

基于边云协同的人脸识别方法研究

魏勤, 李瑛娇, 娄平, 严俊伟, 胡辑伟

引用本文

魏勤, 李瑛娇, 娄平, 严俊伟, 胡辑伟. [基于边云协同的人脸识别方法研究](#)[J]. 计算机科学, 2022, 49(5): 71-77.

WEI Qin, LI Ying-jiao, LOU Ping, YAN Jun-wei, HU Ji-wei. [Face Recognition Method Based on Edge-Cloud Collaboration](#)[J]. Computer Science, 2022, 49(5): 71-77.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于深度学习的单幅图像三维人脸重建研究综述](#)

Review of 3D Face Reconstruction Based on Single Image

计算机科学, 2022, 49(2): 40-50. <https://doi.org/10.11896/jsjcx.210500215>

[面向智慧教育行为分析的图卷积骨架动作识别方法](#)

Graph Convolutional Skeleton-based Action Recognition Method for Intelligent Behavior Analysis

计算机科学, 2022, 49(2): 156-161. <https://doi.org/10.11896/jsjcx.220100061>

[快速局部协同表示分类器及其在人脸识别中的应用](#)

Fast Local Collaborative Representation Based Classifier and Its Applications in Face Recognition

计算机科学, 2021, 48(9): 208-215. <https://doi.org/10.11896/jsjcx.200800155>

[自适应小数据集乳腺癌病理组织分类研究](#)

Research on Classification of Breast Cancer Pathological Tissues with Adaptive Small Data Set

计算机科学, 2021, 48(6A): 67-73. <https://doi.org/10.11896/jsjcx.201000188>

[于改进脉冲耦合神经网络的动态人脸识别](#)

Dynamic Face Recognition Based on Improved Pulse Coupled Neural Network

计算机科学, 2021, 48(6A): 85-88. <https://doi.org/10.11896/jsjcx.200600172>

基于边云协同的人脸识别方法研究

魏 勤 李瑛娇 娄 平 严俊伟 胡辑伟

武汉理工大学信息工程学院 武汉 430070

摘 要 人脸识别被广泛应用于购物、安检、出行、支付和考勤等日常生活中,人脸识别系统需要大的算力与存储空间,因此往往将需要识别的人脸通过网络传送到云平台进行识别,但网络覆盖、拥塞或延时等问题造成人脸识别系统难以满足实际应用的需求,用户体验差。针对人脸识别中存在的问题,提出了基于边云协同的人脸识别方法。该方法结合云计算的处理能力和边缘计算的实时性,使人脸识别系统不受网络状态的约束,应用更加广泛,用户体验更好。在云端,提出了 LResNet 特征提取方法,改进了 ResNet34 网络结构,并利用 ArcFace 人脸损失函数监督训练过程,使网络学习到更多的人脸角度特性;在边缘端,针对计算资源和存储资源有限的问题,提出了 SResNet 特征提取方法,利用深度可分离卷积轻量化 LResNet 网络结构,大大减少了网络参数和计算量。边云协同的人脸识别实验表明,所提系统在任何网络状态下都能进行实时识别且准确率较高。

关键词: 边云协同;人脸识别;ResNet;ArcFace;深度可分离卷积

中图分类号 TP391.41

Face Recognition Method Based on Edge-Cloud Collaboration

WEI Qin, LI Ying-jiao, LOU Ping, YAN Jun-wei and HU Ji-wei

School of Information Engineering, Wuhan University of Technology, Wuhan 430070, China

Abstract Face recognition is widely used in daily life such as shopping, security check, travel, payment and work attendance. Face recognition systems need strong computing power and large storage space, so face images that need to be recognized are usually transmitted to the cloud platform through the network. Due to the problems of network coverage, congestion and delay, face recognition systems are difficult to meet the needs of actual application, and the user experience is poor. Aiming at the problems in face recognition, a face recognition method based on edge-cloud collaboration is proposed. This method combines the processing ability of cloud computing and the real-time performance of edge computing, so that face recognition systems are not constrained by the network status, and its application is more extensive and the user experience is better. In the cloud, the LResNet feature extraction method is proposed to improve the ResNet34 network structure, and the ArcFace face loss function is used to supervise the training process, so that the network can learn more face angle features. At the edge, due to the limited computing resources and storage resources, a SResNet feature extraction method is proposed. Deep separable convolution is used to lighten the LResNet network structure, and it has greatly reduced network parameters and computation. The face recognition experiment on edge-cloud collaboration shows that the system can recognize faces in real time with a high accuracy rate under any network status.

