

基于模约束 CentreFace 的低分辨率人脸识别

范文豪¹, 吴晓富¹, 张索非²

(1. 南京邮电大学 通信与信息工程学院, 江苏 南京 210003;

2. 南京邮电大学 物联网学院, 江苏 南京 210003)

摘要: 人脸识别(face recognition, FR)是计算机视觉领域中研究最广泛的问题之一,随着深度学习的发展使得一般条件下的人脸识别取得了巨大的进展并已大量商用。现有的FR系统已经在某些约束环境下实现了令人满意的识别精度。然而,低分辨率条件下的人脸识别(low-resolution face recognition, LRFR)目前仍然是一个极具挑战性的问题。在低分辨率人脸识别中,人脸图像通常是在非理想条件下捕获的,现有的人脸识别方法识别效果并不理想。为了提高识别精度,面向低分辨率人脸识别,基于CentreFace算法的损失函数进一步提出一种模损失函数用于联合训练。研究表明:该模损失函数可以在保持特征类内距离的情况下,增大类间距离,提高模型的泛化能力。最终在QMUL-SurvFace数据集上进行的4组分析对比实验表明:基于模约束的CentreFace算法识别精度优于CentreFace算法。

关键词: 人脸识别;低分辨率;QMUL-SurvFace;CentreFace;模损失

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2021)05-0048-06

doi:10.3969/j.issn.1673-629X.2021.05.009

Low-resolution Face Recognition Based on Modular Constraint CentreFace

FAN Wen-hao¹, WU Xiao-fu¹, ZHANG Suo-fei²

(1. School of Communication and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;

2. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: Face recognition (FR) is one of the most extensively investigated problems in the field of computer vision. The development of deep learning has made great progress in face recognition under general conditions and has been commercialized in large quantities. In recent years, existing FR systems have already achieved a satisfactory recognition accuracy under environments with certain constraints. However, the low-resolution face recognition remains a challenging problem. In low-resolution face recognition, face images are normally captured under non-ideal conditions. The existing FR methods are not ideal. In order to improve the accuracy of low-resolution face recognition, we further propose a norm loss function based on CentreFace algorithm for joint supervision. The research shows that norm loss function can increase the distance of intra-class while maintaining the distance of inter-class, so that it can improve the generalization ability of the model. Finally, four sets of analysis and comparison experiments on the QMUL-SurvFace dataset show that the CentreFace algorithm based on norm constraints has better recognition accuracy than the CentreFace algorithm.

Key words: face recognition; low resolution; QMUL-SurvFace; CentreFace; norm loss

0 引言

近年来,人脸识别^[1]问题引起了越来越多研究人员的关注。在具有一定约束环境下的人脸识别问题,它们的识别精度已经取得了极大的提高。然而,低分辨率人脸识别问题在人脸识别领域仍然具有挑战性。在人口较稠密的公共场所^[2-3],例如购物商场和游乐园,通常需要通过从监控视频中获得的图像来寻找具

有特殊身份的人。但是,由于行人与监控摄像头之间距离较远以及摄像头的分辨率有限,通常只能获得较低分辨率的人脸图像。在这种情况下捕获的人脸经常是模糊的、光照不均匀的或人脸姿势^[4]不正确的,这些干扰因素使得基于深度模型和预处理的技术(例如人脸正面化和人脸对齐),不能直接应用于低分辨率的人脸图像^[5]。

收稿日期:2020-01-13

修回日期:2020-05-14

基金项目:国家自然科学基金(61372123, 61701252)

作者简介:范文豪(1995-),男,硕士研究生,通信作者,研究方向为深度学习与计算机视觉;吴晓富,博士,教授,研究方向为信息论与编码、机器学习与计算机视觉、密码学与信息安全。

对于人脸识别中的低分辨率问题,已经有了许多解决方法。这些方法大多数基于超分辨率(super resolution, SR)技术^[6-7]来尝试提高图像的质量,将复原后的较高分辨率图像用于人脸识别。尽管基于深度学习的 SR 技术使得重建后的图像在主观图像质量评价指标上取得了较好的评分,但重建后的图像通常过于平滑,会丢失高频细节信息。当图像的分辨率非常低时,通常会出现上述情况,导致恢复的高分辨率图像和低分辨率图像差异明显,识别性能显著下降。

