

基于深度学习与多哈希相似度加权实现快速人脸识别

邓良¹ 许庚林¹ 李梦杰¹ 陈章进^{1,2}

1 上海大学微电子研究与开发中心 上海 200444

2 上海大学计算机中心 上海 200444

(1593481663@qq.com)

摘要 无论是使用传统的方法进行人脸识别,还是使用神经网络进行人脸识别,都存在运算量大、运算时间长等问题,很难对视频中的人脸进行实时检测与匹配。针对上述问题,使用轻量化神经网络进行人脸检测,使用运算简单的哈希算法计算人脸图像相似度,并对多个哈希相似度值加权进行人脸匹配,是减少运算时间、实现快速人脸识别的可行方案。使用轻量化神经网络 Mobilenet 作为人脸特征提取网络,使用剪枝的 SSD 模型作为检测网络,通过级联 Mobilenet 与 SSD 实现人脸的检测,之后对检测到的人脸图像进行识别。首先,分别计算人脸图像的均值哈希相似度与感知哈希相似度。然后,分别使用 α 和 β 作为均值哈希与感知哈希的加权系数对图像的均值哈希与感知哈希相似度值进行加权,并将结果作为图像的最终相似度。当加权后的相似度值大于设定的阈值 I 时,则认为两张图像中的人脸是同一个人;当加权后的相似度值小于设定的阈值 K 时,则认为两张图像中的人脸是不同的人。对于相似度处于阈值 I 和阈值 K 之间的图像,将它们按照相似度值从高到低的顺序择优匹配。所提方法在 WiderFace 和 FDDB 上的人脸检测准确率分别达到 92.5% 和 94.2%, 每张图片的平均处理时间为 56 ms; 在 ORL 标准人脸库进行人脸匹配的准确率达到 96.2%。使用摄像头进行实时人脸识别测试时,所提方法的人脸识别准确率为 95%, 平均人脸识别速度为 80 ms。实验证明,所提方法在保证较高准确率的前提下,能够实现实时的人脸检测与匹配。

关键词: 人脸检测;深度学习;哈希算法;人脸匹配

中图分类号 TP183

Fast Face Recognition Based on Deep Learning and Multiple Hash Similarity Weighting

DENG Liang¹, XU Geng-lin¹, LI Meng-jie¹ and CHEN Zhang-jin^{1,2}

1 Microelectronics Research and Development Center, Shanghai University, Shanghai 200444, China

2 Computer Center, Shanghai University, Shanghai 200444, China

Abstract Whether using the traditional method or neural network for face recognition, there are problems of large computation and long computation time. It is difficult to detect and match the faces in the video in real time. Aiming at the above problems, lightweight neural network is used for face detection, simple hash algorithm is used to calculate the similarity of face images, and multiple hash similarity values are weighted for face matching. It is a feasible scheme to reduce computation time and realize fast face recognition. The lightweight neural network Mobilenet is used as the face feature extraction network, and the pruned SSD model is used as the detection network. The face detection is realized by cascading Mobilenet and SSD, and then the detected face image is recognized. Firstly, the mean hash similarity and the perceived hash similarity of the face images are calculated separately. Then, taking α and β as weighted coefficients of the mean hash and the perceived hash respectively, the mean hash and perceived hash similarity value of the image are weighted, and the result is taken as the final similarity of the image. When the weighted similarity value is greater than the set threshold I , it is considered to be the same person. When the weighted similarity value is less than the set threshold K , it is considered to be a different person. For images whose similarity is between thresholds I and K , they are optimally matched in order of similarity values from high to low. The face detection accuracy rate of the proposed method on WiderFace and FDDB reaches 92.5% and 94.2% respectively, and the average processing time per image is 56ms. The accuracy of face matching in the ORL standard face database reaches 96.2%. When camera is used for real-time face recognition test, the face recognition accuracy of the proposed method is 95%, and the average face recognition speed is 80ms. It has been proved by experiments that real-time face detection and matching can be realized under the premise of ensuring high accuracy.

Keywords Face detection, Deep learning, Hash algorithm, Face matching

收稿日期:2019-09-18 返修日期:2020-01-04 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61674100)

This work was supported by the National Natural Science Foundation of China (61674100).