Keywords Edge-Cloud collaboration, Face recognition, ResNet, ArcFace, Deep separable convolution

1 引言

人脸识别作为一种重要的个人身份鉴别方法,被广泛用于购物、安检、出行、支付和考勤等日常生活中,其应用前景非常广阔。人脸识别系统的应用明显提高了各行业的工作效率,成为了相关领域研究的热点。

人脸识别方法主要分为两大类,一类是基于传统图像处理的人脸识别方法,如特征脸算法^[1]、局部方向模式^[2]、尺度

不变特征变化^[3]和支持向量机^[4]等,这些传统图像处理方法提取的特征属于浅层特征,它们不能从人脸图像中获得深度特征及更加深入的高语义特征。另一类是基于深度学习的人脸识别方法,深度学习的检测器具有强大的特征提取能力^[5]。DeepID 系列^[6-8]、GroupFace^[9]和 Vec2Face^[10]等卷积网络在人脸识别上都有不错的表现。Google 也提出了 FaceNet^[11]网络,该网络使用三元组损失 Triplet loss^[12]来增大类间距,提高模型的性能。He 等^[13-14]提出了 ResNet 网络结构,该

到稿日期:2021-03-22 返修日期:2021-11-17

基金项目:国家自然科学基金(52075404);武汉市科技局应用基础前沿专项(2020010601012176)

This work was supported by the National Natural Science Foundation of China(52075404) and Application Foundation Frontier Special Project of Wuhan Science and Technology Bureau(2020010601012176).

通信作者:魏勤(qinwei@whut.edu.cn)

网络有效解决了网络加深引起的梯度消失和模型退化问题。

深度学习网络具有计算密集和内存密集的特点,因此大多网络模型只能在计算资源和存储资源丰富的云平台上运行。人脸识别系统需要较大的算力与存储空间,因此通常将需要识别的人脸通过网络传送到云平台进行识别。随着物联网的快速发展,无数的边缘终端设备连接到网络,大量的数据给网络传输带来了巨大的挑战,导致网络出现拥堵、故障等问题;即使边缘终端设备数量不多,在网络覆盖不佳的地区依然可能出现网络不畅、延时过长等问题。这些问题造成人脸识别系统实时性差,难以达到实际应用的需求,导致用户体验不佳。

边云协同的提出为解决人脸识别系统实时性差的问题提供了新思路。边云协同将计算任务分散在边缘节点和云端节点,同时保持两者紧密协同联动,使人脸识别系统能更好地应对需求的增长和复杂化。云具有丰富的计算和存储资源,可以在云中建立、分析和优化模型,处理复杂的推理过程。边缘计算可以从云中卸载轻量化模型,数据可以被直接处理,并在边缘反馈,延迟较低。边云协同实现了云和边缘的优势互补。

综上,本文提出了一种基于边云协同的人脸识别方法,该方法结合了云计算的处理能力和边缘计算的实时性,使人脸识别系统不受网络状态的约束,应用更加广泛,用户体验更好。在云端,提出了 LResNet 特征提取方法,该方法对 ResNet 网络结构进行了改进,同时利用 ArcFace 人脸损失函数监督训练过程来优化网络,使网络学习到更多的人脸角度特性;在边缘端,针对计算资源和存储资源有限的问题,提出了 SResNet 特征提取方法,对 LResNet 网络结构进行了轻量化,同时利用深度可分离卷积来减少网络参数和计算量。边云协同的人脸识别实验表明,所提系统在任何网络状态下都能进行实时识别且准确率较高。

2 基于 ResNet 的边云协同人脸识别方法

2.1 边云协同的人脸识别框架研究

人脸识别系统需要较大的算力和存储空间,因此通常将需要识别的人脸通过网络传送到云平台进行识别,但由于网络覆盖、拥塞或延时等问题,人脸识别系统难以满足实际应用的需求,用户体验差。

