



基于扩展卷积神经网络与度量学习的指静脉识别

包晓安¹, 涂小妹¹, 徐璐¹, 张娜¹, 吴彪²

(1.浙江理工大学信息学院, 杭州 310018; 2.山口大学东亚研究科, 日本山口 753-8514)

摘要: 针对在传统卷积神经网络(Convolutional neural networks, ConvNet)算法中由于提取的静脉特征信息不足而导致指静脉识别准确率不高的问题, 提出了一种基于扩展卷积神经网络与度量学习的指静脉识别算法。该算法通过扩展卷积神经网络的宽度与深度来提高 ConvNet 的学习能力, 并使用难样本采样三元组(Triplet hard loss with batch hard mining, TriHard)度量学习函数作为网络损失函数训练网络。此外, 针对常用距离度量方法不能有效度量静脉特征之间的相似度的问题, 在指静脉识别阶段采用了 Wasserstein 距离度量方法, 以提高同源静脉间的相似度, 降低异源静脉间的相似度。仿真实验结果表明: 在 FV-USM 数据集上, 指静脉识别准确率达 98.33%, 较使用 ConvNet 和常用距离度量方法准确率提高了 3.56%; 在 MMCBNU_6000 数据集上, 指静脉识别准确率达 98.02%, 较使用 ConvNet 和常用距离度量方法准确率提高了 2.01%。

关键词: 深度学习; 扩展卷积神经网络; TriHard 度量学习; Wasserstein 距离度量; 指静脉识别

中图分类号: TP391.4

文献标志码: A

文章编号: 1673-3851(2020)03-0232-08

Finger vein recognition based on extended convolutional neural networks and metric learning

BAO Xiaolan¹, TU Xiaomei¹, XU Lu¹, ZHANG Na¹, WU Biao²

(1.School of Informatics Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China;
2.Department of East Asian Studies, Yamaguchi University, Yamaguchi 753-8514, Japan)

Abstract: Aiming at the problem that the accuracy of finger vein recognition is not high due to insufficient vein feature information extracted by ConvNet (convolutional neural networks) algorithm, a finger vein recognition algorithm based on extended convolutional neural networks and metric learning is proposed. The algorithm enhances the learning ability of ConvNet by extending the width and depth of the convolutional neural networks, and uses the TriHard (Triplet hard loss with batch hard mining) metric learning function as the network loss function to train the network. In addition, in order to solve the problem that common distance measurement method cannot effectively measure the similarity between vein features, a Wasserstein distance measurement method was adopted in the finger vein recognition stage to improve the similarity between homologous veins and reduce the similarity between heterogeneous veins. Simulation results show that the accuracy of finger vein recognition on the FV-USM dataset is 98.33%, which is 3.56% higher than that of ConvNet and common distance measurement methods. On the MMCBNU_6000 dataset, the accuracy of finger vein recognition is 98.02%, which is 2.01% higher than that of ConvNet and common distance measurement methods.

Key words: deep learning; extended convolutional neural network; TriHard metric learning; Wasserstein distance measurement; finger vein recognition

收稿日期: 2019-10-31 网络出版日期: 2020-01-02

基金项目: 浙江省重点研发计划项目(2020C03094); 浙江省自然科学基金青年基金项目(LQ20F050010)

作者简介: 包晓安(1973—), 男, 浙江东阳人, 教授, 硕士, 主要研究方向为图像处理、机器学习。

0 引言

生物识别技术在现代社会中发挥着越来越重要的作用^[1]。目前较为前沿的生物识别有人脸识别、指纹识别、虹膜识别、语音识别、手指静脉(指静脉)识别等。其中,指静脉具有活体识别、高度防伪、不受外部环境影响、无接触式等优点,受到越来越多的关注^[2-3],但指静脉识别还存在一定难度,如不能提取具有鲁棒性的静脉特征,不能精确度量特征之间的相似度等。因此,如何有效提取静脉特征以及精确计算特征之间的相似度成为研究难点。