为了提高低分辨率人脸识别的准确率,该文针对低分辨率人脸识别问题对 CentreFace 方法进行了改进。主要的改进包括以下三个方面:(1)提出新的模损失函数与原来的损失函数进行联合训练,以学习在类内距离不变的情况下,具有更大类间距离的人脸识别模型;(2)在训练过程中,随机更改输入图像的亮度,以进行数据增强;(3)改进了传统 CentreFace 中模型的训练方法,能够使模型收敛的效果更好。实验结果证明,改进方案可以有效地解决 CentreFace 方法中的不足,使得在低分辨率人脸识别问题中具有更好的识别精度。

1 相关工作

低分辨率人脸识别是一种特殊的人脸识别问题,用于解决这类的方法可以大致概括为两种:一种是图像的超分辨率技术,另一种是图像分辨率不变的学习方法。第一种方法主要采用超分辨率和去模糊技术,将输入的低分辨率人脸图像转换为对应的高分辨率人脸图像,从而可以采用高分辨率人脸识别(HRFR)技术。第二种方法旨在学习分辨率不变图像的人脸特征。在许多论文中都对第一种方法进行了尝试,但是从结果来看使用这种方法对识别精度的提升并不明显。

为了获得具有高度区分性的人脸特征,近年来提出了一系列新的深度学习人脸识别方法,例如 DeepID2^[8]、FaceNet^[9]、CentreFace^[1]、SphereFace^[10]和 ArcFace^[11]等,这些方法在解决高分辨率人脸识别问题时通常能够表现出良好的性能。2014 年提出的 DeepFace 和 DeepID 系列主要是先训练 Softmax 多分类器;然后抽取特征层,用特征再训练另一个神经网络、孪生网络或组合贝叶斯等人脸验证框架。2015 年 FaceNet 提出了一个绝大部分人脸问题的统一解决框架,直接学习嵌入特征,然后人脸识别、人脸验证和人脸聚类等都基于这个特征来做。FaceNet 在 DeepID2 的基础上,抛弃了分类层,再将 Contrastive Loss 改进为 Triplet Loss,获得更好的类内紧凑和类间差异。但人脸三元组的数量出现爆炸式增长,特别是对于大型

数据集,迭代次数显著增加;导致样本挖掘方法使得很难有效地进行模型的训练。2016 年提出的 Center Loss 为每个类别学习一个中心,并将每个类别的所有特征向量拉向对应类别中心,根据每个特征向量与其类别中心之间的欧几里得距离,以获得类内紧凑度;而类间分散则由 Softmax Loss 的联合训练来保证。然而,在训练期间更新实际类别中心非常困难,因为可供训练的人脸类别数量急剧增加。2017 年 SphereFace 提出 A-Softmax,是 L-Softmax 的改进,提出了角度间隔损失,又归一化了权值 W ,让训练更加集中在优化深度特征映射和特征向量角度上,降低样本数量不均衡问题。2018 年 ArcFace 提出加性角度间隔损失, $\theta + m$,还归一化特征向量和权重,几何上有恒定的线性角度 margin。直接优化弧度,为了模型性能的稳定, ArcFace 不需要与其他损失函数联合监督。

在 QMUL_SurvFace 论文中,采用了五种不同的人脸识别方法实现监控下低分辨率人脸识别挑战。但是仅使用论文中提出的 QMUL_SurvFace 数据集进行训练时,并不是所有的 FR 模型都可以达到收敛。然而,五种不同的 FR 模型都可以在 CASIA 数据上成功训练并收敛。在所有这些 FR 方法中,使用 CASIA 和 QMUL_SurvFace 数据集进行训练的 CentreFace 模型,可以在 QMUL_SurvFace 基准测试上得到最佳 Rank1 识别率为 25.8%。因此,该文针对低分辨率人脸识别问题对 CentreFace 方法进行一系列改进。同时,还与其他较好的 FR 方法进行了比较。

