

基于特征解码的表情识别方法研究

吴东升, 林玉婷, 徐鹏飞

(沈阳理工大学 自动化与电气工程学院, 沈阳 110159)

摘要: 针对目前大多数面部表情提取未充分考虑语义特征以及个人独特面部特征导致面部表情识别准确性低的问题, 提出一种基于特征解码的高效表情识别方法, 称为 FER-FD 方法。该方法由两个模块组成, 即特征解耦模块 (FFD) 和语义强化模块 (VTS)。首先, FFD 模块使用两个深度二维卷积神经网络从输入图像中提取面部和表情特征, 面部特征解耦器将面部特征与表情特征解耦, 以最大限度地减少个人独特面部特征的影响; 其次, VTS 模块采用两个关键思想以无监督的方式自动捕获面部运动, 从而建立全局面部区域的深层语义信息; 最后, 将两个模块的特征串联起来, 以更准确地预测样本的面部表情。实验结果表明, 本文提出的特征解码方法在 CK+ 数据集上获得了 98.78% 的准确率, 对不同场景具有可扩展性和适应性, 具有较好的泛化能力。

关键词: 表情识别; 特征解码; 注意力机制; 深度学习

中图分类号: TP391.4 **文献标志码:** A **DOI:** 10.3969/j.issn.1003-1251.2025.01.003

Research on Expression Recognition Method Based on Feature Decoding

WU Dongsheng, LIN Yuting, XU Pengfei

(Shenyang Ligong University, Shenyang 110159, China)

Abstract: To address the issue of low accuracy in facial expression recognition due to insufficient consideration of semantic features and individual facial characteristics in most current facial expression extraction methods, a highly efficient facial expression recognition method based on feature decoding (FER-FD) is proposed. This method consists of two modules, namely the feature decoupling module (FFD) and the semantic enhancement module (VTS). Firstly, the FFD module employs two deep 2D convolutional neural networks to extract facial and expression features from input images, where the facial feature decoupler disentangles facial features from expression features to minimize the influence of individual facial characteristics. Secondly, the VTS module adopts two key ideas to automatically capture facial movements in an unsupervised manner, thereby acquiring deep semantic information of the global facial region. Finally, concatenating the features from both modules enables more accurate prediction of facial expressions of samples. Experimental results demonstrate that the proposed feature decoding method achieves 98.78% accuracy on the CK+ dataset, exhibiting scalability, adaptability to different scenarios, and good generalization capability.

Key words: expression recognition; feature decoding; attention mechanisms; deep learning

情感机器核心目标在于优化人机交互的体验,是人工智能领域备受瞩目的研究课题^[1]。在交通运输行业,为了降低因驾驶员人为因素所导致的损失,冯笑等^[2]提出了一种基于脑电信号的疲劳检测方法,但在实际应用中存在设备成本高、技术复杂以及可能侵犯驾驶员隐私等问题。为此,科研人员开始探索非侵入性的驾驶员疲劳检测方法。面部表情识别^[3-5]因其非侵入性、实时性与低成本等优势,被认为是极具潜力的一种手段,通过对面部表情的细致分析,可以间接评估驾驶员的疲劳程度。因此,需要一种高效、准确的面部表情识别方法。

面部表情识别的关键是提取表情的语义特征。传统的机器学习常用的特征提取方法包括局部二值模式(LBP)^[6]和 Gabor 小波表示法^[7]。近年来,深度神经网络在视觉和模式识别领域展现出卓越的性能^[8-10]。引入注意力机制^[11]可以提高面部表情识别的鲁棒性。Wang 等^[12]提出一种区域性注意力机制,以增强深度神经网络的语义表示。Zhao 等^[13]在其研究中利用卷积注意力模块(CBAM)将注意力区域从遮挡面部区域转移至非遮挡区域,有效减少了遮挡导致的识别误差,进而提高了目标检测和物体分类的准确性。

