

基于深度学习的污损指纹识别研究

吴震东^{*①} 王雅妮^② 章坚武^②

^①(杭州电子科技大学网络空间安全学院 杭州 310018)

^②(杭州电子科技大学通信工程学院 杭州 310018)

摘要: 随着社会信息化水平的提高及不稳定因素的增加,人们迫切需要更加可靠的识别技术对身份进行认证。因此,利用生物特征进行鉴定已成为时下热潮。其中的指纹识别更是因其方便性和可靠性受到普遍认同。传统的指纹识别方法基于特征点比对寻求相似性,此种方法特征点寻找容易出错,且随着指纹的模糊、破坏、污损或是其他问题,均会使识别率明显降低。针对这些问题,该文提出基于深度卷积神经网络(CNN)的CBF-FFPF(Central Block Fingerprint and Fuzzy Feature Points Fingerprint)算法对污损指纹图像进行分类识别。CBF-FFPF算法提取指纹中心点分块图像及特征点模糊化图,合并后输入CNN网络,进行指纹深层特征识别。将该算法与基于主成分分析(KPCA)、超限学习机(ELM)和k近邻分类器(KNN)的指纹识别算法进行比较,实验结果表明,所提出的CBF-FFPF算法对污损指纹识别有更高的识别率和更好的鲁棒性。

关键词: 指纹识别; 卷积神经网络; 分块指纹; 指纹深层特征。

中图分类号: TP391.4

文献标识码: A

文章编号: 1009-5896(2017)07-1585-07

DOI: 10.11999/JEIT161121

Fouling and Damaged Fingerprint Recognition Based on Deep Learning

WU Zhendong^① WANG Yani^② ZHANG Jianwu^②

^①(School of Cyberspace, Hangzhou Dianzi University, Hangzhou 310018, China)

^②(School of Communication Engineering, Hangzhou Dianzi University, Hangzhou 310018, China)

Abstract: With the development of information technology and the increasing demanding of information security, people are urgently in need of more reliable identification techniques for identity authentication. Therefore, the biometric recognition methods have become a compelling issue. Among the methods, the fingerprint identification technique attracts much interest due to its excellent feasibility and reliability performance. The traditional fingerprint recognition method is based on matching feature points. However, this method needs a long time to find the feature points, and suffering the blur, scaling, damage, and other problems, the recognition rate is decreased seriously. To solve these problems, a fouling and damaged fingerprint recognition algorithm named CBF-FFPF (Central Block Fingerprint and Fuzzy Feature Points Fingerprint) is proposed, it is based on Convolution Neural Network (CNN) of deep learning. Combining small sub block fingerprint, which takes the fingerprint core point as the center from the thinned image and fuzzy graph of fingerprint feature points, as original image input to obtain the recognition rate. The recognition rate based on CBF-FFPF is compared with the fingerprint identification algorithm based on Kernel Principal Component Analysis (KPCA), Extreme Learning Machine (ELM), and K-Nearest Neighbor (KNN). Experimental results show that fingerprint recognition algorithm CBF-FFPF has higher recognition rate and better robustness.

Key words: Fingerprint identification; Convolution Neural Network (CNN); Sub block fingerprint; Fingerprint deep character

1 引言

在当今社会中,身份鉴定越来越重要,其应用

也日益广泛。传统的身份鉴定手段包括:(1)持有物,如身份证、信用卡、钥匙等;(2)鉴定知识,如密码,口令,暗语等。然而,这些鉴定手段总存在着丢失、遗忘,甚至被破译的风险。因此,利用生物识别技术克服传统身份认证方法缺点,使识别更加准确和方便,受到重视。每个生物个体都包含着与其他个体不相同的生理特征,如指纹,掌纹,声纹,虹膜等等,而生物识别技术(Biometric Identification Technology, BIT)^[1]正是利用这些特征进行身份识别。

收稿日期: 2016-10-21; 改回日期: 2017-04-01; 网络出版: 2017-05-11

*通信作者: 吴震东 wzd@hdu.edu.cn

基金项目: 国家重点研发计划(2016YFB0800201), 浙江省自然科学基金(LY16F020016), 浙江省重点科技创新团队项目(2013TD03)

Foundation Items: The National Key Research and Development Program of China (2016YFB0800201), The Natural Science Foundation of Zhejiang Province (LY16F020016), Zhejiang Provincial Science and Technology Innovation Program (2013TD03)

