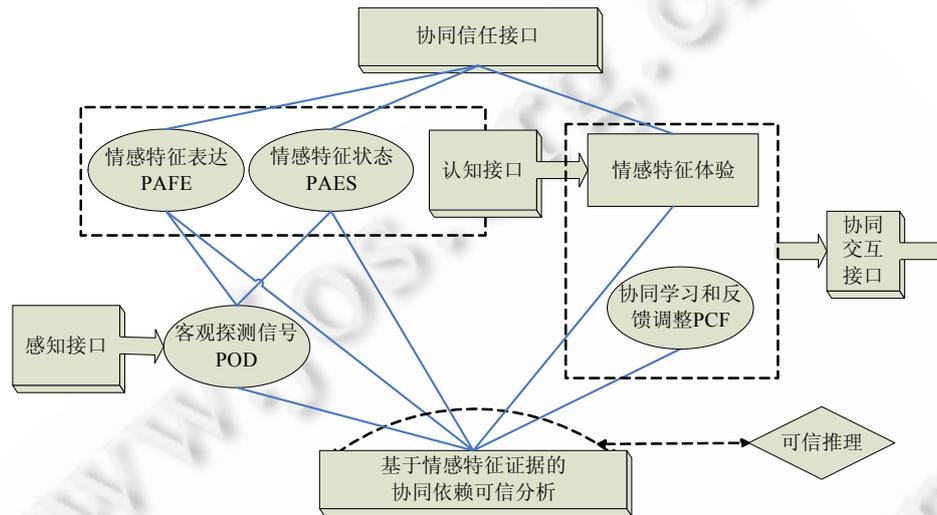


Fig.2 Synergetic trust interface based on affective feature evidence

图 2 基于情感特征证据的协同信任接口

情感特征证据是协同信任接口的主要参数,包括 3 类基本元素:感知信号、情感特征体验和协同交互.感知信号是对环境客观信息的探测 POD(parameters of objective detection);情感特征体验包括情感特征表达 PAFE(parameters of affective feature expression)和情感特征状态 PAES(parameters of affective emotion state)描述;协同交互主要是协同学习和反馈调整 PCF(parameters of cooperation and feedback).定义情感特征参数集合:

$$P = \{PAFE, PAES, PCF, POD\}.$$

参数集合的基本元素在可信计算中普遍存在着不确定性,对情感特征内在意义的理解往往与研究人员的判断有所差异.通常意义上,基于上述参数计算得到的信任度量需要预先给出元素信息在概率上的区间假定或线索,并在区间范围内计算表情的特征证据值.

对参数集合中输入的元素证据信息给出预先定义的因素区间 $[\text{MinSubV}(P_i), \text{MaxSubV}(P_i)] (P_i \in P)$,其中, MinSubV (minimal subjective value)为主观上认为该因素的最小可信概率, MaxSubV (maximal subjective value)为主观上认为最大的可信概率.上述证据因素可以由研究人员根据经验假设出一组区间作为初始范围,个体模型在协同交互的过程中将进行自适应的学习和调整,得到平衡的置信区间.

在证据因素的范围区间中,结合协同信任定义主观的情感特征证据置信区间 $[AFE]$ (affective feature evidence),如公式(1)所示:

$$[AFE] = [\text{MinSubV}(P), \text{MaxSubV}(P)] \quad (1)$$

其中, $MinSubV$ 和 $MaxSubV$ 是模型主观上的协同信任证据元素的置信区间上下界.下面对证据因素进行客观计算,并对上述置信区间进行调整.定义 $MinObjT$ (minimal objective transaction)和 $MaxObjT$ (maximal objective transaction)为根据证据因素客观计算协同信任置信区间的下界和上界,描述为

$$MinObjT(\{P\}) = \min \bigcap_i \{ObjTV(P_i)\} \quad (2)$$

$$MaxObjT(\{P\}) = \max \bigcup_i \{ObjTV(P_i)\} \quad (3)$$

其中, $ObjTV$ (objective transaction value)是分析模型根据客观证据因素推理和预测的信任值,例如 PCF 和 POD .而 $PAFE$ 和 $PAES$ 作为证据因素的信任值应该由 $SubV$ 计算得到.对于 $[AFE]$ 的调整如下:

$$[AFE] = [MinObjTV(\{P\}), MaxObjTV(\{P\})] \quad (4)$$

$$MinObjTV(\{P\}) = \min \bigcap_i \{ObjTV(P_i), MinSubV(\{P\})\} \quad (5)$$

$$MaxObjTV(\{P\}) = \max \bigcup_i \{ObjTV(P_i), MaxSubV(\{P\})\} \quad (6)$$

根据上述公式,利用反馈机制调整协同信任的情感特征证据区间.预动环境中的个体分析模型在交互中存在不确定性,基于证据交互的可信计算对实时的情感特征分析进行辅助验证,确定模型分析结果的可信程度,并通过协同学习完成基于社会规范的反馈调整.在信任计算接口中,个性化表情的情感特征分析模型实时地报告用户情感特征状态、情感特征表达的可信度以及情感体验的合理性,找出用户面部表情的隐藏情感特征.

3 基于特征证据的可信推理描述

在协同信任接口的基础上,设计面部表情特征证据的可信推理方法,结合文献[13]详细阐述个体分析模型的协同信任算法.首先,根据情感特征参数集合 $P = \{PAFE, PAES, PCF, POD\}$ 计算出面部表情的情感特征证据集合 $AFE = \{EFS(\text{emotion feature state, 情感特征状态}), EFE(\text{emotion feature expression, 情感特征表达}), AE(\text{affective experience, 情感体验})\}$.

情感特征的可信计算结果对应于 AFE 的一个子集.对上述证据集合加以分析,得出理论特征证据对于真实情感特征是否可信的分析结果.即,面部表情以多大概率可信,称为主观可信度 SB (subjective belief).

定义 AFE 上的基本可信度分配函数 $t: 2^{AFE} \rightarrow [0, 1]$ (2^{AFE} 为 AFE 的幂集), $\forall A \subset AFE, t(A)$ 称为 A 的可信度分配或基本可信函数,反映对 A 本身的可信估计.由此给出 AFE 上的主观可信度函数为

$$SB(A) = \sum_{B \subset A} t(B), \forall A \subset AFE \quad (7)$$

主观可信度函数 SB 反映了分析模型主观上对 A 的可信程度,但不能反映怀疑 A 的程度.为了全面描述对 A 的信任计算,还需引入怀疑 A 的可信分析方法——似真度函数 pl (plausible),其定义为

$$pl(A) = 1 - SB(\neg A), \forall A \subset AFE \quad (8)$$

其中, $pl(A)$ 表示信任 A 或 A 可能为真的程度.由定义可知, $SB(A)$ 是比 $pl(A)$ 更保守的一类估计方法,通常把 $[SB(A), pl(A)]$ 或 $[pl(A), SB(A)]$ 定义为对某一情感特征 A 进行可信分析的估计区间.

预动环境中,个体模型通过协同交互实现对情感特征证据的信息交换和协同估计,下面给出协同依赖 CSD (cooperative synergetic dependence)程度的区间估计表示.设 $CSD\{D, \neg D\}$ 是定义在 AFE 上的协同依赖集合,其可信度分配 $t_{XY}: 2^{CSD} \rightarrow [0, 1]$ 表示为

$$\sum_{A \in 2^{CSD}} t_{XY}(A) = t_{XY}(\{D\}) + t_{XY}(\{\neg D\}) + t_{XY}(\{D, \neg D\}) = 1 \quad (9)$$

其中,可信度分配 t_{XY} 表示个体分析模型 X 对个体模型 Y 的可信程度估计.在此基础上,定义协同依赖的可信度区间上下界,包含协同依赖程度和似真程度的约束.根据 t_{XY} 计算协同依赖函数和似真度函数如下:

协同依赖函数 $Dep_{XY}: 2^{CSD} \rightarrow [0, 1]$, 有

$$Dep_{XY}(\{D\}) = \sum_{A \in \{D\}} t_{XY}(A) = t_{XY}(\{D\}) \quad (10)$$

其中, A 表示个体表情分析模型与协同依赖相关的可信分析集合; $Dep_{XY}(\{D\})$ 表示个体分析模型 X 依赖模型 Y 的程度,依赖集合 $\{D\}$ 表示模型 X 依赖于模型 Y .