目前已有较多学者提出了关于静脉特征提取的算法,并取得了一定的成果。Zhou等^[4]提出了基于最大主曲率的静脉特征提取算法,该算法通过计算静脉图像每个像素点的 Hessian 矩阵,根据 Hessian 矩阵的特征值得到每个像素点的最大曲率值,利用局部阈值将每个像素点的最大曲率值形成的曲率图转化为二值图,最终将此二值图作为静脉的特征图。蓝伟师等^[5]提出了基于分块 Local binary pattern (LBP) 和二维主成分分析 (Principal components analysis, PCA) 的特征提取算法,该算法对预处理后的感兴趣区域 (Region of interest, ROI) 进行分块,提取每个区域块的均匀 LBP 特征直方图,对每个区域块提取的特征直方图进行 PCA 降维,将降维后的主要特征信息作为静脉的特征。Yang等^[6]提出了基于宽线检测的特征提取算法,该算法以静脉图像的像素点为圆心,以一定长度值为半径作圆,将圆上每一点的灰度值与圆心的灰度值比较得到圆上每点的二值标记,对二值标记求和,如得到的和大于一定阈值则将该圆心像素点设为静脉点,否则为背景点。该算法能判断每个像素点是否为静脉点而形成二值图,将此二值图作为静脉的特征图。但是,以上特征提取算法都是基于传统图像提取特征的算法,对图像质量及手指姿态变化较为敏感,导致提取的特征不足以完全表征静脉图像信息。

近年来,深度学习在指静脉识别中展现出了独特的优势。柴瑞敏等^[7]提出了基于深度信念网络 (Deep belief network, DBN) 的指静脉识别算法,该算法利用局部配置模式 (Local configuration pattern, LCP) 算法提取静脉纹理特征,并作为 DBN 网络的输入,通过逐层训练 DBN 网络,不断调整 DBN 网络参数使模型达到最优。该算法是针对静脉图像进行分类,如果增加类别,需要重新训练网络模型。He等^[8]提出了基于改进的卷积神经网络

算法,该算法通过增加卷积层数并使用 LeaKy-Rectified linear units (LeaKy-ReLU) 作为激活函数来训练网络参数,同时在网络的损失函数中引入判别信息作为约束条件。但该算法仅在少样本训练下效果比较明显。唐溯^[9]提出了基于残差网络 (ResNet-18) 的识别算法,该算法使用 ResNet-18 作为特征提取网络,将 Triplet 损失函数作为目标函数训练网络,使用欧氏距离来计算特征之间的相似度。该算法在一定程度上能降低网络的过拟合,但该网络是一个浅层网络不能提取具有高级语义信息的特征。

针对以上问题,本文提出了基于扩展卷积神经网络与度量学习的指静脉识别算法。该算法首先对公开的数据集进行预处理^[10],然后通过扩展网络深度和宽度来提高网络的学习能力,并使用难样本采样三元组 (Triplet hard loss with batch hard mining, TriHard) 度量学习函数作为网络损失函数训练网络,从而增强网络提取特征的能力。在指静脉识别阶段,针对常用的距离度量方法不能有效地度量静脉特征之间的相似度问题,本文采用 Wasserstein 距离度量^[11-12]方法,该方法可以保留特征空间的几何分布,不仅能提高同源静脉间的相似度,同时能降低异源静脉间的相似度,以此提高算法在静脉识别中的准确率。

1 算法设计

本文提出了基于扩展卷积神经网络与度量学习的指静脉识别算法。该算法首先对公开的指静脉数据集进行预处理;其次,通过扩展 ConvNet 网络宽度和深度来提高网络提取静脉特征的能力;再次,根据构建的学习网络设计合理的损失函数,本文使用 TriHard 度量学习函数作为网络损失函数;最后,在指静脉识别阶段,通过分析常用的距离度量方法不能有效地度量静脉特征之间的相似度问题,本文使用 Wasserstein 距离度量方法计算特征向量之间的相似度。

1.1 指静脉图像预处理

直接采集的指静脉图像包含许多与静脉特征无关的区域,并且图像中存在大量的噪声,因此需要对指静脉图像进行预处理操作。首先,对指静脉原图像进行灰度化处理,然后通过拉伸的 Sobel 算子检测手指边缘,使用最小二乘法对手指边缘线进行线性拟合和断线连接得到较清晰的边缘图。其次,根据边缘图中的两条手指边缘线得到手指中线,利用

中线与水平线之间的夹角矫正原图和边缘图。再次,在矫正后的边缘图上根据边缘线确定 ROI 区域的内切线,使用此内切线在矫正后的原图像上切割得到 ROI 图像。最后,将提取出的 ROI 图像进行对比度拉伸,并归一化为 314×122 像素点的图像。MMCBNU_6000 数据集的 ROI 图像提取过程如图 1 所示,FV-USM 数据集的处理过程类似。