边云协同的提出可以很好地解决人脸识别系统实时性差的问题。云端在网络良好的情况下可以独立运行,边缘可以不受网络状态的约束独立运行,协同方法的研究保证了人脸识别系统在任何网络情况下都可以正常工作。但是,边缘设备的计算资源有限,当在边缘终端设备执行复杂的人脸识别推理过程时,边缘计算可能会增加延时;边缘设备的存储资源有限,若直接将人脸图像存储在边缘设备数据库中,则占用的内存太大,可能会超出边缘设备的存储容量。

云计算的处理能力强、存储空间大,但实时性差,只采用云计算的方式会导致人脸识别系统受到网络状态的约束;边缘计算的实时性好,但边缘设备的计算和存储资源有限。因此,本文提出了边云协同人脸识别框架,如图 1 所示。该方法主要包含基于云计算的 LResNet 人脸识别方法和基于

边缘计算的 SResNet 人脸识别方法。




图 1 人脸识别框架

Fig. 1 Face recognition framework

当网络状况良好时,人脸识别系统终端设备将采集到的人脸图像通过互联网传输至云平台,在云平台上完成人脸图像预处理、LResNet 特征提取和余弦相似度人脸匹配,得出人脸识别结果并将其返回至终端设备进行展示;当终端设备在规定时间内未接收到云平台的响应,即网络出现断开、故障、拥塞或延时等现象时,则在终端设备上进行人脸图像预处理、SResNet 特征提取和余弦相似度人脸匹配,得到结果后在终端展示。

边缘设备的计算资源有限,协同方法通过轻量化网络的方式减小网络模型和参数的大小,使得网络在只需极低计算成本的边缘设备上也可以进行实时识别;边缘设备的存储资源有限,协同方法使用人脸特征向量量数据库的方法来存储人脸特征信息,大大减小了所需的内存空间,解决了边缘存储设备容量有限的问题。

由于云平台拥有丰富的计算资源和存储资源,因此可以提前在云平台上进行 LResNet 和 SResNet 两种人脸特征向量提取方式,如图 2 所示。边缘终端设备可以提前从云中下载 SResNet 人脸特征数据库中的特征向量,在边缘识别时只需提取当前图像的人脸特征,然后与数据库中的人脸特征向量进行比对,大大缩短了边缘侧人脸匹配的时间。




图 2 人脸特征向量数据库

Fig. 2 Face feature vector database

2.2 基于云计算的 LResNet 人脸识别方法

基于云计算的 LResNet 人脸识别方法包含 4 个部分,即

人脸图像预处理、LResNet 特征提取、余弦相似度人脸匹配和得出的人脸识别结果。

人脸图像预处理包含 3 个部分:人脸校正、人脸检测和图片大小归一化。人脸图像校正利用面部的关键点和仿射变化函数对人脸区域进行校正;人脸检测使用 MTCNN (Multi-task Cascaded Convolutional Networks) 对人脸区域进行截取;图片大小归一化使用双线性插值的方法将人脸图像统一调整为 112×96 像素。人脸匹配方法使用余弦相似度方法,通过比较目标人脸特征向量和 LResNet 人脸特征向量数据库中的特征向量,找出符合阈值条件且相似度最高的人脸。

人脸特征提取是人脸识别中最重要的一个步骤。LResNet 是 ResNet 的改进版本,具有更高的识别准确率,用于云平台的人脸特征提取。

2.2.1 ArcFace 损失函数

ResNet 在经过卷积层、池化层等处理后将特征送入全连接层,把特征从多维转成一维,这样不但可以简化计算,而且还有助于网络分类。Softmax^[15]就是将多个输出映射到区间 $(0,1)$ 来进行分类。Softmax 在图片分类中应用广泛,其主要通过输出样本属于各个类的概率大小来进行分类。但是,Softmax 没有约束类内距离和类间距离,影响了人脸识别的精度。