识别质量较好的指纹^[2]已达到较高的水准,而对污损指纹的识别难以有突破。目前,研究者主要通过挖掘污损指纹的潜在特征对污损指纹识别开展研究工作。Liu 等人^[3]提出了一种指纹随机本地区域描述子(Random Local Region Descriptor, RLRD)。RLRD 利用指纹本地方向场构建具有旋转不变性的节点对相对方向描述子。它在处理质量较高的指纹图像时效果较好,但对于质量不高的指纹图像,方向场提取阶段会引入大量噪声,使得方向场计算出现较高误差,因此难以取得较好效果。Paulino 等人^[4]对污损指纹图像研究了基于部分方向场图的指纹校准与匹配方法,提出了基于 Hough 变换的方向场统计特征匹配方法。因运用了统计特征,使得该方法能够在一定程度上克服方向场计算误差。但由于 Hough 变换在克服方向场误差的同时损失了大量的方向场整体特征信息,使得该方法对于不同指纹的区分度不理想。Feng 等人^[5]针对污损指纹方向场估计困难的问题,提出了基于指纹结构先验知识的方向场估计算法。算法利用节点周围方向场集合构建方向场知识字典,作为指纹方向场估计的先验知识库,用能量最小化模型求解当前节点的最佳方向场值。以上研究均提取并发掘了污损指纹的部分潜在特征,提升了污损指纹的识别准确率。但是由于仅依靠人工分析,所提取的特征数量偏少,针对复杂情况,单一特征容易失效。对于污损指纹,需要能挖掘更多有效特征的自动化方法。

本文针对污损指纹识别问题,考虑人眼对低质量指纹识别率远大于机器识别率的现实,判断人眼能捕获比现有指纹特征更多的指纹特征信息,提出运用深度神经网络对指纹图像进行深度学习,提取指纹的深层特征信息,从而改善污损指纹识别率的研究方法。具体为:将指纹图像进行分块处理,提取以指纹中心点为中心的指纹图像块表示训练样例的部分特征,另外提取污损指纹图像所能提取到的部分特征点,并将之模糊化,作为训练样例的另一部分特征。此种方式简化了复杂的残损指纹修复过程,且训练图像含有丰富的可提取特征信息空间。最后,我们利用深度 CNN 算法结构模拟人脑对指纹图像的多层信息特征提取方式,对上述组合训练图像进行自动特征提取,并进行分类识别。实验结

果表明,将两种图像块进行组合,经 CNN 算法训练、识别的方式对识别率提高可做出较大的贡献。本文的主要贡献为:(1)开展了针对指纹识别的深度神经网络信息处理研究;(2)提出了一种有效的指纹深层特征信息学习算法 CBF-FFPF,该算法可自动提取指纹深层特征信息,从而改善污损指纹识别的准确率。

本文结构安排如下:第 1 节具体介绍研究现状和本文的研究内容;第 2 节介绍指纹识别技术和卷积神经网络;第 3 节提出本文模型并具体介绍算法流程;第 4 节具体描述实验步骤及实验结果;第 5 节给出结论及未来的工作计划。

2 相关技术和原理

2.1 指纹识别技术

指纹识别,依靠指纹的纹理所形成的能够表征个人身份的唯一特性,将其与个人身份对应起来,通过比对预先保存的库指纹特征,实现个人身份的认证与鉴别。指纹识别的流程如图 1 所示。

2.1.1 指纹图像预处理 将彩色指纹图像处理成灰度图像后,利用各种算法再将之处理成便于提取特征的仅有黑白两个值的指纹图像,这就是指纹图像预处理^[6]。预处理是影响后续操作的关键一步。指纹图像预处理主要包含:(1)指纹增强。采用例如高斯平滑、Gabor 小波滤波等使指纹图像的纹路更清晰;(2)指纹图像二值化。二值化是将灰度图转化为仅有 0 和 1 的二值图像,将纹线分离开,解决粘连问题;(3)指纹图像细化^[7]。对于指纹这种特殊的图像,我们所关注的其实是纹线的方向走势,纹线的粗细会因为采集者按压的力度而有差异,影响识别的准确度。

在经过上述的指纹增强,二值化与细化等操作之后,由于扫描时的平移与旋转角度不同,往往在几何位置上不能完全匹配,于是需要一个对指纹进行平移、旋转的过程。选择一张基准指纹图片,记为 PIC,其中心点记为 (x_{c0}, y_{c0}) ,指纹中心点与图片中心点重合。

(1)平移量的确定:以待处理指纹的中心点 (x_{c1}, y_{c1}) 为参考点,平移量由待处理指纹中心点距离基




图 1 指纹识别流程




图2 指纹图像预处理

准图像中心点 (x_{c0}, y_{c0}) 的偏移量确定, 记平移好后的图片为 move_PIC;

$$\begin{cases} \Delta x = x_{c0} - x_{c1} \\ \Delta y = y_{c0} - y_{c1} \end{cases} \quad (1)$$