似真度函数 $Pl_{XY}:2^{CSD} \rightarrow [0,1]$,有

$$Pl_{XY}(\{D\})=t_{XY}(\{D\})+t_{XY}(\{D,-D\})=1-Dep_{XY}(\{-D\}) \quad (11)$$

其中, $Pl_{XY}(\{D\})$ 表示模型 X 依赖于模型 Y 的最大程度.

根据协同依赖程度和似真程度得出协同依赖区间 $[Dep_{XY}(\{D\}), Pl_{XY}(\{D\})]$, 其中, $Dep_{XY}(\{D\})$ 和 $Pl_{XY}(\{D\})$ 分别表示个体模型 Y 对模型 X 依赖程度的最小值和最大值.

针对面部表情不同情感特征证据的组合问题,给出证据融合的传递和聚合推理方法,其基础是协同过程中的协同依赖函数和似真度函数.在预动环境中,如果两个分析模型不是直接交互的,则需要根据第三方的个体模型证据来推断协同依赖程度,即协同依赖的传递机制.

假定模型 X 对模型 Y 的协同依赖区间是 $[Dep_{XY}(\{D\}), Pl_{XY}(\{D\})]$, 而模型 Y 对模型 Z 的协同依赖区间为 $[Dep_{YZ}(\{D\}), Pl_{YZ}(\{D\})]$, 根据概率的乘法法则有:

$$t_{XZ}(\{D\})=t_{XY}(\{D\}) \cdot t_{YZ}(\{D\}) \quad (12)$$

$$Dep_{XZ}(\{D\})=Dep_{XY}(\{D\}) \cdot Dep_{YZ}(\{D\}) \quad (13)$$

$$Pl_{XZ}(\{D\})=1-Dep_{XZ}(\{-D\})=Pl_{XY}(\{D\})+Pl_{YZ}(\{D\})-Pl_{XY}(\{D\}) \cdot Pl_{YZ}(\{D\}) \quad (14)$$

同时,有如下不等式成立:

$$Dep_{XZ}(\{D\}) \leq \min\{Dep_{XY}(\{D\}), Dep_{YZ}(\{D\})\} \quad (15)$$

$$Pl_{XZ}(\{D\}) \geq \max\{Pl_{XY}(\{D\}), Pl_{YZ}(\{D\})\} \quad (16)$$

协同依赖的聚合推导用于组合多个可信度分配函数表示的协同依赖函数.在避免证据冲突的前提下,应用正交化因子找出证据之间的一致性.

假设个体分析模型 X 和个体模型 Y 之间存在 n 个协同依赖的情感特征证据,则有 n 个相互依赖子区间 $[Dep_{X_i}(\{D\}), Pl_{X_i}(\{D\})]$, $i \in [1, n]$ 存在.那么模型 X 对模型 Y 的依赖程度总区间为 $[Dep_{XY}(\{D\}), Pl_{XY}(\{D\})]$, 则有:

$$t_{XY} = \bigoplus_i t_i (i=1, 2, \dots, n) \quad (17)$$

$$t_{XY}(A) = K \sum_{\bigcap_{A_i=A} 1 \leq i \leq n} \prod t_i(A_i), A \subseteq 2^{CSD} \quad (18)$$

其中, \bigoplus 表示计算直和, $K = \left[\sum_{\bigcap_{A_i \neq \emptyset} 1 \leq i \leq n} \prod t_i(A_i) \right]^{-1}$ 是正交化因子.我们有下面的一般表达式:

$$K_n^{-1} = 1 + (-1)^n \sum_{i=1}^{n-1} \left(\prod_{i=1}^n Dep(\{D\})_{i_s} \right) + (-1)^{n-s+1} \sum_{s=1}^{n-1} \left(\prod_{i=1}^n Pl(\{D\})_{i_s} \cdot \prod_{k_s}^{n-s} Dep(\{D\})_{k_s} \right) \quad (19)$$