2 CentreFace 方法介绍及改进

2.1 CentreFace 介绍

在本节中,首先简单介绍一下 CentreFace 方法,然后指出 CentreFace 在用于低分辨率人脸识别问题时的一些缺陷,接着对 CentreFace 方法提出一系列的改进。

通常, CentreFace 采用尺寸为 112×112 的 RGB 图像作为输入,并将输入图像像素大小压缩至 $[-1, 1]$ 。将参数 N 设置为模型训练时输入的 batch 大小,然后使用具有不同结构的 CNN 模型作为骨干网络从人脸图像中提取深度特征进行分类。模型的输出是尺寸为 d 的脸部特征向量,可以使用 x_n 表示。为了对特征向量进行分类,在网络的最后添加了一个全连接层用于计算 logits。全连接层中参数 W 的尺寸为 $d \times M$, M 为训练集中类别数量。

在训练过程中,采用 Softmax 损失函数来监督类间特征向量进行分离,可表示为:

$$L_s = - \sum_{n=1}^N \log \frac{e^{W_{i_n}^T x_n + b_{i_n}}}{\sum_{m=1}^M e^{W_{i_m}^T x_n + b_{i_m}}}$$

其中, x_n 表示第 n 个特征向量^[12-13], y_n 是对应于 x_n 的类别, W_m 表示最后全连接层权重 W 的第 m 列, b 是偏差(可省略), N 是 batch 大小, M 是训练集种类个数。Softmax 损失函数确保可以通过决策边界来区分学习到的不同类别的深度特征。

如果仅使用 Softmax 损失函数进行训练,虽然可以在训练过程中很好地区分不同类别的特征向量,但最终的测试结果会很差,因为类间不够紧凑。所以加入中心损失函数来减少类内距离,可表示如下:

$$L_C = \frac{1}{2} \sum_{n=1}^N \|x_n - c_{y_n}\|_2^2$$

其中, c_{y_n} 表示 y_n 类的中心特征向量,它应随着训练数据的不断更新而变化。在对 c_{y_n} 进行更新时,有两点需要注意。首先,每次更新 c_{y_n} 时不是基于整个数据集而是基于当前的小批量训练集进行更新。在迭代过程中,每个类中心点的变化取决于这个 batch 中相应类的特征向量的均值。在这种情况下,每次进行迭代时,并不是所有中心点都会进行更新,因为每个 batch 中经常不能包含所有的类。其次,为了避免由少量错误标记的样本引起的大扰动,需要使用一个小的常量来控制中心向量的学习率。要对 c_{y_n} 进行更新,需要计算 L_C 相对于 x_n 的梯度, c_{y_n} 的更新步骤如下:

$$\Delta c_m = \frac{\sum_{n=1}^N \delta(y_n = m) \cdot (c_m - x_n)}{1 + \sum_{n=1}^N \delta(y_n = m)}$$

$$c_m^{t+1} = c_m^t - \alpha \cdot \Delta c_m^t$$

中心损失函数可以在保持不同类的特征可分离的情况下,最大程度地减少特征的类内距离。在算法描述中,总结了联合监督^[14]下 CentreFace 训练步骤和细节。


2.2 CentreFace 缺陷及改进

在本节中,将会指出 CentreFace 应用于低分辨率人脸识别问题时的两个缺点,并针对这两个问题加以改善。首先,如果仅使用 Softmax 损失函数和中心损失函数来训练模型,会发现中心损失函数的值在训练过程中会不断减小,但是各类的中心点到原点的距离也在不断减小,这意味着类内和类间距离都减小了,这种现象并不能证明中心损失函数的减少对于分类效果是有利的。更加直观的解释可以参考图 1(a),在这种情况下,类内距离的减少对于分类是没有作用的。为了改进 CentreFace 这一缺点,在 Softmax 损失函数和中心损失函数的基础上又添加了一个模损失函数,在保持类内距离的情况下,增加类间距离。提出的模损失函数表示如下:


$$L_N = - \frac{\sum_{m=1}^M \|c_m\|_2}{M}$$

其中, L_N 损失表示每个类中心点到原点 O 的平均距离。在总的损失函数中加入 L_N 是为了防止在训练期间随着类内距离的减少,类间距离也随之减少。模损失函数的影响如图 1(b) 所示。采用 Softmax 损失、中心损失和模损失的联合监督来训练判别特征学习模型。总的损失函数如下:

$$L = L_S + \lambda_1 L_C + \lambda_2 L_N$$



(a) 加入模损失前可能存在的特征分布图



(b) 加入模损失后的特征分布图

图 1 特征分布

CentreFace 算法中训练步骤也可以进行优化。在训练方法中,由于 step 6 位于 step 7 之前,因此在执行时应先更新参数 c_m 再更新参数 θ_c 。但是当计算总的损失函数 L^{t+1} 时,会发现 x_n^{t+1} 中的参数 θ 是 $t+1$ 时刻的 θ_c^{t+1} ,而 c_m^{t+1} 中的参数 θ 是 t 时刻的 θ_c^t 。这将导致在训练过程中中心损耗的收敛速度变慢。但是,如果调整训练方法中 step 6 和 step 7 的顺序,则 x_n^{t+1} 和 c_m^{t+1} 中的参数 θ 都将为 θ_c^{t+1} ,中心损失函数的收敛效果将比之前更好。

参数初始化和训练方法:

参数:

首先初始化卷积层中的参数 θ_c ,全连接层中的参数 W ,和每个类的中心点 $\{c_m | m = 1, 2, \dots, M\}$,设置超参数 $\lambda_1, \lambda_2, \alpha$ 和学习率 μ^t ,迭代次数 $t \leftarrow 0$ 。

训练步骤:

1: while not converge do

2: $t \leftarrow t + 1$

3: 计算总的损失函数 $L^t = L_S^t + \lambda_1 L_C^t + \lambda_2 L_N^t$

4: 计算反向传播梯度: $\frac{\partial L^t}{\partial x_n^t} = \frac{\partial L_S^t}{\partial x_n^t} + \lambda_1 \frac{\partial L_C^t}{\partial x_n^t} + \lambda_2 \frac{\partial L_N^t}{\partial x_n^t}$

5: 更新参数 W : $W^{t+1} = W^t - \mu^t \cdot \frac{\partial L^t}{\partial W^t} = W^t - \mu^t \cdot \frac{\partial L_S^t}{\partial W^t}$

6: 更新参数 c_m : $c_m^{t+1} = c_m^t - \alpha \Delta c_m^t$

7: 更新参数 θ_c : $\theta_c^{t+1} = \theta_c^t - \mu^t \sum_n \frac{\partial L^t}{\partial x_n^t} \cdot \frac{\partial x_n^t}{\partial \theta_c^t}$

8: end while

3 实验与分析

在本节中,首先介绍作为低分辨率人脸识别问题

的基准数据集 QMUL_SurvFace。然后,在该数据集上进行四组对比实验。通过实验结果证明对 CentreFace 方法进行改进的有效性。

3.1 数据集介绍

为了能促进更多的研究人员来开发有效且鲁棒的人脸识别方法来解决低分辨率人脸识别问题,一个新的监控下人脸识别挑战在论文中有所介绍,该挑战称为 QMUL_SurvFace。这一新挑战是目前最大的且唯一一个真实的监控下人脸识别问题。在该挑战中,低分辨率人脸图像是由监控摄像头拍摄得到,而不是通过对高分辨率图像的人工下采样来合成的。数据分布可见表 1。QMUL_SurvFace 数据集包含 463 507 张低分辨率面部图像,这些图像来自于 15 573 个不同的人。在数据集中,人脸图像有着不同的姿势、遮挡、背景、亮度,且伴随着一些运动造成的模糊和其他干扰因素。其中有 10 638 (68.3%) 个人有两张以上的人脸图像。10 638 个人分为两部分:其中一半(5 319)作为训练数据,另一半(5 319)加上剩余的 4 935 (总计 10 254)作为测试数据。QMUL-SurvFace 数据集中人脸图像的分辨率非常低,这使得监控下的人脸识别任务非常具有挑战性。面部的空间分辨率的长度/宽度范围为 6/5 至 124/106 像素,平均值为 24/20。由于分辨率太低,导致人脸检测操作不能检测出 QMUL-SurvFace 数据集中所有图像中的人脸,人脸对齐^[15-16]操作也就无法进行。