通信作者:陈章进(zjchen@shu.edu.cn)

1 引言

人脸识别作为一项重要的生物信息识别技术,在监控、安防、商场客户认证、自助服务等领域都有着非常广泛的应用^[1]。人脸识别技术主要包含两个关键步骤:人脸检测与人脸匹配。早期的算法有基于几何特征的算法^[2]、基于模板匹配的算法^[3]和子空间算法^[4]等多种类型。主成分分析(Principal Component Analysis, PCA)算法^[5]是常用的人脸识别算法。后期出现了“人脸特征提取+分类器”实现人脸识别^[6]的方法,但是传统的人脸特征提取算法需要对整个图像进行遍历来确定特征点,运算量大,且时间复杂度,不能满足实时性的要求。基于卷积神经网络的检测器具有强大的特征提取能力,因此使用神经网络进行图像特征提取也取得了不错的效果。Ren等提出的FasterR-CNN^[7]检测网络,在目标检测方面取得了较好的性能。Redmon等提出的YOLO^[8]算法能够一次性预测多个目标框的位置和类别,实现了端到端的目标检测。随后,Liu等提出了SSD^[9]检测网络。相比于FasterR-CNN网络,SSD检测网络具有更快的运算速度,且精度较YOLO算法有所提高。但是,SSD检测网络前端的特征提取部分使用的是VGG^[10]模型,导致模型的整体计算量庞大,模型的实时性仍然不能满足实际需求。人脸匹配,实质上就是计算不同人脸图像之间的相似度。使用哈希算法进行图像相似度的计算是比较常用且快速的方法,主要包括均值哈希算法(aHash)、感知哈希算法(pHash)、梯度哈希算法(dHash)^[11-13]等。

本文使用轻量化的网络模型Mobilenet^[14]作为SSD检测模型的前端特征提取网络,同时对SSD检测网络进行剪枝。相比标准的SSD检测网络,本文模型只从前端特征提取网络中抽取两个不同尺寸的特征图进行人脸检测,缩短了模型的运算时间。同时针对使用单一哈希算法实现人脸匹配存在准确率和稳定性较低的问题,本文提出将均值哈希相似度值与感知哈希相似度值进行加权作为图像最终相似度值的方法,进行人脸图像的匹配,提高了人脸图像匹配的鲁棒性。

2 人脸识别

2.1 人脸检测算法

现有的人脸检测技术大致可以分为基于人工特征提取的传统方法与基于深度学习的自动特征提取两类。Viola等^[15]于2001年提出使用Haar-like特征并级联AdaBoost^[16]分类器检测人脸,使得人脸检测算法有了很大的改进。Ahonen等^[17]利用局部二值特征进行人脸检测并取得了不错的效果。Yang等^[18]提出通道特征(Aggregate Channel Features, ACF)算法,利用多通道的特征实现人脸检测。Ghiasi等^[19]提出高分辨率可变形部件模型(MultiresHPM),通过级联神经网络进行人脸检测与关键点定位。Li等^[20]在WIDER数据集上训练FasterR-CNN,并在FDDB数据集上进行了人脸检测测试。Zhang等^[21]提出多任务级联神经网络(Multi-task Convolutional Neural Network, MTCNN),利用三层级联神经网络实现人脸检测与对齐。2017年,Yang等^[22]提出了Faceness-Net模型,大大提高了使用深度学习进行人脸检测的准确率。

目前,主流的基于深度学习的人脸检测算法主要分为两种类型:Two-stage方法和One-stage方法^[23]。Two-stage的主要步骤是:先使用卷积神经网络对图像进行特征提取,之后通过级联神经网络产生若干个候选框,最后对这些候选框进行分类与回归^[24]。One-stage的主要思想是:首先使用神经网络提取输入图像的特征,同时在特征提取网络中多个层的特征图上进行密集抽样;然后利用抽取的特征图直接进行分类与回归。整个过程只需要一步就能输出结果^[25]。

2.2 使用哈希算法计算图像相似度

图像相似度比较是指对两张或多张图片的相似程度进行计算。使用哈希算法进行图片相似度比较是比较常用的方法。图像在处理过程中可被看作一个二维信号,图像哈希算法可以通过哈希函数将图像信号转化为若干个比特的二进制编码序列^[26]。主流的图像哈希算法有均值哈希算法、感知哈希算法等。