为了解决这一问题,本文引用了 ArcFace^[16] 人脸损失函数,该函数在提高类内可分性的同时加强了类内紧度和类间差异。

$$W^T x = \|W\| \cdot \|x\| \cdot \cos\theta \quad (1)$$

其中, θ 为权重 W 和特征向量 x 之间的夹角,即特征向量相乘含有角度信息。为了使卷积神经网络可以学习到更多的角度特性,首先将权重值设置为固定值 s ,将偏置值设为 0,这样提取到的特征就转化到了角度空间,决策边界也就只与角度相关;然后引入一个参数 $t(t>0)$ 来控制角度余弦值的大小,让网络学习到更具区分度的特征。ArcFace 损失函数比 Softmax 损失函数的特征分布更加紧凑,决策边界更加明显。ArcFace 损失函数如式(2)所示:

$$L_{\text{ArcFace}} = -\frac{1}{m} \sum_{i=1}^m \ln \left(\frac{e^{s(\cos(\theta_{y_i} + t))}}{e^{s(\cos(\theta_{y_i} + t))} + \sum_{j=1, j \neq y_i}^c e^{s \cos \theta_j}} \right) \quad (2)$$

2.2.2 LResNet 网络结构

ResNet 卷积神经网络是一种经典的特征提取网络,云平台采用的 LResNet 特征提取网络是在 34 层 ResNet 网络的基础上进行改进的。ResNet 网络结构的输入为 224×224 ,而人脸数据的输入为 112×96 ,因此若直接将 112×96 的数据作为网络的输入,则会使原本最后提取到的特征维度由 7×7 变成 4×3 ,维度太小,提取特征的效果不明显,因此将第一个大小为 7×7 的卷积核、步长为 2 的卷积层替换成大小为 3×3 的卷积核、步长为 1 的卷积层,这样第一个卷积层就不会缩减输入的维度,最后可以得到 7×6 的特征维度。因此 LResNet 网络由 1 个大小为 $3 \times 3 \times 64$ 的卷积层、16 个由两个卷积层构成的 block 残差块和 1 个输出为 512 的全连接层组成,其网络结构如图 3 所示。




图 3 LResNet 网络结构

Fig. 3 LResNet network structure

LResNet 网络结构中最重要的一部分是残差模块 (Residual Block) 捷径连接,残差模块通过捷径连接 (Shortcut Connection) 实现,通过 shortcut 将残差模块的输入和输出进行相加,这个操作不会给网络带来额外的参数和计算量,同时还可以加快模型的训练速度,提高模型的训练效果,而且当网络的层数加深时,残差模块还能够很好地解决退化问题。残差模块的结构如图 4 所示。




图 4 残差模块结构

Fig. 4 Residual module structure

残差模块结构有两种,一种是连接相同的维度,另一种是连接不同的维度。图 3 中的实线连接的是相同的维度,虚线连接的是不同的维度。它们的计算方式分别为:

$$y = F(x) + x \quad (3)$$

$$y = F(x) + Wx \quad (4)$$

其中, W 是卷积操作,用于调整 x 的 channel 维度。

2.3 基于边缘计算的 SResNet 人脸识别方法

基于云计算的 SResNet 人脸识别方法包含 4 个部分,即人脸图像预处理、SResNet 特征提取、余弦相似度人脸匹配和得出人脸识别结果。人脸图像预处理与基于云计算的 LResNet 人脸识别方法一致。人脸匹配方法使用余弦相似度方法,边缘终端设备提前从云中下载 SResNet 人脸特征数据库

中的特征向量,在匹配时只须将要识别的图像的人脸特征与数据库中的人脸特征向量进行比对,即可找出符合阈值条件且相似度最高的人脸,由此大大缩短了边缘侧人脸匹配的时间。

SResNet 特征提取网络是 LResNet 网络的轻量化版本,具有更快的识别速度,被用于边缘平台的人脸特征提取。下文将具体介绍 SResNet 的轻量化过程以及 LResNet 网络的结构。

2.3.1 深度可分离卷积

为了减少模型参数和计算量,在 SResNet 网络中引入了深度可分离卷积^[17],其运算成本比传统的卷积更低,参数数量比传统的卷积更少。深度可分离卷积的核心即把卷积拆分为深度卷积(Depthwise)和逐点卷积(Pointwise)两个部分。图 5 为传统卷积核和深度可分离卷积核的示意图,图中 M 为卷积通道数, N 为卷积核个数, D_k 为卷积核的宽和高。