面部表情识别通常受到个人独特面部特征的负面影响。Oulu-CASIA 数据集^[14]中的表情图像具有个体差异性^[15],个人独特面部特征引起同类别面部表情差异大,而不同类别面部表情差异小,从而增加了表情识别模型的误分类风险。Ji 等^[16]既考虑到类内共同特征,又考虑到类间的特征差异,提出了双特征融合网络。受到无监督学习的启发,姚乃明等^[17]提出了一种多任务训练方法,利用不同任务之间的对抗关系消除与表情无关的冗余信息,通过调整损失函数,实现了特征解耦^[18]。Yang 等^[19]提出表情交换网络,通过交换两个不同人物表情图像的表情特征,达到分离表情特征和身份特征的目的,研究发现,消除与表情特征无关的其他特征可以提高面部表情识别的准确性。

深度神经网络和注意力机制在特征提取方面的优越性能^[20]为面部表情识别领域带来了新的机遇和挑战。深度学习无法学习空间的长程依赖关系,并且当干扰区域过大时会导致错误的空间语义关系。为了解决上述方法存在的问题并考虑鲁棒性、语义性和个性化特征,本文提出一种特征解耦的表情识别方法。首先,通过引入特征解耦模块(FFD),成功实现对表情特征和面部特

征的解耦,有效抑制独特属性特征对表情识别的干扰,该模块不仅提高了表情识别的准确性,也增强了方法的鲁棒性,使其能够在不同场景下保持性能的稳定;其次,提出一种新的微分注意力(DA)机制,该机制能够以无监督的方式精确发现和识别图像之间可能存在的变化;最后,将解耦后的表情特征与 DA 机制提取的深层语义特征进行有效融合。本文将该种基于特征解耦的表情识别方法简称为 FER-FD 方法。

1 特征解耦模块

FFD 目标是将原始数据中的特征进行分解,得到可以独立表示不同特征的特征向量。FFD 通过学习数据的特征,将任务相关的特征和无关的特征进行分离,以帮助模型更好地专注与任务相关的信息,从而提高模型的准确性和泛化能力。

在 FFD 中,首先通过面部特征提取器从输入图像中提取用于面部识别的纯面部特征,使用表情特征提取器提取表情特征。其次,解耦器去除与特定表情不直接相关的面部特征,例如皮肤的纹理、颜色、光照条件等;在去除非直接相关特征的同时,解耦器进一步提取和强化与特定表情直接相关的面部特征,如眉毛的弯曲度、眼睛的睁闭程度、嘴角的上扬或下垂等。经过解耦器的处理,最终生成典型的面部特征(typical facial features, TFF),这些特征最大限度地减少了个人独特面部特征的影响,使模型更加聚焦于表情本身,而非个体的面部差异。FFD 架构如图 1 所示。




图 1 FFD 架构图

Fig. 1 FFD architecture diagram

1.1 特征提取器

FFD 模块中的预训练面部识别网络结构如图 2 所示。预训练后,使用 Conv2_x 和 Conv3_x 作为特征提取器。其中,第一个模块主要用于提取面部的基础特征,包含了面部的大致轮廓和基本结构;第二个模块则在此基础上进一步提取与表情相关的特征,包括眉毛的弯曲度、眼睛的睁闭程度以及嘴角的上扬或下垂等。两个模块提取的特

征分别作为面部特征和表情特征,用于后续的处理和分析。另外 Conv4_x 和 Conv5_x 作为面部分类器接收从特征提取器中提取的特征。




图 2 预训练面部识别网络结构

Fig. 2 Pre-trained facial recognition network structure

1.2 解耦器

为了减轻面部特征对表情识别的影响,本文设计了一个解耦器模块构建 TFF 特征。该解耦器由三组卷积层和一个融合算子组成,每组的三个卷积层分别配置了 128, 64 和 128 个大小为 1×1 的核,步幅为 1 个像素,其结构如图 3 所示,三组卷积层分别记为 f_{FACE} , f_{EXP} 和 f_{TFF} 。解耦器的两个输入分别为来自特征提取器提取的面部特征和表情特征。在解耦器中通过逐元素相加操作,对相应的通道进行整合,其中 f_{TFF} 用于从表情特征中滤除面部特征的影响。解耦器的最终输出是 TFF 特征,表达式为

$$T_{uv}(x, y) = f_{\text{TFF}}(f_{\text{EXP}}(E_{uv}(x, y)) + f_{\text{FACE}}(F_{uv}(x, y))) \quad (1)$$