2.2.1 均值哈希算法

均值哈希算法主要利用图片的低频信息,其步骤如下。

- (1)缩小图像尺寸:将图像缩小到 8×8 的尺寸,共64个像素;
- (2)灰度化:将 8×8 的图像转为灰度图;
- (3)计算平均值:计算所有64个像素的灰度平均值;
- (4)比较像素的灰度:若每个像素的灰度值大于或等于灰度平均值,则结果记为1,否则记为0;
- (5)计算相似度:将64个二进制数串连起来作为图像的哈希值,并计算两张图片哈希值的汉明距离,得到相似度值。

2.2.2 感知哈希算法

感知哈希算法首先使用离散余弦变换^[27](Discrete Cosine Transform, DCT)将图像从像素域变化为频域,并保留其频率系数矩阵的左上角区域元素来计算图像的哈希值。图像离散余弦变换的公式为:

$$F(u, v) = c(u)c(v) \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} f(i, j) \cos\left[\frac{(i+0.5)\pi u}{N}\right] \cos\left[\frac{(j+0.5)\pi v}{N}\right] \quad (1)$$

$$c(u) = \begin{cases} \sqrt{\frac{1}{N}}, & u=0 \\ \sqrt{\frac{1}{N}}, & u \neq 0 \end{cases} \quad (2)$$

式(1)和式(2)描述了二维离散余弦正变换。其中, $f(i)$ 为原始的信号; $F(u)$ 是DCT变换后的系数; N 为原始信号的点数; $c(u)$ 可被认为是一个补偿系数,可以使DCT变换矩阵为正交矩阵。

感知哈希算法的具体步骤如下。

- (1)缩小图像尺寸:将图像缩小到 32×32 的尺寸;
- (2)灰度化:将 32×32 的图像转化为灰度图像;
- (3)计算DCT:对灰度化后的图像进行DCT变换,得到 32×32 的DCT系数矩阵;
- (4)计算平均值:取DCT系数矩阵中左上角的 8×8 矩阵,并计算该 8×8 矩阵的平均值;
- (5)比较像素灰度:若抽取的 8×8 矩阵中的每一个像素的灰度值大于或等于平均值,则结果记为1,否则记为0;

(6)计算相似度:将64个二进制数串连起来作为图像的哈希值,并计算两张图片哈希值的汉明距离^[28],得到相似度值。

3 使用改进型 Mobilenet_SSD 进行人脸检测

人脸检测是指对图像中的人脸特征进行提取并分析出人脸在图像中的位置以及人脸框的大小等信息。在 VGG_SSD300 目标检测模型中,由于 VGG 网络的最后两个全连接层的卷积核的个数都为 4096,因此需要一次性存储和计算 4096×4096 的权重矩阵,需要进行约 1678 万次运算,大量的计算资源被花费到全连接层的计算上。为了减少计算量,考虑使用卷积层代替全连接层,一种可行的方法是使用 Mobilenet 网络代替 VGG 网络。本文使用轻量化的 Mobilenet 模型作为人脸的检测网络,并级联 SSD 模型进行人脸框位置的回归。

标准的 Mobilenet 模型输入的图片尺寸为 224×224 。但是,由于 SSD300 网络要求输入的图片尺寸为 300×300 ,本文对标准的 Mobilenet 模型进行修改,修改后的模型输入层的尺寸变为 300×300 。为尽可能保留更多的特征信息,网络第一层是标准的卷积层,之后使用 13 组深度可分解卷积层和逐点卷积层来进一步提取人脸图像特征。

在 VGG 网络中,卷积层提取的是图像的浅层特征,全连接层提取的是目标的高层次特征。因此,在 VGG_SSD 检测模型中使用 VGG 网络中的一个卷积层和全连接层的特征图就能够直接检测出目标。VGG 网络后级联 4 个卷积层的目的是从全连接层中再提取有用的特征信息参与目标的检测,使得检测的准确率更高。但由于 SSD 网络适用于多种目标的检测,而人脸识别只需要分辨出是否为人脸,可以看作二分类问题,不需要使用太多高层次的信息,因此对 SSD 网络进行剪枝,只提取前端特征提取网络中两个不同尺寸的特征图进行人脸检测。本文中使用的 Mobilenet 网络作为 SSD 前端的特征提取网络,并抽取 Mobilenet 网络中的第 11 层和第 13 层的特征图输入到 SSD 网络中。在第 11 个卷积层上产生 4 个不同高宽比的预测框,在第 13 个卷积层上产生 6 个不同高宽比的预测框,在 SSD 网络中对这些预测框进行分类与回归。图 1 给出改进后的 Mobilenet_SSD 人脸检测模型。