似真度和协同依赖度量的一般形式如下所示:

$$Pl(\{D\})_{XYn} = K_n \prod_i Pl(\{D\})_i \quad (20)$$

$$Dep(\{D\})_{XYn} = K_n \cdot \left[(-1)^{s-1} \sum_{s=1}^{n-1} \left(\prod_{i=1}^n Dep(\{D\})_{i_s} \cdot \prod_{j_s}^{n-s} Pl(\{D\})_{j_s} \right) + (-1)^{n-1} \prod_{i=1}^n Dep(\{D\})_i \right] \quad (21)$$

在协同依赖的可信算法中,协同依赖 CSD 是不确定性影响因子.根据 CSD 的协同依赖证据计算表情特征的可信度,通过加权平均的方式定义协同信任函数 CT(cooperative trust):

$$CT = \sum_i \omega_i \cdot f(CSD_i) \quad (22)$$

其中, CSD_i 是当前个体分析模型与第 i 个模型进行交互的协同依赖程度; ω_i 是因式 $f(CSD_i) \in [0,1]$ 的权重,其取值由协同信任的评价者根据经验给出. $f(CSD_i)$ 是关于协同依赖程度的函数,表示根据协同依赖程度 CSD_i 计算出的信任值,用衰减函数表示为 $f(CSD_i) = e^{-|1/2-CSD_i|}$, 则 $CT = \sum_i \omega_i \cdot e^{-|1/2-CSD_i|}$.

基于上述分析,预动环境中个体表情分析模型的协同依赖计算还需要考虑初始信任 T_0 的选取和信任值的变化趋势.协同交互的特征证据模型需要在个体模型间设定初始信任 T_0 ,选择正弦曲线模拟协同信任值的变化趋势,则交互模型的协同信任计算表达式为

$$CT = \sin\left(\pi/2 \cdot CT_0 \cdot \left(1 + \sum_i CT_i - CT_0\right)\right) \quad (23)$$

信任计算本身是不确定性分析,但计算模型中的不确定性被表情的情感特征证据所支持,用协同依赖可信度区间的形式进行描述,克服了表情信息不对称给协同信任计算所带来的影响。

4 协同信任的表情分析实验

模拟预动环境,我们设计了可信表情的分析实验.应用可编程摄像头实时采集用户的面部表情数据,如图 3(a)所示.以摄像头为单位建立个体表情分析模型,使用 Haar-Like^[22]方法提取面部特征,如图 3(b)所示.通过网络将采集数据传输给计算平台,实现模型间的协同交互和自适应学习.个体模型使用动态聚类分析对面部特征进行识别分析,给出基本的情感特征状态;根据用户面部表情特征的表达方式给出情感特征的体验值,作为个体模型进行协同交互的情感特征证据;通过构建实验平台完成情感特征证据的协同依赖计算。



Fig.3 Programmable camera and facial feature extraction

图 3 可编程摄像头与面部特征提取

个体分析模型对用户进行实时的可信表情分析,通过与预动环境中其他个体模型进行交互,完成协同信任计算并反馈调整自身的表情特征库,实现协同交互的自适应学习.根据实验流程和描述,模拟预动环境中可交互的个体模型.如图 4 所示的个体模型运行于 IBM X60 的 Windows 7 平台:个体模型通过 TCP/IP 和可编程摄像头进行表情数据通信,完成模型间协同交互;数据分析引擎借助 Matlab2010a 进行特征证据处理和可信分析计算.考虑到实时性的要求,个体模型通过摄像头采集 30 万像素的面部特征数据。

图 4 展示的是可协同交互的个体表情分析模型控制台:左侧面板是个性化参数调整和分析结果日志区,可以选择需要应用哪些面部特征、设定采样率、控制样本空间大小等,并通过日志来查阅分析模型对用户表情分析的结果;右侧面板是实时的表情数据采样和特征空间分布展示区,上半部分是摄像头面板,用于展示实时采集到的面部数据;下半部分是分析模型建立的表情特征空间分布.每个分析模型对其相应的用户建立表情特征分布图,其中每一点代表经摄像头采样和可信计算后得到的面部帧数据矢量,通过主成分降维后,在二维空间中的分布.为了便于直观感受,选取区域内靠近中心的数据帧显示原始面部.通过个体模型间的交互机制,协同传递和学习预动环境中其他个体模型建立的表情特征分布和个性化的特征证据元素,改进和优化自身的协同信任模型,由此实现的表情特征分析是预动环境中可信的分析结果。