图 1 指静脉 ROI 提取示例图像

图像预处理可以有效地去除与静脉特征无关的区域,使网络能提取到主要的特征,同时也降低了训练网络时输入图像的尺寸大小,进而能提高网络的训练速度。

1.2 扩展 ConvNet 网络构建

ConvNet 的特征提取能力与指静脉识别的准确率有紧密的联系。在卷积神经网络的研究中,一般通过单一地扩展 ConvNet 的深度或宽度使网络能提取到更具表达能力的特征。例如,He 等^[13]通过增加网络深度将 ResNet 从 ResNet-18 扩展到 ResNet-200,而 Huang 等^[14]通过使用 4 倍宽度的基础网络在 ImageNet 数据集中获得了 84.3% 的准确率。由此可知,影响 ConvNet 效率的因素包括网络的宽度和深度,因此本文提出了同时扩展

ConvNet 的宽度与深度来增强网络提取特征的能力,下面详细介绍网络框架设计。

1.2.1 网络框架设计

ConvNet 的定义可用式(1)所示:

$$N = \bigotimes_{i=1,2,\dots,s} F_i^{L_i}(X_{(H_i, W_i, C_i)}) \quad (1)$$

其中: N 表示 ConvNet 网络; $F_i^{L_i}$ 表示层 F_i 在阶段 i 中重复了 L_i 次; \bigotimes 表示卷积运算; $X_{(H_i, W_i, C_i)}$ 表示网络输入; H_i, W_i 表示空间维度; C_i 表示通道维度。ConvNet 通常被划分为多个阶段,每个阶段的所有层共享相同的架构。因此,与其他通过改变卷积核大小而改进网络的方式不同,扩展 ConvNet 深度和宽度不会改变基准网络中的层运算关系。所以,在一定资源条件下,网络的宽度和深度可以任意扩展。

通过以上分析,本文设计了如图 2 所示的指静脉特征提取网络框架,该网络框架以 ResNet-18 为基础网络框架。网络中第 1 个卷积层的卷积核大小为 7×7 ,步长为 2,卷积核数为 128,然后经过一个大小为 3×3 ,步长为 2 的最大池化层。第 2 个卷积模块包含两个一样的卷积层,卷积核大小为 3×3 ,步长为 1,卷积核数为 128,共有 3 个这样的卷积模块。第 3 个卷积模块包含两个卷积层,卷积核大小都为 3×3 ,第一个卷积核步长为 2,第二个卷积核步长为 1,卷积核数都为 256,共有 4 个这样的卷积模块。第 4 个卷积模块包含两个卷积层,卷积核大小都为 3×3 ,第一个卷积核步长为 2,第二个卷积核步长为 1,卷积核数都为 512,共有 8 个这样的卷积模块。第 5 个卷积模块包含两个卷积层,卷积核大小都为 3×3 ,第一个卷积核步长为 2,第二个卷积核步长为 1,卷积核数都为 1024,共有 3 个这样的卷积模块。最后,经过一个大小为 2×2 ,步长为 2 的平均池化层和 2048 维的全连接层。

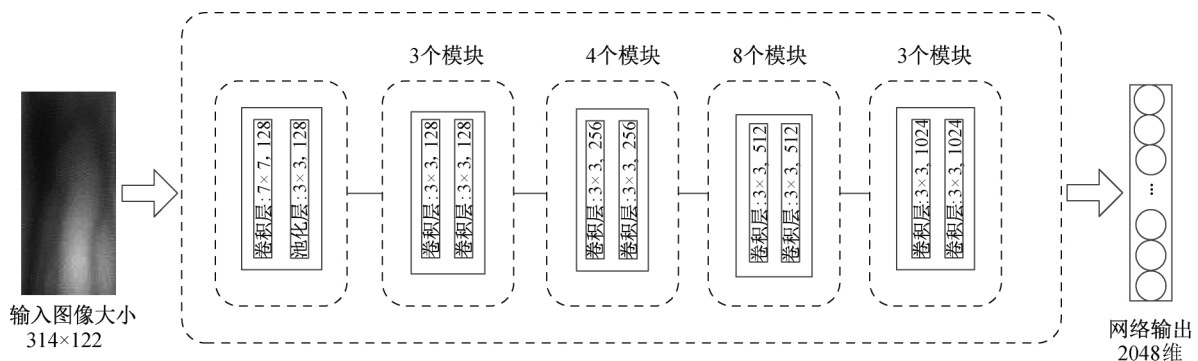


图 2 网络框架结构图

在网络的每个卷积层之后加入 BatchNorm 层和 ReLU 非线性激活函数能有效的训练网络,加快网络收敛速度。ReLU 函数如式(2)所示:

$$f(x) = \max(0, x) \quad (2)$$

其中: $f(x)$ 为输出, x 为输入。使用 ReLU 非线性激活函数,能够提高网络的收敛速度,增强网络的泛

化能力,使网络有更好的预测性能。

1.2.2 度量学习损失函数

常用的度量学习损失函数有:对比损失(Contrastive loss)^[15]、三元组损失(Triplet loss)^[16]和四元组损失(Quadruplet loss)^[17]。本文使用的TriHard损失函数是通过结合Triplet loss和Quadruplet loss改进的度量学习损失函数。

Triplet loss函数是随机从训练样本中抽样三个样本组成两个样本对,将这两个样本对的损失作为网络训练的整体损失。Quadruplet loss函数是随机从训练样本中抽取四个样本组成两个样本对,Quadruplet loss函数在Triplet loss函数的基础上考虑了正负样本间的绝对距离。但是,以上两种损失函数通过随机抽样出来的样本对大部分都简单易区分。如果大量的使用简单易区分的样本对训练网络,那么,网络将提取不到更具表征能力的识别特征。

TriHard损失函数是对于每一个训练batch,从总训练样本中随机挑选P个不同个体,每个个体随机挑选K幅不同的图像,即一个batch中含有 $P \times K$ 幅图像。对于batch中的每一幅图像a挑选出一个距离最大的正样本p和一个距离最小的负样本n,与a组成一个三元组。此时,在训练阶段,距离度量使用欧氏距离。TriHard目标函数如式(3)所示:

$$L_{\text{TriHard}} = \frac{1}{P \times K} \sum_{a \in \text{batch}} (\max_{p \in A} d_{a,p} - \min_{n \in B} d_{a,n} + \alpha)_+ \quad (3)$$

其中:A表示与图像a具有相同label的图像集;B表示与图像a具有不同label的图像集; $\max_{p \in A} d_{a,p}$ 是正样本对距离的上界; $\min_{n \in B} d_{a,n}$ 是负样本对距离的下界; α 是超参数,以避免同源手指的 $\max_{p \in A} d_{a,p}$ 和异源手指的 $\min_{n \in B} d_{a,n}$ 的学习结果变成0。

1.3 Wasserstein 距离度量

Wasserstein 距离度量方法^[18]与常见的距离度量方法不同,该方法可以保留特征空间的几何分布,因此,在度量特征时会使类内更聚合,类间更离散。如果将使用上述构建的ConvNet提取的静脉特征看作平面内的二元分布,即假设 $G_w(X_1)$ 和 $G_w(X_2)$ 是经过网络提取的两个静脉特征分布。则Wasserstein距离可用式(4)表示:

$$W(G_w(X_1), G_w(X_2)) =$$

$$\inf_{\lambda \in \Pi(G_w(X_1), G_w(X_2))} \int \int d(x, y) \lambda(x, y) dx dy \quad (4)$$

其中: $\Pi(G_w(X_1), G_w(X_2))$ 表示特征之间所有

可能的联合分布集合; $d(x, y)$ 表示特征之间的代价函数; $\lambda(x, y)$ 为从一个特征分布到另一个特征分布的运输方案; \inf 表示在所有可能方案中选择代价最小的方案,该最小代价即为Wasserstein距离。Wasserstein距离的求解^[19],有两种最优方法。a)通过给定一个正则项修正参数,使得该问题能近似的转化为Sinkhorn迭代和次梯度迭代的解。b)利用交替乘子下降(Bregman-Alternative Direction Method of Multipliers, Bregman-ADMM)分解问题,近似求解与原问题等价的最优化解。基于Sinkhorn迭代方法的收敛速度要优于Bregman-ADMM算法,所以本文使用Sinkhorn迭代求解Wasserstein距离。

在静脉识别中,Wasserstein距离度量方法比常用的距离度量方法具有更高的准确率。常用的距离度量方法有欧氏距离和余弦距离,欧氏距离的特点是计算两个特征向量之间的大小,反映特征向量之间距离的远近,余弦距离的特点是计算两个特征向量在各个维度上乘积的累加和,反映特征向量之间的方向。因为特征之间的相似度分为两个方面:一方面是特征之间的几何分布,一方面是特征之间的距离大小,所以在度量通过扩展ConvNet网络提取的特征时,如果能综合考虑这两方面因素,将能提高同源静脉间的相似度,降低异源静脉间的相似度。