图 1 改进型 Mobilenet_SSD 人脸检测模型

Fig. 1 Improved Mobilenet_SSD face detection model

模型损失函数^[29]由位置损失 L_{loc} 和分类损失 L_{conf} 加权获得:

$$L(x, c, l, g) = \frac{1}{N} (L_{conf}(x, c) + \alpha L_{loc}(x, l, g)) \quad (3)$$

其中, N 是匹配正样本的总量,如果 $N=0$,则令 $L=0$; x 和 c 分别是分类的指示量和置信度; l 和 g 分别是预测框和实际标注的真实框; α 是位置损失的权重。位置损失 L_{loc} 是预测框 l 和标注的真实框 g 之间的 Smooth L1 损失,定义如下:

$$smooth_{L1}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1 \\ |x| - 0.5, & \text{otherwise} \end{cases} \quad (4)$$

分类损失 L_{conf} 是分类置信度之间的 Softmax 损失,定义如下:

$$L_{conf}(x, c) = - \sum_{i=1}^N x_i \log c_i \quad (5)$$

4 使用多哈希相似度加权进行人脸匹配

在人脸识别中,人脸匹配是除人脸检测之外的另一重要步骤。因此,可以通过计算人脸图像的相似度来判断哪些人脸图像属于一个人,哪些人脸图像是新出现的人脸。由于人脸图像并不是刚性的,存在肤色、表情等差异,因此使用单一的哈希算法计算人脸图像的相似度准确率低且不稳定。针对这一问题,本文提出使用多种哈希算法计算人脸图像的相似度,并将计算的哈希相似度按照一定的权重进行加权,从而得出最终的人脸图像相似度值。人脸图像相似度的计算公式如下:

$$S(S_1, S_2) = \alpha S_1 + \beta S_2, 0 < \alpha < 1, 0 < \beta < 1 \quad (6)$$

其中, $S(S_1, S_2)$ 是最终的人脸图像相似度值。

多哈希相似度加权算法的流程如图 2 所示。首先,分别计算每张图像的均值哈希值(aHash)和感知哈希值(pHash);然后,通过计算汉明距离得到输入图像与待匹配图像的均值哈希相似度 S_1 和感知哈希相似度 S_2 ,并设置合适的相似度阈值 I 和 K ;接着,分别使用 α 和 β 作为 aHash 与 pHash 的权重系数对两个相似度值进行加权;当加权和大于阈值 I 时说明两张人脸图像是同一个人,当加权和小于阈值 K 时说明是不同的人,对处于阈值 I 与阈值 K 之间的图像,将输入的人脸图像与待匹配图像中与之相似度最高的图像进行匹配。