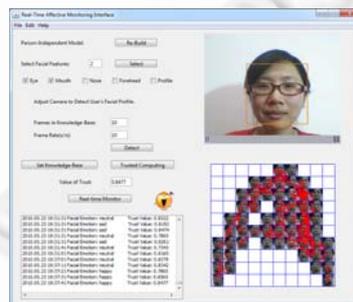


Fig.4 Person-Independent facial feature analysis based on synergetic trust

图 4 基于协同信任的个体表情分析模型

实验场景设定为模拟学术报告的预动环境:在会议室中有 9 位用户在观看 PPT 并进行交流,其中有 2 位教师和 7 位学生.实验目的是验证基于协同信任模型构建的可信表情分析框架是合理的、有效的.通过图 4 描述的分析模型,实时地对用户进行表情分析.情感特征证据的计算方法采用上文阐述的模型算法,表情分类算法采用模型间可协同交互的动态聚类算法,通过实验结果判定面部表情可信分析的优越性.

实验设计如下:个体分析模型从预动环境中实时地采集参与用户的面部特征数据,通过动态聚类分析给出面部特征矢量在计算空间中的分布(如图 4 右下方示意);协同依赖的信任计算与情感特征模型的交互是紧密相关的,实验中的情感特征证据通过证据融合机制(包括传递机制和聚合机制)实现协同依赖,个体模型间根据协同交互迭代传递表情特征证据元素以及模型间的权重因子:情感特征表达证据 $\omega_1 \in [0.4, 0.7]$ 、情感特征状态证据 $\omega_2 \in [0.2, 0.5]$ 和情感特征体验证据 $\omega_3 \in [0.1, 0.3]$,并且满足 $\sum_i \omega_i = 1$,优化个体模型自身对观察用户建立的面部特征库;最后,根据面部特征库和协同依赖的信任算法实时分析用户面部表情分类的可信保障.

下面给出协同依赖的可信表情分析实验的流程描述:

输入:个体模型采集参与用户的面部特征数据;

流程:

- i. 个体分析模型应用可编程摄像头实时地对观察用户进行面部数据采样,经过 Haar-like 特征提取和动态聚类分析后,在计算空间中给出特征矢量的分布展示;
- ii. 在应用协同交互的可信表情分析之前,由于预动环境中尚未有任何一个个体模型已建立好协同信任的计算模型,因此需要给出一个具有初始化信任值 T_0 的个体模型,例如模型 $I(\text{initial})$.该个体模型选取预动环境中的某个用户,让其按照顺序依次给出根据特征证据表达的一组基本面部表情采样,作为个体模型 I 建立的表情特征证据库,仅在该个体模型内根据计算空间中面部特征矢量的分布建立动态聚类分析库以及可信计算模型;
- iii. 将模型 I 作为预动环境中的标准模型,其他个体模型通过与其进行模型间的协同交互来学习,应用协同信任算法建立表情特征证据库;以此类推,其他模型也可以彼此间进行多模型间的协同交互学习,完成更为复杂的情感特征证据库的构建和可信分析计算;
- iv. 个体模型根据协同信任建立表情的可信分析模型,实时计算并记录表情分析结果的可信度量;
- v. 根据真实表达的面部表情情况,对个体模型的可信分析结果给出判别和统计,用于实验结果分析.

输出:返回用户的表情特征分布图和可信表情的分析结果.

根据上述流程,完成实验场景中预定的实验设计:在一段时间内,个体模型分别观察不同的参与用户;选取其中的任一用户,将其对应的个体模型确定为模型 I ,并在模型内给出初始化信任值 T_0 ,建立标准的信任计算模型;其他个体模型在实验流程的指导下,通过彼此间的协同交互完成表情特征证据计算,实现协同信任的可信表情分析,记录表情分类结果和可信分析结果.通过对实验结果进行分析,验证了基于个体模型间协同交互设计的表情特征分析算法是合理且可信的,在此基础上完成的表情识别分析具有可信性保障.