图 5 传统卷积和深度可分离卷积示意图

Fig. 5 Schematic diagrams of traditional convolution and deep separable convolution

由图 5 可知,标准卷积的计算量 P_1 为:

$$P_1 = D_k \times D_k \times M \times N \times D_w \times D_h \quad (5)$$

深度可分离卷积的计算量 P_2 为:

$$P_2 = D_k \times D_k \times M \times D_w \times D_h + M \times N \times D_w \times D_h \quad (6)$$

其中,式(5)与式(6)中的 D_w 和 D_h 分别为传统卷积的宽和高。

参数数量和乘加操作的运算量下降倍数 P_3 为:

$$P_3 = \frac{P_2}{P_1} = \frac{1}{N} + \frac{1}{D_k^2} \quad (7)$$

从式(7)可以看出,与标准卷积相比,深度可分离卷积在参数数量和计算量上大幅度降低,从而提升了模型的运算效率。

深度卷积没有改变通道的能力,输出通道等于输入通道,但是如果输入通道数较少,那么深度卷积只能在低维工作,导致卷积效果不好。受 MobileNetV2^[18] 的启发,本研究在深度卷积之前,用一个大小为 1×1 的卷积进行升维操作,使网络能够在更高维的空间进行特征提取,从而使最后提取到的特征更具有全局性。为了解决低维 ReLU 运算时产生的信息丢失问题,本研究将最后一个 ReLU 函数替换为 Linear 线性激活函数。

2.3.2 SResNet 网络结构

边缘平台采用的 SResNet 人脸特征提取网络是在 LResNet 的基础上进行网络轻量化,SResNet 网络由一个大小为 $7 \times 7 \times 64$ 的卷积层、6 个由两个卷积层构成的 block 残差块和一个输出为 256 的全连接层组成,其网络结构如图 6 所示。




图 6 SResNet 网络结构

Fig. 6 SResNet network structure

图 6 中的 block1 块和 block2 块为深度可分离卷积模块。为了更好地提取特征,block 模块先进行了一个升维的操作,再进行卷积的可分离操作,block1 模块的结构如图 7 所示。




图 7 传统卷积和可分离卷积结构图

Fig. 7 Structure diagrams of traditional convolution and separable convolution

由图 7 可知,深度可分离卷积不会改变输入和输出通道的大小,和传统卷积一样,均为 64 通道变为 128 通道。图 6 中 block2 的结构与 block1 相似,通道大小从 128 变成 256。

3 实验设置及结果分析

3.1 实验设置

3.1.1 实验数据集

本实验使用 CASIA-Webface^[19] 人脸数据集作为训练数据集,该数据集包含了 10575 个人的 490871 张人脸图像,每张图片的大小为 250×250 。将 CASIA-Webface 数据集通过加噪、旋转的方式进行数据增强,防止训练过程中出现过拟合。使用 MTCNN 人脸检测网络对增强后的 CASIA-Webface 数据集进行检测,并将检测到的人脸统一裁剪为 112×96 大小的图片,用于训练网络。

测试数据集选用 LFW 人脸数据集和自制数据集。LFW 数据集包含了 5749 个人的 13233 张人脸图像,图片中的人物表情、姿势和光照条件都有很大不同,图片大小为 250×250 像素。自制数据集包含 100 个人的 700 张图片,每个人有 1~20 张图片不等,图片大小为 240×200 像素。图片由分辨率为 100 万像素的摄像头在光线变化、背景变化、人脸角度

变化的情况下采集。自制数据集集中的人脸图像如图 8 所示。



图 8 自制数据集人脸图像示例
Fig. 8 Sample images of self-make dataset

3.1.2 实验环境及参数设置

本次实验以 4GB 内存的 Cortex-A72 树莓派 4B 开发板为边缘计算设备,以 NVIDIA Tesla V100 16GB GPU 和 Intel (R) Xeon(R) @ 1.70GHz CPU 的服务器为云计算平台;实验的 LResNet 和 SResNet 模型均在 NVIDIA Tesla V100 16GB 的 GPU 上进行训练,训练总轮数 *epoch* 设置为 100,初始学习率设置为 0.01,*batchsize* 设置为 32,总的权重衰减参数设置为 5×10^{-4} ;使用 Adam 优化模型。该方法的整体实现是基于 Pytorch 框架,Python3.6 编写,使用 Pycharm 进行编译与运行。