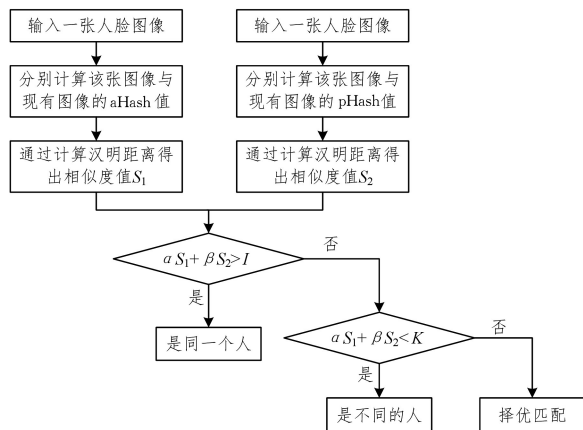


图 2 多哈希相似度加权算法的流程图

Fig. 2 Flow chart of multiple hash similarity weighting

从图 2 可以看出,人脸匹配的准确率与权重系数 α 和 β 以及设置的阈值有关,本文使用遗传算法^[30]优化 α 和 β 并寻找合适的阈值,并规定 α 和 β 的精度为 0.01。使用的数据集是 LFW 标准人脸库,其中包含 5000 个人的图片,每人 2 张,共 10000 张图片。从 LFW 数据库中随机抽取 100 组相同人脸图像和 100 组不同人脸图像,分别计算这 100 组图像的均值哈希相似度值与感知哈希相似度值作为训练数据库。对 α 和 β 进行二进制编码^[31],可以用 7 位二进制数字 0000000-1100100 来表示它们的取值,并将它们的二进制码拼接成 14

位的二进制码,前7位为 α 的取值,后7位为 β 的取值。将拼接后的14位二进制码作为一条染色体,染色体结构如图3所示。




图3 染色体编码结构

Fig. 3 Chromosome coding structure

设置合适的相似度阈值 I ,当加权计算的相似度值大于设置的阈值 I 时,认为这组测试图像是同一个人,记为1,否则记为0。该过程的公式表示为:

$$F(s_i) = \begin{cases} 1, & s_i > I \\ 0, & s_i < I \end{cases}, i=1, 2, \dots, N \quad (7)$$

算法的适应度函数为:

$$f(S) = \frac{\sum_{i=1}^N F(s_i)}{N} \quad (8)$$

算法的总体步骤为:

(1)分别随机产生 $\alpha_1 \sim \alpha_M$ 和 $\beta_1 \sim \beta_M$,将它们按照二进制形式进行编码并进行拼接,形成初始染色体 $S_1 \sim S_M$;

(2)根据式(7)和式(8)计算群体中各个体的适应度值 $f_b(S_1) \sim f(S_M)$;

(3)根据轮转法在 $S_1 \sim S_M$ 中选择 M 个用于繁殖的个体 $S_1' \sim S_M'$;

(4)按照事先设定好的交叉概率 C 将 $S_1' \sim S_M'$ 进行交叉重组,产生 M 个新的个体,形成一个新的群体 $S_1'' \sim S_M''$;

(5)根据设定的变异率 D 随机对 $S_1'' \sim S_M''$ 中任一码位的任一码位进行取反操作,产生新的个体 $S_1''' \sim S_M'''$;

(6)当满足停止条件或者达到最大迭代步数时,停止运算;

(7)修改相似度阈值 I ,重新进行步骤(1)~步骤(6),直到找出合适的阈值 I 与该阈值下的 α 和 β ,使之能够进行准确的人脸匹配。

设置合适的相似度阈值 K ,当加权计算的相似度值小于设置的阈值 K 时,认为是不同的人脸,记为1,否则记为0。人脸相似度阈值优化算法的流程与人脸匹配参数的优化相同。通过opencv将Mobilenet_SSD人脸检测模型检测到的人脸从输入图像上裁剪出来,然后使用多哈希相似度值加权的方法将裁剪出的人脸图像与历史帧中检测出的人脸图像进行比较,从而实现人脸识别。


5 实验测试及分析

本文中所有的测试实验均基于ubuntu 16.4操作系统,Inter i5 9400 CPU,2.9GHz,8GB内存的PC机进行;摄像头像素为720P;Mobilenet_SSD模型在caffe环境下搭建并训练;人脸匹配算法与遗传算法基于Python3.6编写,使用Spyder进行编译与运行。


5.1 人脸检测模型的测试与分析

人脸检测网络使用WiderFace数据集作为训练集,取其中的1/5作为验证集;使用FDDB数据集作为测试集。模型的训练使用GTX 1070显卡进行加速,设置初始学习率为0.1, batch_size为64,最大迭代次数为50000,每迭代1000次进行验证。训练时,在模型的数据层对输入图像进行旋转、缩放、归一化等数据增强,防止训练过程中出现过拟合。图4是