表 1 QMUL_SURFFACE 挑战数据集划分

Split	All	Training	Number
IDs	15 573	5 319	10 254
Images	463 507	220 890	242 617
	(1 ~ 558)	(2 ~ 558)	(1 ~ 482)

3.2 网络模型

文中使用的网络模型以 34 层和 50 层的 ResNet 为主,具体参见表 2。fc1 层的输出是输入人脸图像所提取到的特征向量。fc2 层的输出向量的维数为训练数据集种类数,以 QMUL_SurvFace 数据集为例,网络模型输出维数为 5 319,网络输入图像的尺寸为 112×112。为了分析提取到的特征维度对结果的影响,对比实验中分别提取人脸图像的 256 维和 350 维的特征向量进行对比。对于数据预处理部分,会将所有面部图像的大小调整为 112。即使图像的大小发生了改变但基本分辨率改变不大,因此仍将这些调整大小后的图像视为低分辨率图像。通过观察 QMUL_SurvFace 数据集,发现来自同一身份的人脸图像的亮度经常变化很大。因此在数据预处理期间,会随机改变面部图像的亮度以作为数据增强。

表 2 34 层和 50 层 ResNet 网络结构

输出尺寸	34-layers	50-layers
conv0 (None,112,112,-1)	[3,3,16]	[3,3,64]
conv1 (None,56,56,-1)	$\begin{bmatrix} 3 & 3 & 16 \\ 3 & 3 & 16 \end{bmatrix} \times 3$	$\begin{bmatrix} 3 & 3 & 64 \\ 3 & 3 & 64 \end{bmatrix} \times 3$
conv2 (None,28,28,-1)	$\begin{bmatrix} 3 & 3 & 32 \\ 3 & 3 & 32 \end{bmatrix} \times 4$	$\begin{bmatrix} 3 & 3 & 128 \\ 3 & 3 & 128 \end{bmatrix} \times 4$
conv3 (None,14,14,-1)	$\begin{bmatrix} 3 & 3 & 128 \\ 3 & 3 & 128 \end{bmatrix} \times 6$	$\begin{bmatrix} 3 & 3 & 256 \\ 3 & 3 & 256 \end{bmatrix} \times 14$
conv4 (None,7,7,-1)	$\begin{bmatrix} 3 & 3 & 256 \\ 3 & 3 & 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 3 & 3 & 512 \\ 3 & 3 & 512 \end{bmatrix} \times 3$
fc1 (None,350)	[7 * 7 * 256,350]	
fc2 (None,5 319)	[350,5 319]	

3.3 对比实验和结果分析

在所有实验中,会将 QMUL-SurvFace 数据集中的所有人脸图像调整为所需的大小 112,然后对图像中每个像素减去 127.5 除以 128,从而将像素值压缩至 $[-1,1]$ 。在 CentreFace 算法中,设置参数 $\lambda_1 = 0.005$, $\lambda_2 = 0.2$, $\alpha = 0.5$ 。为了对 closed-sets 数据集识别的性能进行评估,选择广泛使用的度量:累积匹配特征(cumulative matching characteristic, CMC)曲线。receiver operating characteristic(ROC)曲线同 CMC 一样,是模式识别系统,如人脸、指纹、虹膜等的重要评价指标,尤其是在生物特征识别系统中,一般同 ROC 曲线一起给出,能够综合评价出算法的好坏。CMC 曲线综合反映了分类器的性能,它评价的指标与深度学习当中常用的 top1 err 和 top5 err 评价指标意思一样,不同的是横坐标的 Rank 表示正确率而不是错误率。其中 Rank-1 的比率是最常见的评价指标。Rank-r 的 CMC 定义如下:

$$\text{CMC}(r) = \sum_{i=1}^r \frac{N_{\text{mate}}(i)}{N}$$

其中, $N_{\text{mate}}(i)$ 表示匹配在 Rank-i 处的 probe 图像数量, N 表示 probe 中的类别数。在以下实验中,使用 Rank-1 作为评价指标^[17]。

