

文章编号: 2095-4980(2023)09-1150-06

基于受试者工作特征 pAUC 优化的人脸识别系统

唐林瑞泽, 白仲鑫, 张晓雷*

(西北工业大学 航海学院, 陕西 西安 710072)

摘 要: 基于深度学习的人脸识别技术在大量应用场景中表现出优于传统方法的性能, 它们的损失函数大致可分为 2 类: 基于验证的和基于辨识的。验证型损失函数符合开集人脸识别的流程, 但实施过程比较困难。因此目前性能较优的人脸识别算法都是基于辨识型损失而设计的, 通常由 softmax 输出单元和交叉熵损失构成, 但辨识型损失并没有将训练过程与评估过程统一起来。本文针对开集人脸识别任务提出一种新的验证型损失函数, 即最大化受试者工作特征(ROC)曲线下的部分面积(pAUC); 同时还提出一种类中心学习策略提高训练效率, 使提出的验证型损失和辨识型损失有较强的可比性。在 5 个大规模非限定环境下的人脸数据集上的实验结果表明, 提出的方法和目前性能最优的人脸识别方法相比, 具有很强的竞争性。

关键词: 人脸识别; 部分面积优化; 损失函数; 类中心

中图分类号: TP391.4

文献标志码: A

doi: 10.11805/TKYDA2021258

Partial Area Under Curve optimization for face recognition system

TANG Linruize, BAI Zhongxin, ZHANG Xiaolei*

(School of Marine Science and Technology, Northwestern Polytechnical University, Xi'an Shaanxi 710072, China)

Abstract: Deep learning based face recognition has outperformed traditional methods in many application scenarios. There are two main lines of research to design loss functions for face recognition, i. e., verification and identification. The verification loss functions match the pipeline of open-set face recognition, but it is hard to implement. Therefore, most state-of-the-art deep learning methods for face recognition take the identification loss functions with softmax output units and cross-entropy loss. Nevertheless, identification loss function dose not match the training process with evaluation procedure. A verification loss function is proposed for open-set face recognition to maximize partial area under the Receiver-Operating-Characteristic(ROC) curve, partial Area Under Curve(pAUC). A class-center learning method is also proposed to improve training efficiency, which is critical for the proposed loss function to be comparable to the identification loss in performance. Experimental results on five large scale unconstrained face recognition benchmarks show that the proposed method is highly competitive with state-of-the-art face recognition methods.

Keywords: face recognition; partial Area Under Curve optimization; loss function; class centers

目前使用深层卷积神经网络(Deep Convolution Neural Networks, DCNNs)的嵌入进行人脸表征是人脸识别的首选方法^[1-4]。面部图像经过人脸对齐后^[5], DCNNs 将人脸图像映射为类内距离小且类间距离大的嵌入。

在训练 DCNNs 时, 有 2 种类型的损失函数, 分别为辨识型损失和验证型损失。前者主要由 softmax 分类输出单元和交叉熵损失构成^[1,4,6], 在 softmax 中引入带有间隔项的余弦函数控制类间距离, 但这类损失函数有 2 个缺点: a) 线性变换矩阵 $W \in \mathbb{R}^{d \times n}$ 的大小会随着身份数的增加而增加; b) 模型所学特征在闭集分类问题中对于不同类别的可区分性很强, 而在开集人脸识别任务中可区分性显著下降。验证型损失函数通过构造成对的或是三元组的样本进行模型训练, 如三元组损失函数^[2]。构造样本对进行训练恰好模拟了人脸注册和测试的流程, 模型不

收稿日期: 2021-06-18; 修回日期: 2021-08-16

基金项目: 国家自然科学基金资助项目(61671381); 中国传媒大学媒体融合与传播国家重点实验室开放基金资助项目(SKLMCC2020KF009)

*通信作者: 张晓雷 email: xiaolei.zhang@nwpu.edu.cn

再需要 softmax 输出层进行分类,而是直接输出 2 张人脸的相似度来进行身份判别。当相似度高于某一阈值时,即认为 2 张人脸为同一身份。验证型损失函数也存在以下缺点: a) 在大规模数据集中,构造样本对容易出现组合爆炸的问题,且过多的样本对会导致训练模型的迭代次数显著增加; b) 能够有效解决组合爆炸问题的难例挖掘(hard sample mining)策略实现困难。尽管验证型损失函数有一些缺点,但其训练过程与评估过程是一致的,因此更适合于开集人脸识别。另外,在真实的应用场景中,人脸识别系统仅在受试者工作特征(ROC)曲线下的部分区域(pAUC)工作,而不是整个 ROC 曲线。