Mobilenet_SSD模型训练时的loss与accuracy变化曲线。



(a)训练时 loss 的变化曲线




(b)训练时 accuracy 的变化曲线

图4 Mobilenet_SSD训练时 loss 与 accuracy 的变化曲线

Fig. 4 Loss and accuracy curves in Mobilenet_SSD training

从图4(a)可以看出,在WiderFace数据集上经过50000次迭代训练之后,模型的loss已经降到0.1左右;图4(b)显示模型的准确率达到92%时模型已经收敛。将训练好的模型放到FDDB数据集上进行测试,测试时的IOU阈值设置为0.6。对于人脸检测模型,通常使用ROC曲线来进行评价,曲线下方的面积越大,说明模型的性能越好。图5给出模型在WiderFace与FDDB数据集上的ROC曲线。



(a)WiderFace上的测试结果

(b)FDDB上的测试结果

图5 Mobilenet_SSD模型测试的ROC曲线

Fig. 5 ROC curve of Mobilenet_SSD model test

通过图5可以看出,模型在FDDB数据集上的测试性能优于在WiderFace数据集上的测试性能,且模型在两个数据集上的准确率最终都达到92%以上,满足日常使用需求。在相同的环境下将本文模型与目前主流的人脸模型进行对比测试,测试数据集为FDDB,人脸检测的IOU阈值设为0.6。表1列出本文模型与MTCNN和FacenessNet模型的对比结果。

表1 3种人脸检测模型在FDDB上的测试结果

Table 1 Test results of three face detection models on FDDB

Model	准确率/%	时间/ms
MTCNN	94.80	68
FacenessNet	97.00	75
本文模型	94.20	56

通过对比测试发现,本文模型与MTCNN模型的检测准确率基本一致,但运行速度比MTCNN快18%左右;与Face-

nessNet 模型相比,本文模型的准确率低 3%左右,但运行速度快 25%左右。可以看出,本文模型在人脸检测的准确率上达到了主流水平,且运行速度是 3 个模型中最快的。

5.2 人脸匹配算法的测试与分析

在 LFW 标准人脸库上使用遗传算法对参数 α 与 β 进行优化,设置交叉率为 0.5,变异率为 0.02。经过迭代优化得出:当 $\alpha=0.44, \beta=0.59$ 时,计算得出的相似度值与实际图像的相似度较为接近;将阈值 I 设置为 0.83 时,相同人脸的匹配率达到 92.4%;将阈值 K 设置为 0.79 时,不同人脸的识别率达到 98.1%。本文后续的测试均在 $\alpha=0.44, \beta=0.59, I=0.83, K=0.79$ 的设置下进行。

本文使用国际上常用的 ORL^[32] 标准人脸库进行算法的验证。该人脸库包括 40 个人的 400 幅人脸图像,每人具有不同光照、表情、视角的 10 幅脸部图像,且均为 92×112 像素、256 级的灰度图像。图 6 给出 ORL 人脸库中的部分样本。

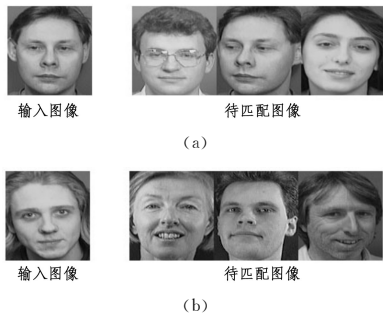


图 6 ORL 人脸库中的部分样本

Fig. 6 Part of the samples in ORL face database

图 6(a)中的图像用于测试算法是否能够正确匹配相同人脸,图 6(b)中的图像用于测试算法是否能够判断出新的人脸。使用均值哈希算法(aHash)、感知哈希算法(pHash)与本文算法计算图 6 中两组图像的相似度值并进行比较,结果如表 2 所列。其中,a(1),a(2),a(3)分别表示图 6(a)中待匹配图像与输入图像的相似度值,b(1),b(2),b(3)分别表示图 6(b)中待匹配图像与输入图像的相似度值。

表 2 3 种哈希算法计算相似度结果的对比

Table 2 Comparison of similarity results calculated by three

hash algorithms

算法	a(1)	a(2)	a(3)	b(1)	b(2)	b(3)
均值哈希	0.609	0.763	0.785	0.673	0.734	0.703
感知哈希	0.634	0.861	0.802	0.714	0.675	0.691
本文算法	0.642	0.843	0.818	0.717	0.721	0.717