式中: $T_{uv}(x, y)$ 为第 v 个特征通道中的帧 $u(x, y)$ 位置的输出; E_{uv} 为表情特征提取中第 v 个特征通道的帧 $u(x, y)$ 位置输出; F_{uv} 为面部特征提取中第 v 个特征通道的帧 $u(x, y)$ 位置的输出。




图 3 解耦器的结构

Fig. 3 The structure of the decoupler

2 语义强化模块

随着深度学习的发展,注意力机制显著改善了计算机视觉识别能力。其中,注意力自回归机制通过计算输入序列中不同位置之间的相关性得分,使模型关注重要的区域,有助于提高模型的解释性和可理解性。但该机制赋予所有位置相等的注意力权重,使模型计算复杂度较高,且每个位置对输出的贡献相同,导致模型输出准确率较低。

在此基础上,本文提出 DA 机制,使模型只关注输入序列中与当前位置直接相关的信息,将注意力权重矩阵变为微分矩阵,使模型能够更好地理解输入序列中不同位置的重要性,从而更加准确地生成输出和更好地捕捉关键信息,有助于模型在处理具有复杂结构和语义信息的任务时更好地捕捉关键信息,提高任务的完成质量。

2.1 序列非重叠分块

将解耦器的输出 $T \in \mathbf{R}^{H \times W \times C}$ (H, W, C 分别为通道的高度、宽度和数量)划分为几个不重叠的图像块 \mathbf{B}_{TFF} , 表达式为

$$\mathbf{B}_{\text{TFF}} = \{b_{\text{TFF}}^i\}_{i=0}^{N_b-1} \quad (2)$$

$$|\mathbf{B}_{\text{TFF}}| = HW / (bs \times bs) \quad (3)$$

式中: b_{TFF}^i 为图像 T 的第 i 个区域块,其中 $0 \leq i \leq N_b - 1$; N_b 为图像所划分的不重叠区块数量; $bs \times bs$ 表示每个区块的分辨率。

2.2 替换区域

给定两个图像 T 和 $T + \delta$, 得

$$\lim_{\delta \rightarrow 0} s(b_{\text{TFF}}^i, b_{\text{TFF}+\delta}^i) = 1 \quad (4)$$

式中: δ 为位置索引; b_{TFF}^i 为图像 T 的第 i 个区域块; $b_{\text{TFF}+\delta}^i$ 为图像 $T + \delta$ 的第 i 个区域块; s 为测量 b_{TFF}^i 和 $b_{\text{TFF}+\delta}^i$ 之间相似性的函数。

本文提出了一种区域替换机制,如图 4 所示。首先,将图像 T 中的 b_{TFF}^i 与图像 $T + \delta$ 的 $b_{\text{TFF}+\delta}^i$ 进行随机交换,得到一个新的图像 T_s 。其次,强制模型发现这些变化并把新的图像 T_s 重建回原始的图像 T 和 $T + \delta$ 。由此模型在识别和恢复交换方面得到了进一步加强。

2.3 DA 机制

来自 T_s 的图像块 $b_{\text{TFF}/S}$ 由两种类型组成,分别是来自图像 T 的 b_{TFF}^i 的 $b_{\text{TFF}/S}^i$ 和来自图像 $T + \delta$ 的 $b_{\text{TFF}+\delta}^i$ 的 $b_{\text{TFF}/S}^j$, 其中 j 指未交换区域。下一阶段是学习如何从 $b_{\text{TFF}/S}$ 重建 b_{TFF}^i 。由于 $b_{\text{TFF}/S}^i$ 包含了图像 T 和图像 T_s 之间的所有变化,理论上,可