基于在声纹识别任务中提出的 pAUC 算法^[7],本文针对开集人脸识别任务提出一种新的验证型损失函数,即最大化 ROC 曲线下的 pAUC 算法,并成功地将该方法用于人脸识别系统中。受辨识型损失函数的启发,在训练过程中引入了类中心学习的策略来提高训练效率。相比于图像与图像的比较,图像与类中心的比较方法更有效且稳定。因为类中心相比于人脸图片数量要少得多,且更具有代表性;同时它在训练的过程中可以用一个在线更新的向量来表示。在 5 个大规模非限定环境下的人脸数据集上的实验结果表明,本文提出的方法和目前性能最优的人脸识别方法相比,具有很强的竞争性。

1 方法

1.1 pAUC 优化

在训练过程中,将成对的人脸图像输入到 DCNN 后得到相对应的嵌入,并计算它们的相似度分数 s ; 然后通过 pAUC 损失函数优化更新模型。测试阶段,训练好的 DCNN 直接输出嵌入向量,并利用该向量进行人脸验证。其训练和测试框架如图 1 所示。

设训练集 $\Gamma = \{(\mathbf{x}_n, \mathbf{y}_n; l_n) | n = 1, 2, \dots, N\}$, 其中 $\mathbf{x}_n$ 和 $\mathbf{y}_n$ 是输入的一对人脸经过 DCNN 提取后的嵌入, l_n 用来判断 $\mathbf{x}_n$ 和 $\mathbf{y}_n$ 是否为同一身份的标签, 如果为同一身份, 则 $l_n = 1$; 否则 $l_n = 0$ 。定义一个相似度函数 $s_n = f(\mathbf{x}_n, \mathbf{y}_n)$, $s_n \in \mathbb{R}$ 。则有:

$$\hat{l}_n = \begin{cases} 1, & \text{当 } s_n \geq \theta \text{ 时} \\ 0, & \text{其他} \end{cases}, \forall n = 1, 2, \dots, N \quad (1)$$

式中 θ 为一个决策阈值。当 θ 给定后, 就能计算真正例率(True Positive Rate, TPR)和假正例率(False Positive Rate, FPR)。TPR 是指在所有的正例中, 将同类样本($l_n = 1$)正确预测($\hat{l}_n = 1$)的比例。FPR 是指在所有的负例中, 将不同类样本($l_n = 0$)错误预测为同一类($\hat{l}_n = 1$)的比例。给定不同的 θ , 能得到一系列的 $\{TPR(\theta), FPR(\theta)\}$ 值, 从而绘制 ROC 曲线, 如图 2 所示。

图 2 中的灰色区域即为定义的 pAUC, 是指当 FPR 值在 $[\alpha, \beta]$ 区间时的 ROC 曲线下面积, 其中 α 和 β 为 2 个超参数。为了计算 pAUC, 构造 2 个集合:

$$P = \{(s_i, l_i = 1) | i = 1, 2, \dots, I\} \quad (2)$$

$$\mathcal{N} = \{(s_j, l_j = 0) | j = 1, 2, \dots, J\} \quad (3)$$

其中 $I + J = N$ 。然后, 通过约束 $FPR \in [\alpha, \beta]$, 从 N 得到一个新的子集 N_0 , 构造步骤如下:

1) 用 $[j_a/J, j_\beta/J]$ 代替 $[\alpha, \beta]$, 其中 $j_\beta = \lfloor J \cdot \beta \rfloor$, $j_a = \lceil J \cdot \alpha \rceil + 1$ 为 2 个整数;

2) 将相似度得分 $\{s_j\}_{j \in \mathcal{N}}$ 降序排列, 其中 $\forall j: s_j$ 表示所有满足条件 s_j 的 j 都会参与计算;

3) 构造负例子集 $\mathcal{N}_0$: 由集合 $\mathcal{N}$ 中相似得分 $\{s_j\}_{j \in \mathcal{N}}$ 按降序排列后的第 j_a 到第 j_β 个样本构成, 记为 $\mathcal{N}_0 = \{(s_k, l_k = 0) | k = 1, 2, \dots, K\}$, 其中 $K = j_\beta - j_a$ 。

最后 pAUC 由集合 P 和 $\mathcal{N}_0$ 计算可得:




Fig.1 An overview of the proposed pAUC framework
图 1 pAUC 框架




Fig.2 Illustration of the ROC curve, AUC, and pAUC
图 2 ROC 曲线, AUC 和 pAUC 示例

$$pAUC = 1 - \frac{1}{IK} \sum_{\forall i: s_i \in P} \sum_{\forall k: s_k \in \mathcal{N}_i^c} \left[\mathbb{I}(s_i < s_k) + \frac{1}{2} \mathbb{I}(s_i = s_k) \right] \quad (4)$$

式中 $\mathbb{I}(\cdot)$ 为一个示性函数, 当条件成立时, 返回 1; 否则, 返回 0。但式(4)是一个 NP 难问题, 无法直接优化, 故使用合页损失函数(hinge loss)^[8]进行松弛:

$$\mathcal{L}_{\text{hinge}}(z) = \max(0, \delta - z) \quad (5)$$

式中 $z = s_i - s_k$ 。由于式(5)对 z 求导恒为常数, 无法反映不同样本之间的差异, 故对式(5)做如下改进:

$$\mathcal{L}'_{\text{hinge}}(z) = \max(0, \delta - z)^2 \quad (6)$$

将式(6)代入式(4), 并将最大化问题转为最小化问题, 则 pAUC 优化的目标函数可表示为:

$$pAUC = \min \frac{1}{IK} \sum_{\forall i: s_i \in P} \sum_{\forall k: s_k \in \mathcal{N}_i^c} \max[0, \delta - (s_i - s_k)]^2 \quad (7)$$

式中 s 使用余弦相似度函数 $s_n = f(\mathbf{x}_n, \mathbf{y}_n)$ 计算:

$$s_n = f(\mathbf{x}_n, \mathbf{y}_n) = \frac{\mathbf{x}_n^T \cdot \mathbf{y}_n}{\|\mathbf{x}_n\| \|\mathbf{y}_n\|} \quad (8)$$

式中 $\|\cdot\|$ 为 ℓ_2 范数。

1.2 类中心学习

设训练集为 $\mathcal{X} = \{\mathbf{x}_{uv} | u = 1, \dots, U; v = 1, \dots, V_u\}$, 其中 u 和 v 表示第 u 个身份里的第 v 张面部图片, U 是训练集中总的身份数, V_u 是第 u 个身份所包含的照片数量, 则整个训练集中的照片数量为 $\sum_u V_u$ 。如果用所有这些图片构造分批次的训练集 T , 其数量将会非常庞大, 直接使用整个数据集是不实际的。因此, 在本工作中除了使用小批次(mini-batch)训练, 还引入了 2 种方法构造样本对:

1) 随机采样: 在每一个小批次迭代中, 采用如下随机采样策略来构造集合 T' 。首先随机从整个训练集 $\mathcal{X}$ 中抽取 t 个身份, 再从它们每个身份随机抽取 2 张照片并进行全排列。由此构成一个包含 $2t$ 张照片的集合 T' 。该集合包含 t 对正例和 $C_{2t}^2 - t = t(2t-1) - t$ 对负例。

2) 类中心学习: 在每一个小批次迭代中利用类中心学习法构造集合 T^{t_1} 。受辨识型损失函数的启发, 给每一个身份分配一个类中心向量 $\mathbf{w}$, 记作 $\{\mathbf{w}_u\}_{u=1}^U$, 如图 3 所示。在每一次迭代时, 随机选取 t_1 张照片, 并将其与类中心 $\{\mathbf{w}_u\}_{u=1}^U$ 进行组合构造 T^{t_1} 。其中包含了 t_1 对正例和 $(t_1 U - t_1)$ 对负例。另外, 类中心 $\{\mathbf{w}_u\}_{u=1}^U$ 是随机初始化的, 并且会在每次迭代时通过反向传播进行更新。




Fig.3 Class-center learning method

图3 类中心学习

将随机采样与类中心学习法对比可以发现, 类中心学习法将每个身份的所有图像信息汇聚到一个中心向量 $\mathbf{w}$ 上。因此, 类中心相比于单张图像具有更强的代表性和鲁棒性, 且数量也大大减少; 在 T^{t_1} 上进行训练, 效率也将提高且更容易收敛。