(2)旋转量的确定: 旋转操作是在平移后的图片 move_PIC 基础上进行的。旋转量 θ_c 如图3所示, 通过计算纹线方向场最大曲率, 可得如图直线, 将直线旋转至图片中线位置, 所得角度即为旋转量 θ_c 。按此方法, 最终可以得到对齐后图片, rota_PIC。




图3 旋转量的确定

2.1.2 特征提取与指纹匹配 指纹的特征点包括中心点、三角点、端点、叉点等。指纹的形状特征包括弓形、帐篷弓形、右旋、左旋、漩涡形、双旋形6大类。通过适当的算法对原始指纹图像进行预处理, 就可以在处理后的图像上得到特征点的相关信息, 包含数目、位置以及指纹纹线的走向。本文采用卷积神经网络算法, 通过机器训练自动寻找特征信息, 简化了人工或各种其他算法提取特征的繁琐过程。采集器采集到的未知指纹, 通过与指纹库中的指纹进行匹配, 判断该枚指纹属于哪一个人。

2.2 卷积神经网络(CNN)

深度神经网络^[8,9]是利用某种算法建立起类似于人脑的简单模型, 即将复杂的信息仅用小部分基元素的线性组合进行表达。而卷积神经网络是其中一个较为成功的模型。它利用局部权值共享, 使得人工神经网络向生物神经网络进一步靠近, 让网络更趋于简单化, 大大缩短了训练时间。

2.2.1 卷积神经网络结构 卷积神经网络如图4所示, 其基本组成层是输入层, 卷积层, 下采样层和输出层。基本步骤如下: 第1步, 图像经过简单的大小调整, 使得输入到输入层的每幅图像大小一致。第2步, 输入层后紧接着卷积层。卷积层的作用是




图4 卷积神经网络结构

通过几个权值不同的卷积核对图像的局部进行滤波操作, 卷积核的数量即相同位置可得到的不同特征的数量。因此, 一个卷积核就可得到一幅特征图 (Feature Map)^[10]。第3步, 卷积层后面一般会跟随着下采样层 (不是绝对), 它通过最大池化或平均池化操作进一步缩小特征图的大小并在某种程度上保持了特征的旋转和移位不变性。第4步, 经过几层的卷积层^[11]与下采样层相间的处理, 最后通过一个全连接操作对图片进行分类识别。所有的权值和偏置都利用BP算法进行调整。

2.2.2 卷积神经网络的训练过程 如图4所示, 输入图片的大小被规整为 32×32 。而C1和S2, C3和S4均为卷积层和池化层相间, 最后连接的是一层全连接层。

(1)卷积: 卷积运算的一个重要特点是, 一种卷积核可提取输入图片的一种特征, 而一定数量的卷积核能提取出图片已知的各类特征。在图像处理中, 不同的卷积核可滤波出图像不同的特征, 如:

可锐化图像边缘的卷积核 $\begin{bmatrix} -1 & -1 & -1 \\ -1 & 9 & -1 \\ -1 & -1 & -1 \end{bmatrix}$; 可检测水平

边缘的卷积核 $\begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ -1 & -1 & 2 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix}$ 及图像垂直边缘的卷

积核 $\begin{bmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{bmatrix}$ 。

在卷积神经网络中,卷积核的大小可人为设定,而卷积核中的值先是通过随机初始化,然后通过训练调整得到。简单来说,这里的卷积层可理解为网络的参数层,由BP算法调整而得,得到这些卷积核也就是整个网络训练的最终目的。

(2)池化: 最常见的池化操作为平均池化和最大池化,两种池化方式得到的结果相似,都减少了参数个数并保持局部范围旋转、平移、伸缩等不变性。 S_2 中包含4个 14×14 的特征图。前一层的特征图中每 2×2 不重叠的邻域取平均,替代激活函数中的输入,最后得到4个输出特征图。由于邻域为不重叠的 2×2 区域,因此 S_2 的结果是 C_1 中特征图缩小 $1/4$ 得到的。完成这一步后,相当于卷积后的大图片缩小为原来的 $1/4$,因此进一步降低了数据的维度,有效地避免了过拟合。

3 污损指纹识别

和直接输入指纹图像进行深度学习的指纹识别模型不同的是,本文所提出的模型对指纹图像进行了有利于深度学习的预处理,有针对性地模糊化指纹浅层特征信息处理图像,试图突出指纹特征信息同时减弱偏移、污损等噪声对指纹信息的干扰。模型命名为CBF-FFPF(Central Block Fingerprint and Fuzzy Feature Points Fingerprint),该模型利用指纹中心点所富含的特征形状信息和存在的特征点之间的相对位置^[12]及相互关系等信息作为训练的输入图像信息,这种模型有着更高的识别率。