图 4 区域替换图

Fig. 4 Area substitution diagram

以利用 $\mathbf{b}_{\text{TFF}/S}$ 中的 $\mathbf{b}_{\text{TFF}/S}^i$ 索引的基本事实强制模型专注于这些交换的区块。然而,采用这些信息可能会降低发现这些差异变化的学习能力。因此,采用 DA 强制网络自动关注 $\mathbf{b}_{\text{TFF}/S}^i$, 并使其具备精确发现和识别图像之间所有变化的能力。

在 $\mathbf{b}_{\text{TFF}+\theta}$ 和 $\mathbf{b}_{\text{TFF}/S}$ 之间构建一个注意力图 $\hat{\mathbf{A}}$, $\hat{\mathbf{A}}$ 说明了 $\mathbf{b}_{\text{TFF}+\theta}^i$ 和 $\mathbf{b}_{\text{TFF}/S}^i$ 两个对应块之间的相关性。

对于所有 $\mathbf{b}_{\text{TFF}/S}^i \in \mathbf{b}_{\text{TFF}+\theta}$ 和 $\mathbf{b}_{\text{TFF}/S}^j \in \mathbf{b}_{\text{TFF}}$, 由于 $\mathbf{b}_{\text{TFF}/S}^i$ 包含了图像 T 和图像 T_S 之间所有的变化, 所以 $\hat{\mathbf{A}}(i, i) > \hat{\mathbf{A}}(j, j)$ 恒成立。DA 的完整表达式为

$$\hat{\mathbf{A}} = \text{Softmax}(\mathbf{Q}(\mathbf{B}_{\text{TFF}+\theta}) \otimes \mathbf{K}(\mathbf{B}_{\text{TFF}/S})^T) \quad (5)$$

$$\sum_{j=0}^{N_b} \hat{\mathbf{A}}(i, j) = 1 \quad (6)$$

式中: $\mathbf{B}_{\text{TFF}+\theta}$ 为图像 $T + \theta$ 中不重叠的图像块; $\mathbf{B}_{\text{TFF}/S}$ 为图像 T_S 中不重叠的图像块; \mathbf{Q} 为查询向量; \mathbf{K} 为键向量。

$$\mathbf{B}_{\text{da}} = \text{diag}(\hat{\mathbf{A}}) \times \mathbf{V}(\mathbf{B}_{\text{TFF}/S}) \quad (7)$$