2 算法步骤

根据以上构建的扩展ConvNet网络以及度量学习函数,设置初始学习率为0.01,随后每10步学习率呈指数下降,下降率 $\gamma = 0.1$ 。同时设置batch_size为16,网络训练500次。步骤1为训练扩展ConvNet网络。

步骤1 扩展卷积神经网络的训练

输入:指静脉数据集(FV-USM, MMCBNU_6000)

输出:指静脉特征向量

加载经过ImageNet预训练了的网络模型初始化ConvNet网络

设置SGD为网络权重更新方式

加载指静脉数据集

for 训练次数=1 to 500

特征图=ConvNet(指静脉数据集)

损失值= L_{TriHard} (特征图)

损失值经过SGD反向传播更新网络参数

保存模型参数

使用步骤1训练得到网络模型,将网络模型保

存为.pth文件。在指静脉识别阶段,加载保存的网络模型结构和模型参数,待识别的静脉图像经过网络模型提取静脉特征,再使用 Wasserstein 距离度量方法计算特征之间的相似度,再选择合适的阈值判断是否是同源静脉图像。步骤2为指静脉识别。

步骤2 指静脉识别

输入: X_1, X_2 (静脉识别图像)

输出:1 or 0(1表示同源静脉,0表示异源静脉)

加载 ConvNet 网络模型结构和模型参数

X_1 图像静脉特征 = ConvNet(X_1)

X_2 图像静脉特征 = ConvNet(X_2)

相似度 = Wasserstein(X_1 图像静脉特征, X_2

图像静脉特征)

if 相似度 < 阈值

Return 1

else

Return 0

3 实验仿真及结果分析

3.1 实验环境及数据集

为了分析和评估本文提出的算法的性能,本节进行了扩展前和扩展后的网络在静脉数据集上的识别效果对比实验,同时进行了 Wasserstein 距离度量与其他常用距离度量方法的对比实验,最后将本文算法与使用其他的卷积神经网络提取静脉特征的算法进行对比实验。

a) 实验环境。实验中计算机的配置如下:CPU为 Intel(R) Core(TM) i7-4790 K CPU;主频为 4.00 GHz;内存为 8 GB;系统为 Linux 4.4.0-130-generic x86_64 位;GPU为 NVIDIA Corporation GM204 (GeForce GTX 970)。采用 python3.7 和 pytorch1.0.1。

b) 数据集。本文使用的两个公开的数据集,数据集的有关信息如表1所示。FV-USM^[20]是分两期采集,每期同一个静脉图像为6张,MMCBNU_6000^[21]采集了一期,同一个静脉图像为10张,本文选用 FV-USM 数据集和 MMCBNU_6000 数据集进行实验论证。

3.2 对比实验

为了验证本文提出的基于扩展卷积神经网络与度量学习的指静脉识别算法,本节设计了三个对比实验。实验一验证提出的扩展卷积神经网络的有效性,实验二验证 Wasserstein 距离度量方法的有效性,实验三验证本文提出的指静脉识别算法的有效性。

表1 FV-USM 和 MMCBNU_6000 数据集信息

信息	数据集	
	MMCBNU_6000	FV-USM
人数/人	100	123
每人采集的手指个数/个	6	4
每根手指图像个数/个	10	6
采集时期数/次	1	2
图像总数/幅	6000	5904
图像尺寸大小(像素)	640×480	640×480

3.2.1 网络算法对比实验

为了验证本文提出的扩展卷积神经网络以及度量学习函数在指静脉识别算法中的有效性,设计了实验一。

实验采用 ResNet-18 网络结构和 Triplet 损失函数构成的算法作为算法1,使用 ResNet-18 网络结构和 TriHard 损失函数构成的算法作为算法2,采用扩展的 ConvNet 网络和 Triplet 损失函数构成的算法作为算法3,使用扩展的 ConvNet 网络和 TriHard 损失函数构成的算法作为算法4。最后使用欧氏距离计算特征之间的相似度。