2 与其他损失函数的对比

2.1 与辨识型损失函数的联系

辨识型损失函数通常由 softmax 分类输出单元和交叉熵损失构成，其表达式如下：

$$\mathcal{L}_{\text{softmax}} = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{W_{y_i}^T x_i + b_{y_i}}}{\sum_{j=1}^n e^{W_j^T x_i + b_j}} \quad (9)$$

式中： $x_i \in \mathbb{R}^d$ 表示属于第 y_i 类的第 i 个样本在 DCNN 最后一个隐藏层中的深层次特征，维数 d 通常设置为 $512^{[4,6,9-10]}$ ； $W_j \in \mathbb{R}^d$ 表示权重矩阵 $W \in \mathbb{R}^{d \times n}$ 的第 j 列； b_{y_i} 为偏置项。一个批次的大小(batch size)和该批次中的类别数分别为 N 和 n 。目前，基于 $\mathcal{L}_{\text{softmax}}$ 改进的辨识型损失函数^[1,4,6]的统一表达式为：

$$\mathcal{L}_\theta = -\frac{1}{N} \sum_{i=1}^N \log \frac{e^{s[\cos(m_1 \theta_{y_i} + m_2) - m_3]}}{e^{s[\cos(m_1 \theta_{y_i} + m_2) - m_3]} + \sum_{j=1, j \neq y_i}^n e^{s \cos \theta_j}} \quad (10)$$

式中： m_1 、 m_2 、 m_3 均为间隔项； θ 为类中心 w_j 和样本 x_i 的夹角。

文中提出的类中心学习法和 softmax 分类器有着紧密的联系。式(7)是为了在每个小批次迭代时最大化训练集 T^U 的 pAUC，而最小化 $\mathcal{L}_{\text{softmax}}$ 是为了让每个批次中的样本能够正确分类。在 pAUC 优化中，类中心 $\{w_u\}_{u=1}^U$ 是用来构造训练集 T^U 的；在 softmax 分类器中，它为式(9)的一个参数。

2.2 与三元组损失函数的联系

三元组损失函数^[2]要求正例之间的距离要大于负例之间的距离，其表达式为：

$$f(x^a, x^p) - f(x^a, x^n) > \delta \quad (11)$$

式中： x^a 、 x^p 、 x^n 分别表示锚点(anchor)、正样本和负样本； δ 为一个可调节超参数。

pAUC 和三元组损失函数的主要区别有两点。首先，由式(5)知：

$$s_i - s_k > \delta \quad (12)$$

式中 s_i 由任意一对正例构成， s_k 由任意一对负例构成，即 pAUC 的相对约束是一个四元组。

其次，pAUC 能在大量的训练样本中挑选出有效的难例，而三元组损失函数实现起来有困难。

3 实验

3.1 数据集准备

如表 1 所示，使用了 4 个基准数据集进行实验。其中 CASIA^[11] 数据集作为训练集，它包含了 1 万多个身份，约 50 万张非限定环境下的人脸图片。测试集为 LFW^[12]、CFP-FP^[13]、AgeDB-30^[14] 和 UMDFaces^[15]。图片预处理方式采用了和文献[1,4,6]相同的方法，利用面部的 5 个关键点，将图片裁剪为 112×112 的大小。为保证严格的开集测试，移除了训练集和测试集中重合的身份。

3.2 实验设置

对于嵌入提取网络，使用常见的 CNN 网络架构，分别为 ResNet34、ResNet50 和 ResNet100^[16]；使用 Backbone-BN-Dropout-FC-BN 架构从图片提取 512 维嵌入特征。本实验使用深度学习框架 Pytorch 中的 Adam 和 SGD 优化器进行联合优化，并在 2 块 NVIDIA 2080Ti 上进行训练。初始学习率设置为 0.1，在第 150 000 次迭代时设为 0.01，第 250 000 次迭代时设为 0.001，第 300 000 次迭代时停止训练。每个训练批次中的样本数量设置为 512，权值衰减设置为 0.9，动量设置为 0.000 1。

文中对比了 5 种方法性能，分别为三元组损失^[2]、基于 softmax 的交叉熵损失 SphereFace^[6] (引入余弦损失) 和 CosFace^[4] (引入带间隔的余弦损失)、基于随机采样的 pAUC (pAUC-R) 和基于类中心学习的 pAUC (pAUC-C)。对于

表 1 训练和测试的人脸数据集

Table 1 Face datasets for training and testing

datasets	#identities	#images
CASIA ^[11]	10 575	494 414
LFW ^[12]	5 749	13 233
CFP-FP ^[13]	500	7 000
AgeDB-30 ^[14]	568	16 488
UMDFaces ^[15]	8 277	367 888