式中: \mathbf{B}_{da} 为输出向量; \mathbf{V} 表示 $\mathbf{B}_{\text{TFF}/S}$ 线性变换后输

出的特征值。

3 表情识别流程

本文提出的基于特征解码的表情识别方法流程如图 5 所示。整个面部表情识别可分为两个模块:特征解耦模块和语义强化模块。具体识别步骤如下。

1) 在 FFD 阶段, 训练特征提取器、解耦器以实现最佳的面部表情识别。

2) 将 TFF 特征而不是原始图像输入到 VTS 模块中, 以简化 VTS 模块并降低小数据集上过度拟合的风险。

3) 基于 DA 机制帮助模型精确捕获输入序列中的语义信息, 实现对输入序列中重要信息的捕捉。

4) 通过学习公开的数据集中样本, 进一步优化模型准确率, 完成面部表情识别。

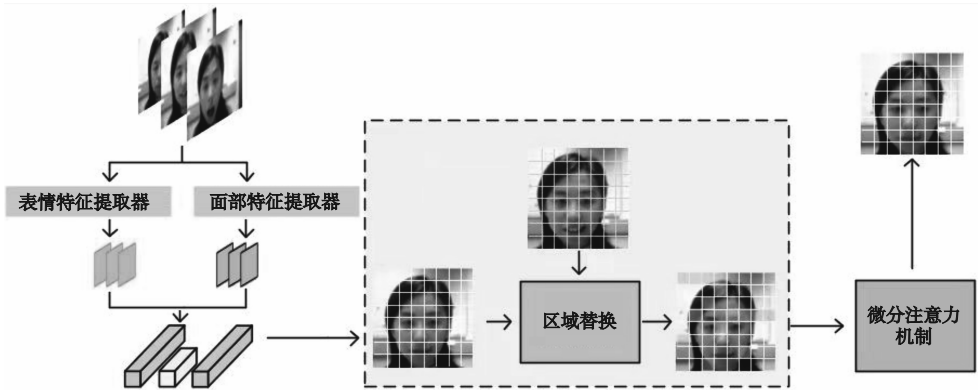


图 5 整体流程图

Fig. 5 Overall flowchart

4 实验验证

为验证本文方法的有效性, 采用扩展 Cohn-Kanade (CK+) 数据集^[21] 进行实验分析。实验中学习率固定为 0.000 1。所有的方法均选择优化器 Adam。本文实验所用的环境配置为: CPU 采用 Intel Core i7-8700; GPU 采用 NVIDIA GTX 1080; 深度学习框架为 Pytorch。

本文采用 MER 2019 挑战赛的标准指标和协议^[22] 评估模型性能。

4.1 数据集

CK+ 数据集包含 327 个带有七种表情的标记图像序列: 愤怒、蔑视、厌恶、恐惧、幸福、悲伤和惊讶。CK+ 中的所有表达序列都以中性表达开始, 并以情绪的峰值状态结束。本文将 CK+ 数据集划分为三个部分: 训练集、验证集、测试集。CK+ 中的图像序列按标签升序分为 10 个子集。使用 8 个子集作为训练集, 用于训练模型。使用 1 个子集作为验证集, 用来调整超参数和监控模型性能。使用剩下的 1 个子集作为测试集, 用于最终评估模型的性能。

4.2 在 CK + 数据集上的结果

本文使用 CK + 通过 10 倍交叉验证将 FER-FD 方法与其他先进方法进行比较,准确率如表 1 所示。在 CK + 数据集中,10 倍交叉验证的准确率平均标准差为 1.609%。表 1 显示 FER-FD 方法在 CK + 上获得了 98.78% 的准确率,比 3DCNN-DAP^[23] 提高 6.38%,比 CNN-DNN^[24] 提高 1.53%。进一步比较发现,CNN-DNN 将所有图像都输送到 CNN,导致计算成本增加。相比之下,FER-FD 方法对于 FER 任务具有更好的适应性和更高的准确率。

表 1 在 CK + 数据集上的结果
Table 1 Results on CK + dataset

方法	准确率/%
3DCNN	85.90
3DCNN-DAP	92.40
CNN-DNN	97.25
FER-FD	98.78

图 6 显示了 FER-FD 方法在 CK + 数据集上运行结果的混淆矩阵,分别展示了识别愤怒、蔑视、厌恶、恐惧、快乐、悲伤和惊讶的准确率。其中蔑视、厌恶、快乐和惊讶实现了 100% 识别,证明 FER-FD 方法在 CK + 上的综合性能较好。




图 6 CK + 数据集上的混淆矩阵

Fig. 6 Confusion matrix plot on CK + dataset

5 结论

本文提出了一种基于 FER-FD 的表情识别方法,并在 CK + 数据集上对该方法的性能进行了评估,得到如下结论。

1) 将面部特征与表情特征进行解耦。模型在识别表情时更加专注于表情本身,而不是受到面

部其他特征的干扰,能更准确地反映面部表情的变化,从而解决了主体间变异导致模型在识别表情时产生混淆的问题。

2) 通过 DA 引导网络,使模型重点关注面部最显著的部分,忽略背景中的噪声敏感性。DA 机制有助于模型更深入地理解面部表情的语义信息,进而提升识别性能。

3) 将经过解耦处理的表情特征与通过 DA 机制获取的深层语义特征进行序列连接,从而实现了特征的高效整合。

4) FER-FD 与其他常规的面部表情识别方法相比,模型参数和计算复杂度显著降低,具有更强的鲁棒性和面部语义获取能力。

参考文献 (References):