实验数据集划分如下:在 MMCBNU_6000 和 FV-USM 数据集上进行算法验证,按照交叉验证法将数据集划分为10个大小相似的互斥子集,每次使用9个子集的并集作为训练集,余下的一个子集作为测试集,这样获得10组训练/测试集,取这10组测试集准确率的平均作为最后静脉识别准确率。网络参数设置如第2节算法步骤所示。指静脉识别准确率实验结果如表2所示。

表2 验证扩展卷积神经网络的识别准确率 %

实验方法	数据集	
	FV-USM	MMCBNU_6000
算法1	94.77	96.01
算法2	95.96	96.43
算法3	96.23	97.16
算法4	97.11	97.54

由表2可知,在数据集 FV-USM 中,算法2比算法1提高了1.19%,说明使用 TriHard 损失函数比使用 Triplet 损失函数能更好的训练网络。算法3和算法1比较,静脉识别准确率提高了1.46%,说明提出的扩展 ConvNet 网络能提高静脉识别准确率。最后,由算法4可知,本文提出的扩展卷积神经网络与 TriHard 度量学习函数在指静脉识别算法中要优于使用 ResNet-18 网络结构和 Triplet 损失函数。在数据集 MMCBNU_6000 上静脉识别准确率也有同样的提高。

此外,各算法的受试者工作特征曲线(Receive operating characteristic curve, ROC)与 P-R 曲线如

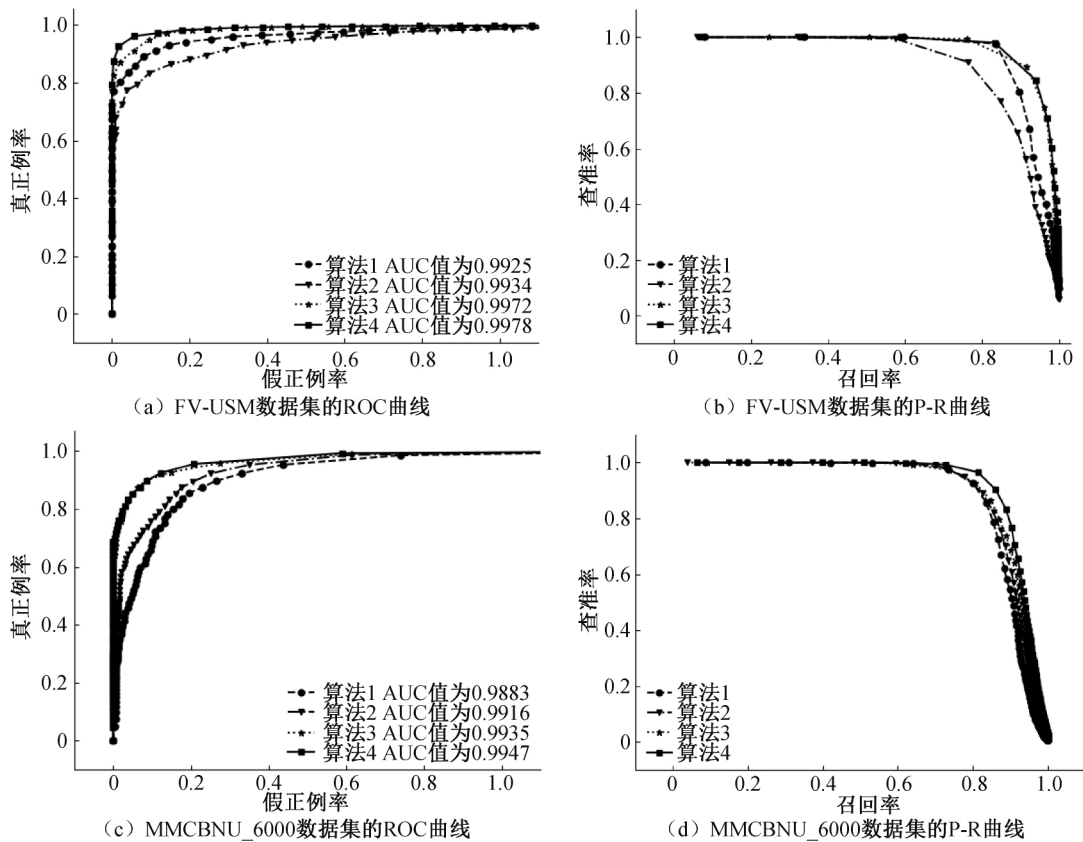


图3 FV-USM和MMCBNU_6000数据集的实验曲线

图3(a)和图3(c)表示在数据集FV-USM和MMCBNU_6000上验证的ROC曲线,其中,横轴为假正例率,纵轴为真正例率。根据ROC曲线计算的AUC可以看出,算法4的AUC值比其他算法的AUC值更大,AUC值越大表明网络模型越能提取具有表达能力的静脉特征。图3(b)和图3(d)表示在数据集FV-USM和MMCBNU_6000上验证的Precision-Recall曲线,其中,横轴为召回率,纵轴为查准率。在P-R曲线中,算法4的曲线比其他三种算法的曲线右突出更明显,表示算法4的网络模型更具鲁棒性。综上所述,使用扩展的卷积神经网络以及TriHard度量学习算法,在静脉识别中有更高的准确率。因为本文扩展的ConvNet较好的平衡了网络的深度和宽度,当只扩展网络宽度时,网络学习图像的精细特征能力比学习图像的高级语义特征能力强。同理,当只扩展网络深度时,网络学习图像的高级语义特征能力比学习图像精细特征的能力强。当同时扩展网络深度和宽度时,ConvNet能学习到更全面的特征。

3.2.2 Wasserstein距离度量对比实验

为了验证Wasserstein距离度量的有效性,在

图4所示,从图4中可以看出,算法4与其他算法相比较,算法4的网络模型具有更好的鲁棒性。