3.2 实验结果分析

3.2.1 人脸存储方式对比实验

本实验比较了人脸图片数据库和人脸特征向量数据库这两种方式存储的人脸信息。图 9 给出了数据集 LFW 的图像示例。将 LFW 数据集图像经过人脸校正、MTCNN 人脸检测和图像大小归一化处理为 112×96 大小的图像,示例如图 10 所示。



图 9 LFW 数据集的图像示例
Fig. 9 Sample images of LFW dataset



图 10 数据预处理后的图像示例
Fig. 10 Sample images after data processing

将人脸图像用两种方式存储,一种是直接以图片数据库的方式存储,存储图 10 所示的图像;另一种是以人脸特征向量数据库的方式存储,即将预处理后的人脸图像通过识别

网络提取 128 维特征向量,将人脸信息以键值对 (key-value) 的形式存储在 json 文件中,key 值为人脸 ID,value 值为人脸特征向量。比较这两种方式在存储大小为 1 MB 的空间中能存储的人脸数量,存储方式对比结果如表 1 所列。

表 1 存储方式的比较
Table 1 Comparison of storage modes

存储方式	存储数量
人脸图片	7×10^6
人脸特征向量	39×10^6

从表 1 可以看出,在存储空间大小相同时,人脸特征向量能存储的人脸数量远大于人脸图片存储的人脸数量,前者是后者的 5.57 倍。由此可知,使用人脸特征向量存储人脸信息可大大减小边缘端的存储负担,减轻边缘存储压力。

3.2.2 云端模型的有效性证明实验

为了验证本文云端算法的有效性,本实验选取 3 种不同的特征提取网络,即 CurricularFace^[20]、ResNet34 和本文算法 LResNet,并将其部署在云服务器上。LFW 数据集提供了 6000 对的人脸比对标签,其中包含了 3000 对正样本对和 3000 对负样本对。本实验在 6000 对人脸比对标签上测试人脸验证的准确率,通过 10 折交叉验证的方式来获得平均准确率,以平均准确率作为评价模型优劣的指标之一。3 种网络模型的模型大小、平均加载时间、平均提取时间和在 LFW 数据集上的准确率如表 2 所列。

表 2 CurricularFace、ResNet34 和 LResNet 的性能比较
Table 2 Performance comparison of CurricularFace、ResNet34 and LResNet

网络结构	模型大小	平均加载时间/s	平均提取时间/s	准确率/%
Curricular Face	248.8×10^6	0.27	0.34	96.13
ResNet34	190.2×10^6	0.23	0.29	96.21
LResNet	190.2×10^6	0.23	0.29	96.48

从表 2 可以看出,相比 CurricularFace、ResNet34 的性能更好,其平均加载和提取时间更短且准确率更高。而本文模型在 ResNet34 模型的基础上进行了改进,相比 ResNet34 模型,改进后的 LResNet 模型的准确率有了进一步的提升,验证了本文提出的云平台算法 LResNet 的有效性。

3.2.3 边缘模型的有效性证明实验

SResNet 是为了适用于边缘计算平台而对 LResNet 进行轻量化的结果。将两种模型分别部署在 4 GB 内存的 Cortex-A72 树莓派 4B 开发板上,比较其模型大小、平均加载时间、平均提取时间和在 LFW 数据集上的准确率。LResNet 和 SResNet 两种模型的性能比较结果如表 3 所列。

表 3 LResNet 和 SResNet 的性能比较
Table 3 Performance comparison of LResNet and SResNet

网络结构	模型大小	平均加载时间/s	平均提取时间/s	准确率/%
LResNet	190.20×10^6	2.34	2.65	96.48
SResNet	11.00×10^6	0.18	0.22	94.30