不同训练方法:在第一组对比实验中,网络模型采用 34 层 ResNet,提取到的人脸特征向量维数为 256。分别采用文中提出的改进后和改进前的训练方法^[9]进行训练,可以获得两条损失函数曲线。损失函数曲线如图 2, Rank-1 识别率可见表 3。比较两条曲线可以发现,图 2(a) 的 loss 函数曲线收敛于值 1.45,图 2(b) 的 loss 函数曲线收敛于值 1.3,说明改进后的训练方法有助于以更快的速度收敛且收敛后的中心损失更小。

不同网络和特征维度的影响:在第二组对比实验

中,分别采用 34 层 ResNet 和 50 层 ResNet 的网络模型,且提取了不同维度的特征向量。实验结果见表 4,从中可以发现,当网络模型为 50 层 ResNet,特征向量维数为 350 时可以获得最佳结果。

预处理加入数据增强:在第三组对比实验中,在数据预处理期间随机更改人脸图像的亮度。仍然使用 34 层 ResNet 和 50 层 ResNet,提取到的特征向量维度是 350。实验结果见表 5,可以发现,数据预处理阶段采用数据增强可以极大地提高人脸的识别性能。

模损失函数联合监督:在第四组对比实验中,根据上述对比实验中的最佳结果进行了进一步的实验。将模损失函数添加到总的损失函数中,将三个损失函数结合起来进行联合训练。首先,计算每个类别中的点到该类别的中心点的距离,以及从所有类别的中心点到原点 O 的距离。距离分布如图 3 所示。发现在加上模损失函数后,各类中心点到原点 O 的距离大约增加了一倍,但是每个类中的点到中心点的距离分布和未添加之前相当接近。从图中可以看出,模损失可以在保持类内距离的同时增加类间距离。从表 6 中可以看出,提出的模损失函数给 Rank-1 的识别率带来了进一步的提高。

表 3 不同训练方法下的 Rank-1 识别率 %

方法	ResNet-34
改进前训练方法	27.294
改进后训练方法	27.688

表 4 不同网络结构和特征维度下的

Rank-1 识别率 %		
特征维度	ResNet-34	ResNet-50
256	27.688	28.267
350	28.383	28.945

表 5 数据增强对 Rank-1 识别率的影响 %

	ResNet-34	ResNet-50
无数据增强	28.383	28.945
添加数据增强	29.457	29.972

表 6 添加模损失函数对 Rank-1 识别率的影响 %


	ResNet-50
Softmax+center loss	29.972
Softmax+center+模 loss	30.403

在以上四组实验中,仅使用 QMUL_SurvFace 数据集来训练模型,最佳的 Rank-1 识别率为 30.403%。与文中使用 CASIA 和 QMUL_SurvFace 图像训练模型的最佳 Rank-1 识别率相比,实验结果中的最佳 Rank-1 识别率更高。这意味着改进后的 CentreFace 比原始的 CentreFace 效果更好。此外,还在 QMUL_SurvFace


数据集中测试了最新的 ArcFace 方法的性能。为了便于进行比较,实验中仍然使用 50 层的 ResNet,提取的特征向量维度为 350。将 ArcFace 中尺度因子 s 设置为 64,参数 m 设置为 0.5。在实验中也仅使用 QMUL-SurvFace 数据集来训练所构建的模型,但得到的 Rank-

表 7 不同 FR 方法的 Rank-1 识别率

训练数据集	CASIA+QMUL_SurvFace	QMUL_SurvFace
网络结构	28-layers ResNet	50-layers ResNet
SphereFace	22.1 %	-
ArcFace	-	24.987 %
改进前 CentreFace	25.8 %	-
改进后 CentreFace	-	30.403 %




(a) 训练方法改进前中心损失函数曲线




(b) 训练方法改进后中心损失函数曲线


图 2 中心损失函数曲线



(a) 两种情况下各类中心点到原点 O 的距离的分布图



(b) 未添加模损失情况下各类中的点到中心点的距离的分布图



(c) 添加模损失后各类中的点到中心点的距离的分布图

图3 距离分布

1 识别率仅为 24.987%。在表 7 中,对原始 CentreFace,改进后的 CentreFace, SphereFace 和 ArcFace 的实验结果进行了比较。