- [1] BRUCKNER D, ZEILINGER H, DIETRICH D. Cognitive automation survey of novel artificial general intelligence methods for the automation of human technical environments[J]. IEEE Transactions on Industrial Informatics, 2012, 8(2): 206 - 215.
- [2] 冯笑, 代少升, 黄炼. 基于可解释深度学习的单通道脑电跨被试疲劳驾驶检测[J]. 仪器仪表学报, 2023, 44(5): 140 - 149.
FENG X, DAI S S, HUANG L. Cross-subject driver fatigue detection from single-channel EEG with an interpretable deep learning model[J]. Chinese Journal of Scientific Instrument, 2023, 44(5): 140 - 149. (in Chinese)
- [3] 冉瑞生, 翁稳稳, 王宁, 等. 基于人脸关键特征提取的表情识别[J]. 计算机工程, 2023, 49(2): 254 - 262.
RAN R S, WENG W W, WANG N, et al. Expression recognition based on the extraction of key facial features[J]. Computer Engineering, 2023, 49(2): 254 - 262. (in Chinese)
- [4] SHANGGUAN Z X, LIU Z Y, LI G, et al. Dual-stream multiple instance learning for depression detection with facial expression videos[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering: a Publication of the IEEE Engineering in Medicine and Biology Society, 2023, 31: 554 - 563.
- [5] ZHOU X Z, HUANG P, LIU H M, et al. Learning content-adaptive feature pooling for facial depression recognition in videos[J]. Electronics Letters, 2019, 55(11): 648 - 650.
- [6] OJALA T, PIETIKAINEN M, MAENPAA T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(7): 971 - 987.
- [7] ZHENG W M, ZHOU X Y, ZOU C R, et al. Facial expression recognition using kernel canonical correlation analysis (KCCA) [J]. IEEE Transactions on Neural Networks, 2006, 17(1): 233 - 238.
- [8] YU J H, XU Y K, CHEN H, et al. Versatile graph neural networks toward intuitive human activity understanding [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, PP(99): 1 - 13.
- [9] YU J H, GAO H W, SUN J, et al. Spatial cognition-driven deep learning for car detection in unmanned aerial vehicle imagery[J]. IEEE Transactions on Cognitive and Developmen-