实验3.2.1的基础上设计了实验二。首先,使用扩展的ConvNet来提取静脉特征。其次,分别使用Wasserstein距离、欧氏距离和余弦距离进行特征之间的相似性计算。最后,设定合适的阈值将静脉特征判别为同源静脉或异源静脉。由于Wasserstein度量的是一个分布,因此,需要将特征编码转化为一个 x, y 的分布。Wasserstein距离度量正则化系数为0.1,迭代次数为100。实验结果如表3所示。

表3 Wasserstein与常见距离度量方法在

公开数据集上的准确率

度量方式	数据集	
	FV-USM	MMCBNU_6000
Wasserstein 距离	98.33	98.02
欧氏距离	97.11	97.54
余弦距离	96.82	96.94

根据表3可知,在同一测试集下,Wasserstein距离度量有更高的准确率,即对于同源静脉特征,使用Wasserstein距离度量会更有可能会将它们判别为同一类别,相反,对于异源静脉特征,Wasserstein距离度量能更好的将它们归为不同类别。

3.2.3 与其他 ConvNet 网络对比实验

为了验证本文算法的有效性,设计了此实验。在两个公开数据集 FV-USM 和 MMCBNU_6000 下,将本文扩展 ConvNet 网络与其他卷积神经网络(VGG16、AlexNet 和 CapsNet)进行对比实验,实验环境与网络参数设置同 3.2.1 节。为了实验验证的公平性,在网络训练阶段,使用欧氏距离计算静脉特征之间的相似距离,将此距离值作为网络训练的损失值,该损失值通过反向传播更新网络参数。在指静脉识别阶段,都使用 Wasserstein 距离度量方法计算特征之间的相似度。实验结果如表 4 所示。

表 4 本文算法与其他 ConvNet 网络静脉识别准确率 %

识别算法	数据集	
	FV-USM	MMCBNU_6000
本文算法	98.33	98.02
VGG16	97.50	97.78
AlexNet	96.93	96.44
CapsNet	96.08	96.12

根据表 4 可知,在相同的实验环境下,本文算法要优于其他使用 ConvNet 网络提取静脉特征算法。这是因为通过扩展 ConvNet 网络深度和宽度,网络不仅能提取到图像的精细语义特征,而且能获得图像中的高级语义信息,从而能获得较好的准确率。

4 结 论

本文提出了一种基于扩展卷积神经网络与度量学习的指静脉识别算法,该算法通过扩展网络的深度和宽度来提高卷积神经网络的学习能力,并使用 TriHard 度量学习函数作为网络损失函数训练网络,从而增强网络提取静脉特征的能力。通过在 FV-USM 和 MMCBNU_6000 数据集上对所提算法进行验证,实验结果表明:扩展 ConvNet 能有效的提高指静脉识别的准确率。

在指静脉识别阶段,本文还使用了可以保留空间几何特性的 Wasserstein 距离度量方法计算特征之间的相似度,该度量方法能提高同源静脉间的相似度,降低异源静脉间的相似度,从而提高指静脉识别的准确率。对所提出的度量方法在 FV-USM 和 MMCBNU_6000 数据集上进行验证,实验结果显示:在指静脉识别中使用 Wasserstein 距离度量方法较使用其他距离度量方法静脉识别准确率高。