在实验中,个体模型通过交互传递表情特征证据和权重因子,改进模型自身对用户表情聚类的构建和可信判断过程.在迭代交互的过程中,由于个体模型处于相同的预动环境,最终会逐渐形成协同的一致性.例如,个体模型所分析的主体面部特征聚类分布的差异度会随着交互的进行逐渐变小,并稳定在一个差异度相似的水平上.为了便于评估个体模型间的协同效应,根据模型间的协同交互,给出协同交互差异率 CID(cooperative interactive differences)的定义:

$$CID_{(m)}^{(k+1)} = \left| \sum_j AFE_j^{(k+1)} - \sum_j \omega_j^{(k,m)} \cdot AFE_j^{(k,m)} \right| \left/ \left(\sum_j \omega_j^{(k,m)} \cdot AFE_j^{(k,m)} \right) \right. \quad (24)$$

其中, $CID_{(m)}^{(k+1)}$ 表示当前个体模型在第 $k+1$ 次迭代后与第 m 个模型交互的协同差异率, $\sum_j AFE_j^{(k+1)}$ 表示通过第 $k+1$ 次迭代交互后得到的新特征证据矢量和, $\sum_j \omega_j^{(k,m)} \cdot AFE_j^{(k,m)}$ 表示第 k 次迭代交互过程中来自第 m 个模型的

特征证据加权矢量和。

协同交互差异率的定义表明:交互差异率越大,交互双方在特征证据分布的差异越大;反之,交互差异率越小,进行协同交互的模型在特征证据分布上会有更多的相同点。

根据实验设计,预动环境中 9 位用户对应不同的个体模型,随机选取其中任一模型确定为 Model I ,其余的个体模型依次定义为 Model 1~Model 8。通过研究其他模型与 Model I 的协同差异率 $CID_{(i)}^{(k+1)}$,分析预动环境中个体模型在交互过程中形成的协同一致结果。

图 5 展示了 Model 1~Model 8 个体模型与 Model I 间的交互差异率;曲线分布空间的横轴表示个体模型与 Model I 交互的时间,而纵轴表示个体模型与 Model I 的协同差异率值。从模型间的协同差异率曲线图直观地看到:随着 Model 1~Model 8 与 Model I 的交互,个体模型对观察用户进行表情特征证据的迭代计算,通过学习 Model I 中已经建立的特征证据分布和信任分析算法改进模型自身的可信表情模型,最终趋向大部分的个体模型与 Model I 分析的特征证据分布的差异度降低,从而快速地达到表情可信分析的局部优化。同时,其他个体模型的特征证据结构和初始化信任值是通过与 Model I 协同学习而建立的,而 Model I 中是初始化由选定用户根据自身情况给出的符合真实判定条件的可信面部表情表达,由此,根据协同算法得到的表情分析结果是预动环境中全局优化和可信的。对个体模型间协同交互差异率的分析表明,基于模型交互的协同信任算法是合理的,且在预动环境中能够实现构建全局优化解。根据构建的个体表情分析模型和特征证据分布,进一步对实时分析的表情分类结果进行可信性度量 and 识别。