3.1 以指纹中心点为中心的分块指纹(CBF)

对于中心点的提取原理是基于方向场的剧烈变化,采取Poincare公式^[13],这是提取指纹图像中心点的经典方式。 O' 为方向场,式(2)给出的是假定奇异点 (i, j) 的Poincare值计算公式:

$$\text{Poincare}(i, j) = \frac{1}{2\pi} \int_0^{2\pi} \frac{\partial}{\partial \theta} O'(i + \varepsilon \cos \theta, j + \varepsilon \sin \theta) d\theta \quad (2)$$

由于奇异点的特殊性,中心点与三角点的平均方向场差值为 π 与 $-\pi$,而一般的图像区域对应的值为0。因此根据Poincare公式,我们就可以知道中心点与三角点所对应的Poincare值为 $1/2$ 与 $-1/2$ 。

CBF算法是在经过预处理得到污损指纹细化图的基础上,再利用Poincare公式找到细化指纹图的中心点。然后截取指纹中心点的图像块。该步骤的目的是简化修复缺损指纹^[14]的步骤,但又提取了样本的中心点及形状特征。

3.2 指纹特征点模糊化图(FFPF)

某点的灰度值与周围8个点的灰度值作差并取

绝对值相加,和为 2×255 是端点,和为 6×255 是叉点。

为了对特征点图进行模糊化处理,我们所采用的方法是Kriging径向基函数。其函数表达式为: $\phi(r) = e^{-r^2/\sigma^2}$ 。 σ 称为径向基函数的扩展常数,它的大小变化可反映在函数图像的宽度。即图像的宽度随着 σ 的变小而变窄。Kriging径向基函数是基于局部最优线性无偏估计的,为较常用径向基函数,它能够实现非线性映射而且较少的参数也简化了计算的复杂度。

我们利用上述方法得到残损指纹的特征点并将之模糊化。这一步骤是为了弱化具体的指纹线条,突出强调特征点及特征点之间的相互关系,相对弱化它们的具体位置,这样具有较高的旋转移动不变性。

3.3 CBF-FFPF算法

经过上述两个步骤的提取之后,为了充分利用污损指纹的所有信息,我们需要将中心点块图和特征点模糊化图经过大小调整并适当去掉两种图像的空白边缘,上下拼接后再去掉部分空白拼接部分成为一幅图输入到输入层,如图5所示。




图5 合并图

模型前几层主要采用局部连接的方式,而最后一层则采用全连接的方式,参数和权重调整采用BP算法。算法具体介绍如下:

(1)卷积层卷积: 在一个卷积层上,其特征图是由几个不同的卷积核分别与上一层的输出特征图进行卷积,之后再通过一个激活函数得到, $f(\cdot)$ 表示激活函数。每一个输出图可能是卷积多个输入图的加权和:

$$X_j^\ell = f \left(\sum_{i \in M_j} X_i^{\ell-1} * K_{ij}^\ell + b_j^\ell \right) \quad (3)$$

(2)下采样层采样: 下采样层的作用是按一定比例减小与之相连的前一层输出图的维度,但不改变输出特征图的数量。其公式为

$$X_j^\ell = f \left(\beta_j^\ell \text{down} \left(X_j^{\ell-1} \right) + b_j^\ell \right) \quad (4)$$

这里的 $\text{down}()$ 表示一个下采样函数, 它可使输出图像缩小 n^2 倍。这里的激活函数与其他层的相一致。

(3) 反向传播 BP 算法调整参数:

(a) 前向传播: 对于多类问题, 共 C 类, N 个训练样本, 代价函数用平方误差函数来表示, 即

$$E = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^C (t_k^n - y_k^n)^2 \quad (5)$$

$$y_k^n = f \left(\sum_{i=1}^L W_{ij} x_i + b_j \right) \quad (6)$$

其中, t_k^n 表示第 k 类样本中的第 n 幅图的理想标签值, y_k^n 表示该输入图所对应的网络输出标签值。

(b) 反向传播: 反向传播误差即代价函数对权重 W 与偏置 b 的偏导数, 参数更新定义如式(7), 式(8), 其中 α 为学习率:

$$W_{ij} = W_{ij} - \alpha \frac{\partial}{\partial W_{ij}} E(W, b) \quad (7)$$

$$b_j = b_j - \alpha \frac{\partial}{\partial b_j} E(W, b) \quad (8)$$

(4) 识别率计算: 输出标签值与理想标签的误差可以表示为: $\varepsilon = \|O - T\|$ 。其中, T 为理想标签值。

找到符合 $\varepsilon \leq 0.1$ 的样本并统计出个数, 即可得到识别率, 如式(7):

$$\text{correct} = \sum x / M \quad (9)$$

其中, 当 $\varepsilon \leq 0.1$ 时, x 取 1, 当 $\varepsilon > 0.1$ 时, x 取 0。分母 M 为总的测试数据图片个数。