尽管本文算法在指静脉识别中获得了较高的准确率,但是存在一些不足,如需要更多的硬件资源训

练扩展后的网络,如果网络参数设置不当,训练时容易发生梯度消失的现象。

参考文献:

- [1] 李鹏飞, 淡美俊, 姚宇颀. 生物识别技术综述[J]. 电子制作, 2018(10): 89-90.
- [2] Lu Y, Wu S Q, Fang Z J, et al. Exploring finger vein based personal authentication for secure IoT[J]. Future Generation Computer Systems, 2017, 77: 149-160.
- [3] 尹义龙, 杨公平, 杨璐. 指静脉识别研究综述[J]. 数据采集与处理, 2015, 30(5): 933-939.
- [4] Zhou L Z, Yang G P, Yin Y L, et al. Finger vein recognition based on stable and discriminative superpixels [J]. International Journal of Pattern Recognition and Artificial Intelligence, 2016, 30(6): 1650015.
- [5] 蓝师伟, 沈雷. 基于多特征阈值融合的手指静脉识别算法[J]. 杭州电子科技大学学报(自然科学版), 2018, 38(5): 24-28, 84.
- [6] Yang J F, Shi Y H. Towards finger-vein image restoration and enhancement for finger-vein recognition [J]. Information Sciences, 2014, 268: 33-52.
- [7] 柴瑞敏, 但称称. 一种改进的深度置信网络及其在自然图像分类中的应用[J]. 计算机应用与软件, 2016, 33(9): 221-223, 244.
- [8] He X, Chen X. FVR based on deep learning and improved Gabor feature fusion [J]. Computer Simulation, 2018, 35(11): 356-361.
- [9] 唐溯. 基于深度学习的指静脉识别算法研究[D]. 广州: 华南理工大学, 2018: 19-35.
- [10] 夏锋, 李重, 沈益. 基于张量特征分解的三维网格模型降噪[J]. 浙江理工大学学报(自然科学版), 2018, 39(3): 333-340.
- [11] 郑昌金, 章登义, 苏科华, 等. 基于 LBP 特征和熵正则化 Wasserstein 距离的人脸表情识别[J]. 计算机与数字工程, 2017, 45(2): 242-246.
- [12] 包晓安, 高春波, 张娜, 等. 基于生成对抗网络的图像超分辨率方法[J]. 浙江理工大学学报(自然科学版), 2019, 41(4): 499-508.
- [13] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). New York, USA: IEEE, 2016: 770-778.
- [14] Huang Y P, Cheng Y L, Chen D, et al. Gpipe: Efficient training of giant neural networks using pipeline parallelism[EB/OL]. (2018-11-16)[2019-07-25]. <https://arxiv.org/abs/1811.06965>
- [15] Varior R R, Haloi M, Wang G. Gated Siamese

- convolutional neural network architecture for human Re-identification [C]//Computer Vision – ECCV 2016. Cham: Springer International Publishing, 2016: 791-808.
- [16] Alexander H, Lucas B, Bastian L. In defense of the triplet loss for person Re-Identification [EB/OL]. (2017-03-22) [2017-11-21]. <https://arxiv.org/abs/1703.07737>.
- [17] Chen W H, Chen X T, Zhang J G, et al. Beyond triplet loss: A deep quadruplet network for person Re-identification [C] //2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017. New York, USA: IEEE, 2017: 1320-1329.
- [18] Deshpande I, Zhang Z Y, Schwing A. Generative modeling using the sliced Wasserstein distance[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New York, USA: IEEE, 2018: 3483-3491.
- [19] Martin A, Soumith C, Leon B. Wasserstein GAN[EB/OL]. (2017-01-26) [2017-12-6]. <https://arxiv.org/abs/1701.07875>.
- [20] Mohd Asaari M S, Suandi S A, Rosdi B A. Fusion of band limited phase only correlation and width centroid contour distance for finger based biometrics[J]. Expert Systems with Applications, 2014, 41(7): 3367-3382.
- [21] Neumann C, Tönnies K, Pohle-Fröhlich R. AngioUnetA convolutional neural network for vessel segmentation in cerebral DSA series[C]//Proceedings of the 13th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications, 2018. Funchal, Madeira, Portugal: Science and Technology Publications, 2018: 331-338.

(责任编辑:康 锋)