通过表 2 可以看出,当相同人脸的相似度阈值 $I=0.83$,不同人脸的相似度阈值 $K=0.79$ 时,使用本文算法能够很好地区分相同人脸与不同人脸。将 ORL 人脸库中的图像每 5 张作为一组,总共 80 组测试数据,将本文算法、余弦相似度^[33](Cosinsim)和互信息相似度^[34](Mutual Information)在该测试数据上进行测试对比,结果如表 3 所列。

表 3 3 种人脸匹配算法的对比

Table 3 Comparison of three face matching algorithms

算法	平均计算时间/ms	匹配准确率
Cosinsim	1500	0.893
Mutual Information	75	0.916
本文的算法	20	0.962

通过表 3 的对比可以看出,本文算法进行 5 张人脸图像的匹配时,平均仅用时 20ms,远短于其他两种方法;同时本文算法的准确率为 96.2%,达到了主流匹配算法的水平。

5.3 实时人脸识别的测试与分析

使用 Python3.6 编写程序,通过 opencv 将人脸检测模型与人脸匹配算法进行封装,使用 opencv 将摄像头采集到的图像裁剪到合适尺寸后输入到 Mobilenet_SSD 中进行人脸检测,并将检测到的人脸从原图像中裁剪出以进行人脸匹配。图 7 给出实时人脸识别测试的效果。




图 7 实时人脸识别测试

Fig. 7 Real-time face recognition test

经过多次测试发现:本文算法的人脸识别准确率达 95%左右,平均人脸识别时间为 80 ms 左右,满足日常对人脸识别的性能需求。

本文提出的基于深度学习和多哈希相似度加权的人脸检测匹配算法,与主流的检测算法 FasterR-CNN 相比,具有运算量低、检测速度快的优势;与 YOLO 算法相比,具有检测准确率高、检测速度快的优势;与 MTCNN 和 FacenessNet 等人脸匹配算法相比,具有运算量低、易于移动端部署的优势。

结束语 本文提出了一种基于深度学习与多哈希相似度加权的人脸检测匹配方法。多次实验测试证明,本文方法的平均人脸识别准确率达到 95%左右,平均识别时间为 80 ms 左右,满足日常使用需求,具有一定的实用价值与现实意义。但是,本文算法仍存在对小目标和模糊图像的识别率不高的问题。针对这些问题,未来将通过进一步优化人脸检测网络和增加人脸清晰度判别等方法进行改进。

参 考 文 献

- [1] JIANG R D, CHU W, YAN J. Intelligent recognition system for face recognition under ARM platform[J]. Computer Engineering and Design, 2018, 39(2): 590-595.
- [2] BUHMANN J, LADES M, MALSBURG C V D. Size and distortion invariant object recognition by hierarchical graph matching [C]// International Joint Conference on Neural Networks. 1990: 416-441.
- [3] SONG J, CHEN B, CHI Z, et al. Face Recognition Based on Binary Template Matching [C]// Third International Conference on Intelligent Computing (ICIC 2007). Springer-Verlag, 2007.
- [4] SHAN S, GAO W, ZHAO D. Face recognition based on face-specific subspace[J]. International Journal of Imaging Systems & Technology, 2010, 13(1): 23-32.
- [5] DAVE P, AGARWAL J, METTA T. Face Detection using Principal Component Analysis (PCA) [J]. International Journal of Computer Applications, 2014, 95(17): 37-40.