前 3 种方法, 直接使用本文中设置好的超参数; 对于后 2 种方法, 在 ResNet50 上进行参数选择, 其中 α 设置为 0, β 采用了 $[0.001, 1]$ 区间内多个值, δ 按照文献[7]中规律选择 0.4。

3.3 消融实验

如表 2 所示, 首先使用 CASIA 训练集和 ResNet50 探究 pAUC-R 和 pAUC-C 的 β 设置, 其中 $\delta = 0.4$ 。可以发现, pAUC 算法采用类中心学习的效果明显好于随机采样的方法, 由此证明类中心学习策略是有效的。此外还可以看出, 基于类中心学习的 pAUC 损失和辨识型损失(SphereFace、CosFace)具有很强的可比性, 且性能要优于同为验证型损失的 Triplet loss。在选择适当的超参数后, pAUC-C 性能可以达到所比较方法中的最优。

为进一步比较几种损失函数的性能, 用 CASIA 训练数据集和 ResNet100 进行训练, 测试集换为规模更大的 UMDFaces。其中 pAUC 的参数统一设置为 $\delta = 0.4$ 、 $\alpha = 0$ 、 $\beta = 0.001$ 。由图 4 可知, pAUC-C 相比于其他几种损失函数, 性能仍最优。另外, 将 pAUC 值进行归一化, 如表 3 所示, 可知 pAUC-C 相比于其他几种损失函数, 鲁棒性最强。

表 2 不同损失的验证结果(%)

loss functions	LFW	CFP-FP	AgeDB-30
pAUC-R($\beta = 0.001$)	97.68	91.86	88.75
pAUC-R($\beta = 0.01$)	97.81	92.11	89.62
pAUC-R($\beta = 0.1$)	97.75	91.81	88.82
pAUC-R($\beta = 1$)	96.12	88.98	87.93
pAUC-C($\beta = 0.001$)	99.54	95.52	94.88
pAUC-C($\beta = 0.01$)	99.48	95.37	94.57
pAUC-C($\beta = 0.1$)	99.51	95.45	94.49
pAUC-C($\beta = 1$)	98.75	90.67	90.12
Triplet(0.35)	98.98	91.90	89.98
SphereFace(1.35)	99.11	94.38	91.70
CosFace(0.35)	99.51	95.44	94.56




Fig.4 ROC curves of different loss functions on UMDFaces

图 4 在 UMDFaces 上测试所得 ROC 曲线

表 3 归一化受试者工作特征曲线下的部分面积(%)

$\alpha = 0, \beta = 0.001$	pAUC
pAUC-C	100.00
pAUC-R	93.24
Triplet(0.35)	94.87
SphereFace(1.35)	97.15
CosFace(0.35)	99.94

3.4 超参数分析

本小节主要探讨超参数对于 pAUC-C 性能的影响。实验中超参数 $\alpha = 0$ 、 $\beta = (0, 1]$ 、 $\delta = (0, 2]$ 。为快速验证几个超参数的效果, 将网络换为 ResNet34, 并只取训练的前 7 个 epochs。训练集仍为 CASIA, 测试集为 CFP-FP, 如表 4 所示。不难发现, β 控制的是 FPR 的范围, 它对 pAUC-C 的性能起着关键性的作用。当 $\beta < 0.1$ 时, 模型的性能比较稳定; 当 β 趋近于 1 时, 模型性能出现了明显下降; 当 $\beta = 1$ 时, 即为 AUC 优化。 $\beta < 0.1$ 时, 性能稳定是因为此时 pAUC-C 更加关注那些容易被错误分类的样本, 而不是那些对模型优化没有帮助的易分类样本。即, pAUC-C 的优化是一个难例挖掘过程。另外可以发现 $\delta \geq 0.4$ 比 $\delta = 0$ 的效果好, 即添加一个间隔项可以帮助增大类间距离。

4 结论

本文针对开集人脸识别任务提出了一种新的验证型损失函数 pAUC。同时, 提出的用类中心学习策略来构造样本对的方法极大地提高了 pAUC 损失训练模型的效率。在 5 个大规模非限定环境下的人脸数据集上的实验结果

表 4 pAUC-C 在 CFP-FP 上的验证结果(%)