4 结束语

提出了一种模损失函数并将该损失与 Softmax 损失和中心损失相加,三种损失函数联合监督进行训练。相比于仅使用 Softmax 损失和中心损失,加入的模损失函数可以在保持特征类内距离不变的情况下,增大类间距离,从而增强网络模型对特征的判别能力。此外,还对 CentreFace 的训练方法做了一些改进,通过调整训练步骤来更好地进行参数更新优化,最终中心损失函数值可以收敛得更好。在基准人脸数据集上的实验结果表明,改进的 CentreFace 在低分辨率人脸识别任务上的识别精度要优于之前的 CentreFace 以及其他先进的人脸识别方法。

参考文献:

[1] WEN Y, ZHANG K, LI Z, et al. A discriminative feature learning approach for deep face recognition[C]//European conference on computer vision. Amsterdam, The Netherlands: Springer, 2016: 499–515.

[2] DE-LA-TORRE M, GRANGER E, SABOURIN R, et al. Adaptive skew-sensitive ensembles for face recognition in video surveillance[J]. Pattern Recognition, 2015, 48(11): 3385–3406.

[3] RADTKE P V W, GRANGER E, SABOURIN R, et al. Skew-sensitive boolean combination for adaptive ensembles—an application to face recognition in video surveillance[J]. Information Fusion, 2014, 20: 31–48.

[4] DRIRA H, AMOR B B, SRIVASTAVA A, et al. 3D face recognition under expressions, occlusions, and pose variations[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(9): 2270–2283.

[5] 王智飞. 低分辨率人脸识别算法研究[D]. 北京: 北京交通大学, 2013.

[6] 苏衡, 周杰, 张志浩. 超分辨率图像重建方法综述[J]. 自动化学报, 2013, 39(8): 1202–1213.

[7] 江静, 张雪松. 图像超分辨率重建算法综述[J]. 红外技术, 2012, 34(1): 24–30.

[8] SUN Y, WANG X, TANG X. Deep learning face representation by joint identification-verification[J]. Advances in neural Information Processing Systems, 2014, 27: 1988–1996.

[9] SCHROFF F, KALENICHENKO D, PHILBIN J. FaceNet: a unified embedding for face recognition and clustering[J]. Proceedings of the IEEE conference on computer vision and pattern recognition. Boston, MA, USA: IEEE, 2015: 815–823.

[10] LIU W, WEN Y, YU Z, et al. Sphreface: deep hypersphere embedding for face recognition[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu, HI, USA: IEEE, 2017: 212–220.

[11] PARKHI O M, VEDALDI A, ZISSERMAN A. Deep face recognition[C]//Proceedings of the British machine vision conference. [s. l.]: [s. n.], 2015: 1–12.

[12] LU X, DUAN X, MAO X, et al. Feature extraction and fusion using deep convolutional neural networks for face detection[J]. Mathematical Problems in Engineering, 2017(2017pt. 1): 1376726. 1–1376726. 9.

[13] RANJAN R, SANKARANARAYANAN S, CASTILLO C D, et al. An all-in-one convolutional neural network for face analysis[C]//2017 12th IEEE international conference on automatic face & gesture recognition. [s. l.]: IEEE, 2017: 17–24.

[14] 余成波, 田桐, 熊递恩, 等. 中心损失与 Softmax 损失联合监督下的人脸识别[J]. 重庆大学学报, 2018, 41(5): 92–100.

[15] 董兰芳, 张军挺. 基于 Faster R-CNN 的人脸检测方法[J]. 计算机系统应用, 2017, 26(12): 262–267.

[16] ZHANG K, ZHANG Z, LI Z, et al. Joint face detection and alignment using multitask cascaded convolutional networks[J]. IEEE Signal Processing Letters, 2016, 23(10): 1499–1503.

[17] 陈绵书, 陈贺新, 桑爱军. 计算机人脸识别技术综述[J]. 吉林大学学报: 信息科学版, 2003, 21(5): 101–109.