由表 3 可知,SResNet 网络模型在准确率小幅度下降

2.18%的情况下,其大小、加载时间和特征提取时间分别降低了94.2%,92.3%和91.7%,有效地降低了模型的计算量和模型的复杂程度。因此,SResNet模型在边缘计算平台只需要很少的计算资源,大大降低了模型部署在边缘计算设备的难度,缩短了模型在边缘端的识别时间,减小了内存占用率。

3.2.4 边云协同人脸识别实验

人脸识别系统通过Qt框架搭建用户界面,经过测试,系统界面友好且运行稳定。系统启动时自动加载检测模型和识别模型。

在自制数据集中选取100个人的光线适中的清晰正脸照,在云平台上将这100张人脸图像预处理为如图10所示的112×96大小的图像,并将其作为人脸标准图像库,然后提取LResNet和SResNet的人脸特征向量,建立LResNet和SResNet人脸特征向量数据库。将SResNet人脸特征向量数据库下载到边缘侧,便于边缘侧直接与识别图像特征向量进行人脸匹配。

实验选取自制数据集中剩余的600张图片来进行测试。为了证明本文模型在边云协同计算场景下的优势,将本文的边云协同模型与改进前的边云协同模型进行了实验对比。其中,本文协同模型中的云计算模型为LResNet模型,边缘计算模型为SResNet模型;改进前的协同模型中的云计算模型和边缘计算模型都为LResNet模型。在两种边云协同模型下,对这600张图片分别进行网络正常和网络异常状态下的人脸识别实验,网络异常状态包括网络断开、网络故障和网络阻塞等。网络断开即不连接任何网络;网络故障使用linux自带的netem工具模拟,网络阻塞使用流控工具Traffic Control模拟。若边缘发送的连接请求在0.3s内未接收到服务器的响应,则直接使用边缘模型进行识别。表4列出了在不同条件下人脸识别的平均时间和准确率的比较。

表4 不同条件下人脸识别的性能比较

Table 4 Performance comparison of face recognition in different conditions

网络 状态	本文协同模型		改进前的协同模型	
	平均识别 时间/s	准确率/%	平均识别 时间/s	准确率/%
网络正常	1.28	93.17	1.28	93.17
网络断开	1.02	90.83	3.52	93.17
网络故障	1.31	90.83	3.83	93.17
网络阻塞	1.37	92.33	3.90	93.17

从表4可以看出,在网络正常的状态下,本文模型人脸识别的平均时间为1.28s,准确率为93.17%,此情况下的图像均传输至云平台识别;在网络断开状态下的人脸识别的平均时间为1.02s,准确率为90.83%,此情况下的图像均在边缘识别;在网络故障状态下,边缘在0.3s无响应后均使用边缘模型识别,因此准确率与网络断开状态相同;在网络阻塞状态下,云端在0.3s内响应则使用云端模型识别,在0.3s内未响应则使用边缘模型识别,平均识别时间为1.37s,准确率为92.33%;对于其他的网络异常状态,若发送的请求在0.3s内有响应,则识别时间最长为云端模型推理时间加0.3s,若无响应则识别时间为边缘模型推理时间加0.3s。无论是在

哪种网络状态下,本文的边云协同模型都能及时选择云计算和边缘计算的一种模型进行识别,从而达到实时识别的目的,而改进前的边云协同模型虽然识别率较高,但在网络异常状态下识别时间过长,不符合人脸识别系统的需求。由此说明,在任何网络状态下,本文提出的边云协同人脸识别模型都能进行实时识别且准确率较高,满足人脸识别系统的要求。

结束语 本文从人脸识别系统出发,提出了一种基于边云协同的人脸识别方法。该方法结合了云计算的处理能力和边缘计算的实时性,使人脸识别系统不受网络状态的约束,应用更加广泛,用户体验更好。在云端,采用ResNet的改进模型LResNet提取人脸特征,在模型训练的过程中使用ArcFace损失函数进行监督,使网络学习到更多的人脸角度特性;在边缘端,引入了深度可分离卷积,对LResNet模型网络结构进行剪枝,提出了轻量化人脸特征提取模型SResNet,将其部署在边缘设备上。在树莓派上的人脸识别实验表明,人脸识别系统中边缘和云协同工作,保证了系统在任何网络状态下都能进行实时识别且准确率较高。但是,相比LFW公开数据集(大多为欧美人脸)的识别率,本文方法针对自制数据集(亚洲人脸数据集)的识别率有所下降。针对此问题,未来将使用迁移学习等方法进一步对人脸识别模型进行改进。

参 考 文 献

[1] TURK M,PENTLAND A.Eigenfaces for Recognition [J]. Journal of Cognitive Neuroscience,1991,3(1):71-86.