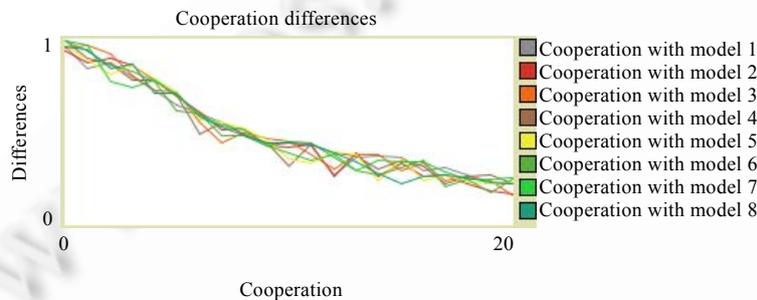


Fig.5 Cooperative interactive differences with models synergetic interaction

图 5 模型间交互的协同差异率

表 1 列出了实验中采用不同策略对信任计算的效率和结果比较,包括信任分析算法的平均收敛时间以及对表情状态识别的可信判断均值,平均收敛时间体现出了算法效率。对比实验结果可以发现:随着个体模型采样样本帧数量的增加,基于模型间协同交互构建的分析算法与普通单模型算法在收敛时间上基本持平:交互使得计算信任的时间有所增加,但均在可接受范围内,平均增加时间 0.13s;而随着采样样本数量的增加,协同交互使得个体模型在选取初始化信任值 T_0 和特征证据分布结构上有更大的优势,进而降低了算法收敛的时间。如从 2 000 帧~4 000 帧的过程中,计算时间减少了 3%,且得到的是全局优化的协同依赖结果,算法效率有所提高。同时,随着个体模型间协同交互差异率在交互的过程中越来越小并趋于平衡,迭代传递的特征证据元素和权重因子保证了个体模型实时分析和可信判别表情状态的结果更加准确。表 1 表明,随着采样样本量的递增,个体模型的表情识别可信度分别提高了 0.5%,1.1%,1.9%和 3.1%。在充分保证个体模型对用户表情特征证据分布和协同依赖一致性和高效性构建的同时,个体模型的可信分析率仍然有如此提高,从而验证了基于模型间交互建立的协同信任分析算法的合理性和可用性。

实验应用协同信任,设计可交互的个体模型实现对表情特征证据的协同依赖和可信分析,验证了基于协同交互改进的可信分析算法可以有效地提高表情识别分析的可信率。在个体模型信任框架的基础上,通过与其他模型间分享特征证据的分布信息,改善了模型中初始信任值和证据分布对信任模型分析准确率的影响。很大程

度上避免了预动环境中不同用户在表达相似情感时由于表情表达的差异性对个体模型选取特征证据矢量造成的局部混淆,使得证据理论得到了有效的扩展,并能在全局中得到优化.

Table 1 Convergence time and mean value of synergetic trust

表 1 协同信任的收敛时间和信任均值

采样样本/帧	单模型分析		多模型协同	
	收敛时间/s	信任均值	收敛时间/s	信任均值
500	0.72	0.664	0.84	0.679
1 000	1.39	0.720	1.45	0.731
2 000	2.26	0.793	2.43	0.812
4 000	4.41	0.820	4.59	0.851

5 结 论

本文结合协同学理论扩展了证据理论,提出以模型间交互学习为基础的协同信任计算模型,并将该模型应用到预动环境中的表情分析研究.算法框架描述了个体模型在建立可信表情分析的过程中,通过迭代交互已有的初始化信任值和表情特征证据,从全局优化的角度给出了表情可信分析的协同建立方法和调整策略,以此得到可信的表情结果.协同信任算法模型的提出,从智能认知的角度解释了表情分析的算法内涵和可信概念,建立了系统化的可信表情分析机制,为构建准确、优化的实时表情研究提供了理论基础.设计实现了协同信任表情分析实验,验证了协同信任算法优化实时表情的可信分析效果.在不损失算法效率的基础上,通过模型间交互,降低了初始信任和证据选取的影响,提高了信任模型与真实表情特征分析的相似度和分析识别的准确率.

致谢 在此,我们向对本文的工作给予理论和实验支持的许光全老师和张瑜同学表示感谢.

References:

- [1] Khuzadi M. On health monitoring. In: Proc. of the 2008 IEEE Aerospace Conf. IEEE Press, 2008. 1–8. http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4526637 [doi: 10.1109/AERO.2008.4526637]
- [2] Yang CQ, Wu ZS, Zhang YF. Structural health monitoring of an existing PC box girder bridge with distributed HCFRP sensors in a destructive test. Smart Materials and Structures, 2008,17(3):10. [doi: 10.1088/0964-1726/17/3/035032]
- [3] Cigada A, Caprioli A, Redaelli M, Vanali M. Vibration testing at Meazza stadium: Reliability of operational modal analysis to health monitoring purposes. Journal of Performance of Constructed Facilities, 2008,22(4):228–237. [doi: 10.1061/(ASCE)0887-3828(2008)22:4(228)]
- [4] Su CJ. Mobile multi-agent based, distributed information platform (MADIP) for wide-area e-health monitoring. Computers in Industry, 2008,59(1):55–68. [doi: 10.1016/j.compind.2007.06.001]
- [5] Tennenhouse D. Proactive computing. Communications of the ACM, 2000,43(5):43–50. [doi: 10.1145/332833.332837]
- [6] Oulasvirta A, Salovaara A. A cognitive meta-analysis of design approaches to interruptions in intelligent environments. In: Proc. of the Conf. on Human Factors in Computing Systems (CHI). ACM Press, 2004. 1155–1158. <http://dl.acm.org/citation.cfm?doid=985921.986012> [doi: 10.1145/985921.986012]
- [7] Timpka T. Proactive health computing. Artificial Intelligence in Medicine, 2001,23(1):13–24. [doi: 10.1016/S0933-3657(01)00073-2]
- [8] Vanhala J, Mäyrä F, Koskinen I. Living in metamorphosis: Proactive computing in the home environment. Interactions (ACM), 2005,12(4):28–31. [doi: 10.1145/1070960.1070981]
- [9] Ulla A, Juhani L. Programme Memorandum. Research programme on health services research 2004-2007. Research Council for Health Academy of Finland. 2007. 1–18. <http://www.aka.fi/Tiedostot/Tiedostot/TERTTU/Programme%20Memorandum.pdf>
- [10] Reetta K. Research programme on environmental, societal and health effects of genetically modified organisms 2004-2007. Academy of Finland. 2008. 1–36. <http://www.aka.fi/en-gb/A/Science-in-society/Research-programmes/Completed/Research-Programme-on-Environmental-Societal-and-Health-Effects-of-Genetically-Modified-Organisms-2004-2007-ESGEMO/>

- [11] Alpo V. ProHeMon: Proactive health monitoring. Final Report of the Research Project in the Academy of Finland Proactive Computing Research Program. 2006. 1–14. <http://www.cs.tut.fi/~varri/prohemon/profina4.pdf>
- [12] Koivistoinen T, Junnila S, Värri A, Kööbi T. A new method for measuring the ballistocardiogram using EMFi sensors in a normal chair. In: Proc. of the 26th Annual Int'l Conf. of the IEEE EMBS. IEEE Press, 2004. 2026–2029. http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1403596 [doi: 10.1109/IEMBS.2004.1403596]
- [13] Xu GQ, Feng ZY, Wu HB, Zhao DX. Swift trust in a virtual temporary system: A model based on the Dempster-Shafer theory of belief functions. Int'l Journal of Electronic Commerce, 2007,12(1):93–126. [doi: 10.2753/JEC1086-4415120104]
- [14] Haken H. Synergetics: An Introduction. New York: Springer-Verlag, 1977. 191–224.
- [15] Haken H. Information and Self-Organization. 2nd Enlarged ed., New York: Springer-Verlag, 2000. 69–114.
- [16] Liu LP, Yager RR. Classic works of the Dempster-Shafer theory of belief functions. Studies in Fuzziness and Soft Computing, 2008,219:1–34. [doi: 10.1007/978-3-540-44792-4]
- [17] Shafer G. A Mathematical Theory of Evidence. Princeton: Princeton University Press, 1976. 35–73.
- [18] Picard RW. Affective Computing. London: Massachusetts Institute of Technology Press, 1997. 1–83.
- [19] Saloey P, Mayer JD. Emotional intelligence. Imagination, Cognition and Personality, 1990,9(3):185–211. [doi: 10.2190/DUGG-P24E-52WK-6CDG]
- [20] Goleman D. Working with Emotional Intelligence. New York: Bantam Books Publications, 2000. 133–234.
- [21] Meyerson D, Weick KE, Kramer RM. Swift trust and temporary groups. In: Kramer RM, Tyler TR, eds. Trust in Organizations: Frontiers of Theory and Research. London: Sage Publications, 1996. 166–195.
- [22] Pavani SK, Delgado D, Frangi AF. Haar-Like features with optimally weighted rectangles for rapid object detection. Pattern Recognition, 2010,43(1):160–172. [doi: 10.1016/j.patcog.2009.05.011]



徐超(1982—),男,山东沂水人,博士,讲师,CCF 会员,主要研究领域为情感计算,模式识别.



王家昉(1982—),男,博士,工程师,主要研究领域为知识工程,智能 Agent.



冯志勇(1965—),男,博士,教授,博士生导师,CCF 高级会员,主要研究领域为知识工程,服务计算.