- tal Systems, 2022, 14(4): 1574 – 1583.
- [10] GIA Q K, NGAN L, NHAN D C, et al. Non-volume preserving-based fusion to group-level emotion recognition on crowd videos[J]. Pattern Recognition, 2022, 128: 108646.
- [11] YU J H, GAO H W, CHEN Y Q, et al. Deep object detector with attentional spatiotemporal LSTM for space human-robot interaction[J]. IEEE Transactions on Human-Machine Systems, 2022, 52(4): 784 – 793.
- [12] WANG K, PENG X J, YANG J F, et al. Region attention networks for pose and occlusion robust facial expression recognition[J]. IEEE Transactions on Image Processing; a Publication of the IEEE Signal Processing Society, 2020: 4057 – 4069.
- [13] ZHAO Z Q, LIU Q S, WANG S M. Learning deep global multi-scale and local attention features for facial expression recognition in the wild[J]. IEEE Transactions on Image Processing; a Publication of the IEEE Signal Processing Society, 2021, 30: 6544 – 6556.
- [14] PANTIC M, VALSTAR M, RADEMAKER R, et al. Web-based database for facial expression analysis[C]//2005 IEEE International Conference on Multimedia and Expo. Amsterdam, Netherlands; IEEE, 2005: 5 pp.
- [15] EKMAN P. An argument for basic emotions[J]. Cognition and Emotion, 1992, 6(3/4): 169 – 200.
- [16] JI Y L, HU Y H, YANG Y, et al. Cross-domain facial expression recognition via an intra-category common feature and inter-category distinction feature fusion network[J]. Neurocomputing, 2019, 333(C): 231 – 239.
- [17] 姚乃明, 郭清沛, 乔逢春, 等. 基于生成式对抗网络的鲁棒人脸表情识别[J]. 自动化学报, 2018, 44(5): 865 – 877.
- YAO N M, GUO Q P, QIAO F C, et al. Robust facial expression recognition with generative adversarial networks[J]. Acta Automatica Sinica, 2018, 44(5): 865 – 877. (in Chinese)
- [18] 唐珺琨, 张辉, 张邹铨, 等. 基于任务关联特征解耦网络的无监督领域自适应图像分类[J]. 计算机科学, 2023, 50(S2): 293 – 300.
- TANG J K, ZHANG H, ZHANG Z Q, et al. Unsupervised domain adaptive image classification based on task correlation feature decoupling network[J]. Computer Science, 2023, 50(S2): 293 – 300. (in Chinese)
- [19] YANG L, TIAN Y, SONG Y H, et al. A novel feature separation model exchange-GAN for facial expression recognition[J]. Knowledge-Based Systems, 2020, 204: 106217.
- [20] 于耀淋, 张景异, 睢付佳. 基于生成式对抗网络的人脸图像生成[J]. 沈阳理工大学学报, 2022, 41(5): 29 – 33.
- YU Y L, ZHANG J Y, JU F J. Face image generation based on generative adversarial network[J]. Journal of Shenyang Ligong University, 2022, 41(5): 29 – 33. (in Chinese)
- [21] 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]//2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition-Workshops. San Francisco, CA, USA: IEEE, 2010: 94 – 101.
- [22] SEE J, YAP M H, LI J, et al. Megc 2019 – the second facial micro-expressions grand challenge[C]//2019 14th IEEE International Conference on Automatic Face & Gesture Recognition. Lille, France; IEEE, 2019: 1 – 5.
- [23] LIU M Y, LI S X, SHAN S G, et al. Deeply learning deformable facial action parts model for dynamic expression analysis[C]//Asian Conference on Computer Vision. Cham, Swiss: Springer, 2015: 143 – 157.
- [24] JUNG H, LEE S, YIM J, et al. Joint fine-tuning in deep neural networks for facial expression recognition[C]//2015 IEEE International Conference on Computer Vision. Santiago, Chile; IEEE, 2015: 2983 – 2991.

(责任编辑:和晓军)

(上接第18页)

- [24] WANG J J, YAN J X, LI C, et al. Deep heterogeneous GRU model for predictive analytics in smart manufacturing: application to tool wear prediction[J]. Computers in Industry, 2019, 111: 1 – 14.
- [25] 陈昱, 项薇, 龚川. 基于数据挖掘的注塑产品质量在线检测及预测[J/OL]. 中国机械工程, 1 – 8[2024 – 03 – 11]. <http://kns.cnki.net/kcms/detail/42.1294.TH.20230331.1527.006.html>.
- CHEN Y, XIANG W, GONG C. Online diagnostic inspection and prediction of product quality in injection molding intelligent factory based on data mining[J/OL]. China Mechanical Engineering, 1 – 8[2024 – 03 – 11]. <http://kns.cnki.net/kcms/detail/42.1294.TH.20230331.1527.006.html>.
- [26] 张友, 李聪波, 林利红, 等. 数据不完备下基于 Informer 的离心鼓风机故障趋势预测方法[J]. 计算机集成制造系统, 2023, 29(1): 133 – 145.
- ZHANG Y, LI C B, LIN L H, et al. Centrifugal blower fault trend prediction method based on Informer with incomplete data[J]. Computer Integrated Manufacturing Systems, 2023, 29(1): 133 – 145. (in Chinese)

(责任编辑:和晓军)