- [6] RANGSEE P, RAJA K B, VENUGOPAL K R. Modified Local Ternary Pattern Based Face Recognition Using SVM[C]//2018 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS). 2018.
- [7] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks [C]//International Conference on Neural Information Processing Systems. 2015.
- [8] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only Look Once: Unified, Real-Time Object Detection [J]. arXiv: 1506.02640, 2015.
- [9] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single Shot MultiBox Detector[J]. arXiv:1512.02325, 2015.
- [10] SIMONYAN K, ZISSER, AN A. Very Deep Convolutional Networks for Large-Scale Image Recognition [J]. arXiv: 1409.1556v6, 2014.
- [11] HUANG J H, LI X W, CHEN B H, et al. Comparative Study of Image Similarity Algorithm Based on Hash[J]. Journal of Dali University, 2017, 12(2): 32-37.
- [12] YIN Y M, PENG Y, QI J H. Research on the Image Similarity Retrieval Algorithm Based on Double Hash[J]. Information and Communications Technologies, 2019, 13(1): 33-38.
- [13] DENG J, ZHOU B, SHI Y L. Application of Improved Image Hash Algorithm in Image Tamper Detection[C]//2018 International Conference on Intelligent Transportation, Big Data & Smart City (ICITBS). IEEE Computer Society, 2018.
- [14] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications [J]. arXiv:1704.04861, 2017.
- [15] VIOLA P, JONES M J. Robust Real-Time Face Detection[J]. International Journal of Computer Vision, 2004, 57(2): 137-154.
- [16] YAN J X, YIN J X. Multi-pose face detection based on face feature and AdaBoost algorithm[J]. Journal of Computer Applications, 2010, 30(4): 967-970.
- [17] AHONEN T, HADID A, PIETIKAINEN M. Face Description with Local Binary Patterns: Application to Face Recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28(12): 2037-2041.
- [18] YANG B, YAN J, LEI Z, et al. Aggregate channel features for multi-view face detection[C]//IEEE International Joint Conference on Biometrics. 2014: 1-8.
- [19] GHIASI G, FOWLKES C C. Occlusion Coherence: Localizing Occluded Faces with a Hierarchical Deformable Part Model [C]//Computer Vision & Pattern Recognition. 2014.
- [20] LI Q Y, JI Q G, HONG S D. FastFace: Real-time robust face detection algorithm [J]. Journal of Image and Graphics, 2019, 24(10): 1761-1771.
- [21] 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.
- [22] YANG S, LUO P, LOY C C, et al. Faceness-Net: Face Detection through Deep Facial Part Responses[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(8): 1845-1859.
- [23] ZHOU X Y, WANG W, LI L Y. Overview of Target Detection Algorithm Based on Deep Learning[J]. Electronic Measurement Technology, 2017, 40(11): 89-93.
- [24] MARCETIC D, HRKAC T, Slobodan Ribaric. Two-stage cascade model for unconstrained face detection[C]//2016 First International Workshop on Sensing, Processing and Learning for Intelligent Machines (SPLINE). IEEE, 2016.
- [25] ZHANG J L, WU X W, ZHU J K. Feature Agglomeration Networks for Single Stage Face Detection[J]. arxiv: 1712. 00721, 2017.
- [26] LI E, WEN Z S, ZHANG Y L, et al. Face recognition system based on OpenCV and mean hash algorithm[J]. Industrial Design, 2016(8): 132-133.
- [27] WANG A C, CHEN H T. Robust Perceptual Image Hashing Technique Based on Discrete Cosine Transform[J]. China Safety Science Journal, 2009, 19(4): 91.
- [28] WANG C, KAO W H, HSIAO C K. Using Hamming Distance as Information for SNP-Sets Clustering and Testing in Disease Association Studies[J]. Plos One, 2015, 10(8): e0135918.
- [29] REN J J, WANG N. Study on the Loss Function in Artificial Neural Networks [J]. Journal of Gansu Normal University, 2018, 23(2): 65-67.
- [30] RIBEIRO R, FEITOSA A R S, DE SOUZA R E, et al. Reconstruction of electrical impedance tomography images using genetic algorithms and non-blind search[C]//2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI 2014). IEEE, 2014.
- [31] ZHANG W X, LIANG Y. The Mathematical Foundation of Genetic Algorithm[J]. Journal of Xi'an Jiaotong University, 2000, 34(10): 6.
- [32] GAO H K, MA S N. Research on Fast Face Authentication Technology Based on ORL Database[J]. Science & Technology Communication, 2014, 16(12): 89-92.
- [33] NGUYEN H V, BAI L. Cosine Similarity Metric Learning for Face Verification[C]//Computer Vision-ACCV 2010-10th Asian Conference on Computer Vision. Queenstown, New Zealand, 2010.
- [34] RAGHAVENDRA R, VENKATESH S, RAJA K B, et al. Mutual Information Based Multispectral Image Fusion for Improved Face Recognition[C]//2016 12th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS). IEEE, 2016.



DENG Liang, born in 1996, master. His main research interests include digital chip design, deep learning, and face recognition.



CHEN Zhang-jin, born in 1969, doctor, professor. His main research interests include digital chip design, large-screen LED display research and development.