	$\delta = 0$	$\delta = 0.4$	$\delta = 0.8$	$\delta = 1.2$	$\delta = 1.6$
$\beta = 0.001$	81.50	92.23	91.11	91.24	89.54
$\beta = 0.01$	83.71	92.59	91.65	91.43	90.60
$\beta = 0.1$	83.59	91.05	89.50	89.48	88.85

表明,提出的方法和目前性能最优的人脸识别方法相比,具有很强的竞争性。

参考文献:

- [1] DENG Jiankang, GUO Jia, XUE Niannan, et al. ArcFace: additive angular margin loss for deep face recognition[C]// 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Long Beach, CA, USA: IEEE, 2019: 4685–4694.
- [2] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: a unified embedding for face recognition and clustering[C]// 2015 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Boston, MA, USA: IEEE, 2015: 815–823.
- [3] SUN Yi, WANG Xiaogang, TANG Xiaoou. Deep learning face representation by joint identification–verification[EB/OL]. (2014–06–18). <https://doi.org/10.48550/arXiv.1406.4773>.
- [4] WANG Hao, WANG Yitong, ZHOU Zheng, et al. CosFace: large margin cosine loss for deep face recognition[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 5265–5274.
- [5] ZHANG Kaipeng, ZHANG Zhanpeng, LI Zhifeng, et al. Joint face detection and alignment using multitask cascaded convolutional networks[J]. IEEE Signal Processing Letters, 2016, 23(10): 1499–1503.
- [6] LIU Weiyang, WEN Yandong, YU Zhiding, et al. SphereFace: deep hypersphere embedding for face recognition[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Honolulu, HI, USA: IEEE, 2017: 6738–6746.
- [7] BAI Zhongxin, ZHANG Xiaolei, CHEN Jingdong. Partial auc optimization based deep speaker embeddings with class–center learning for text–independent speaker verification[C]// 2020 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). Barcelona, Spain: IEEE, 2020: 6819–6823.
- [8] GENTILE C, WARMUTH M K. Linear hinge loss and average margin[C]// Proceedings of the 11th International Conference on Neural Information Processing Systems. Denver, CO: MIT Press, 1998: 225–231.
- [9] WEN Yandong, ZHANG Kaipeng, LI Zhifeng, et al. A discriminative feature learning approach for deep face recognition[C]// Computer Vision–ECCV 2016. Amsterdam, The Netherlands: Springer, 2016: 499–515.
- [10] ZHANG Xiao, FANG Zhiyuan, WEN Yandong, et al. Range loss for deep face recognition with long–tailed training data[C]// 2017 IEEE International Conference on Computer Vision(ICCV). Venice, Italy: IEEE, 2017: 5419–5428.
- [11] YI Dong, LEI Zhen, LIAO Shengcai, et al. Learning face representation from scratch[EB/OL]. (2014–11–28). <https://doi.org/10.48550/arXiv.1411.7923>.
- [12] HUANG G B, MATTAR M, BERG T, et al. Labeled faces in the wild: a database for studying face recognition in unconstrained environments[C]// Workshop on Faces in 'Real–Life' Images: Detection, Alignment, and Recognition. Marseille, France: HAL, 2008: inria–00321923.
- [13] SENGUPTA S, CHEN Juncheng, CASTILLO C, et al. Frontal to profile face verification in the wild[C]// 2016 IEEE Winter Conference on Applications of Computer Vision(WACV). Lake Placid, NY, USA: IEEE, 2016: 1–9.
- [14] MOSCHOLOU S, PAPAIOANNOU A, SAGONAS C, et al. AgeDB: the first manually collected, in–the–wild age database[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition Workshops(CVPRW). Honolulu, HI, USA: IEEE, 2017: 1997–2005.
- [15] BANSAL A, NANDURI A, CASTILLO C D, et al. UMDFaces: an annotated face dataset for training deep networks[C]// 2017 IEEE International Joint Conference on Biometrics(IJCB). Denver, CO, USA: IEEE, 2017: 464–473.
- [16] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR). Las Vegas, NV, USA: IEEE, 2016: 770–778.

作者简介:

唐林瑞泽(1997–), 男, 在读博士研究生, 主要研究方向为模式识别与智能系统. email: lrztang@mail.nwpu.edu.cn.

张晓雷(1983–), 男, 博士, 教授, 博士生导师, 主要研究方向为模式识别与智能系统.

白仲鑫(1991–), 男, 在读博士研究生, 主要研究方向为模式识别与智能系统.