[2] WANG Y,LI X.Face Recognition Based on LDP Feature and Bayesian Model [J]. Computer Science,2017,44(12):283-286,291.

[3] TARIQ U,LIN K H,LI Z,et al.Recognizing emotions from an ensemble of features [J]. IEEE Transactions on Systems, Man and Cybernetics,Part B(Cybernetics),2012,42(4):1017-1026.

[4] WU Q H,GAO X D.Face Recognition in Non-ideal Environment Based on Sparse Representation and Support Vector Machine [J]. Computer Science,2020,47(6):121-125.

[5] DENG L,XU G L,LI M J,et al.Fast Face Recognition Based on Deep Learning and Multiple Hash Similarity Weighting [J]. Computer Science,2020,47(9):163-168.

[6] SUN Y,WANG X G,TANG X,et al.Deep Learning Face Representation from Predicting 10000 Classes[C]//27th IEEE Conference on Computer Vision and Pattern Recognition. Columbus:IEEE,2014:1891-1898.

[7] SUN Y,CHEN Y H,WANG X G,et al.Deep Learning Face Representation by Joint Identification-Verification [EB/OL]. (2014-06-18)[2020-12-20]. <https://arxiv.org/abs/1406.4773>.

[8] SUN Y,WANG X G,TANG X,et al.Deeply learned face representations are sparse, selective, and robust [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition. Boston:IEEE,2015:2892-2900.

[9] KIM Y,PARK W,ROH M C,et al.GroupFace: Learning Latent Groups and Constructing Group-Based Representations for Face Recognition[C]//2020 IEEE/CVF Conference on Computer Vi-

- sion and Pattern Recognition (CVPR). IEEE,2020:5620-5629.
- [10] DUONG C N, TRUONG T D, LUU K, et al. Vec2Face: Unveil Human Faces From Their Blackbox Features in Face Recognition[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE,2020:6131-6140.
- [11] SCHROFF F, KALENICHENKO D, PHILBIN J. Facenet: A unified embedding for face recognition and clustering[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Boston:IEEE,2015:815-823.
- [12] WANG S S, CHEN Y. A joint lass function for deep face recognition[J]. Multidimensional Systems and Signal Processing, 2019,30(3):1517-1530.
- [13] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016:770-778.
- [14] HE K M, ZHANG X, REN S, et al. Identity Mappings in Deep Residual Networks[C]//14th European Conference on Computer. Amsterdam:IEEE,2016:630-645.
- [15] LIU W, WEN Y, YU Z, et al. SphereFace: Deep Hypersphere Embedding for Face Recognition[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017:6738-6746.
- [16] DENG J, GUO J, XUE N, et al. ArcFace: Additive Angular Margin Loss for Deep Face Recognition[C]//2019 IEEE Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE,2019:4685-4694.
- [17] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications [EB/OL]. (2017-04-17) [2020-12-20]. <https://arxiv.org/abs/1704.04861>.
- [18] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted Residuals and Linear Bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE,2018:4510-4520.
- [19] DONG Y, LEI Z, LIAO S C, et al. Learning face representation from scratch[EB/OL]. (2014-11-28) [2020-12-20]. <https://arxiv.org/abs/1411.7923>.
- [20] HUANG Y, WANG Y, TAI Y, et al. CurricularFace: Adaptive Curriculum Learning Loss for Deep Face Recognition[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). IEEE,2020:5900-5909.



WEI Qin, born in 1980, Ph.D, associate professor, postgraduate supervisor. Her main research interests include signal processing and fault diagnosis.

(责任编辑:李亚辉)