CBF-FPPF 算法的目的是最大可能地运用样本的所有信息, 并在一定程度上减小了训练样本的大小, 即输入层图像向量的个数减少, 从而缩短训练时间并提高识别率。本文算法节省了修复残损指纹的时间, 且充分运用了污损指纹所有的信息。

4 实验结果与分析

本实验的测试指纹库来自于 SF 自采指纹库, 进行了盲对齐处理。该指纹库是在实验室环境中, 随机选取 38 个人作为样本来源, 每个人 20 幅指纹图像。采集过程进行了指纹污损预处理, 如手指沾水、涂色等。通常采用 3:1 的比例, 随机抽取指纹图像进行训练与测试, 原图的大小为 492×442 。

本文所采用的 CNN 模型是 7 个隐层, 每层的激活函数均采用 sigmoid 函数, 在图像输入层, 统

一把图像的大小统一调整为 227×227 , 方便后面的特征提取。CNN 的参数设置如图 6 所示。

根据本文算法, 实验分为 4 个步骤:

(1) 截取以指纹中心点为中心的图像块, 截取后图片的大小为 326×247 ;

(2) 提取经过预处理的缺损指纹的所有特征点并将之模糊化, 图像有所扩大, 为 492×442 ;

(3) 由于指纹特征点模糊化图运用了径向基函数, 会扩大原图像素点数, 使得特征点模糊化图大于中心块图。因此需要调整中心点块图和特征点模糊化图大小并去掉一些空白边缘, 最后合并成一幅图, 合并后的图像大小为 356×234 ;

(4) 将合并好的图调整大小为 227×227 , 再输入到卷积神经网络中进行训练识别, 并得出识别率。

另外, 对于本文的算法, 我们还粗略的研究了迭代次数对训练过程中损失函数值的影响, 实验结果如图 7 所示。从该实验结果可看出, 迭代次数的增加使得损失下降, 且两者呈非线性关系。因此, 为了得到较小的损失和较短的训练时间, 我们需要选择合适的迭代次数。本文所选取的迭代次数为 5000 次。

为了验证深度学习在指纹识别方面^[15,16]确实有着较大的优势, 本实验采用了基于核的主成分分析(KPCA)算法, 超限学习机(ELM)算法和 K 近邻分类器(K-Nearest Neighbor, KNN)来与之对比。KPCA 方法^[17]是先将输入映射到高维空间(常称为特征空间)中, 然后在高维空间中实现 PCA。ELM 方法^[18]是先随机给定输入层到隐层的权值和偏置, 根据最小二乘法来求得到隐藏层到输出层的权值和偏置。 K 近邻分类算法属于被动分类, 即边测试边训练建立分类模型。

实验结果如表 1 和图 8 所示。其中, 表 1 的实验是改变输入图片的种类和算法, 比较两者对识别率的影响。图 8 的实验是比较 4 种算法在输入图像为合并图时对不同样本训练数所得到的不同识别率的关系。

为了验证本文的算法有着较好的抗噪性能, 我们在原先 SF 盲对齐指纹库的基础上加上高斯白噪声, 并重复上述步骤, 实验结果如表 2 所示。

从表 1 可以看出, CNN 算法在指纹识别方面比其他 3 种图片分类算法有明显的优势, KNN 算法比 CNN 算法的识别率略低, 而另两种算法的识别率明




图6 本文所用的CNN模型




图7 损失与迭代次数的关系




图8 训练样本数与识别率的关系

表1 不同输入图像与算法对识别率的影响(%)

算法	CNN	KPCA	ELM	KNN
预处理过的指纹图像原图	91.25	42.63	44.38	67.61
中心点图	94.73	81.05	63.75	90.22
特征点模糊化图	95.38	76.32	68.75	91.74
合并图	98.68	77.89	80.99	92.61

表2 不同算法的抗噪性能比较(%)

算法	CNN	KPCA	ELM	KNN
预处理过的指纹图像原图	90.73	42.63	54.38	65.44
中心点图	93.45	80.53	42.50	88.57
特征点模糊化图	94.77	77.89	84.39	15.77
合并图	97.38	77.37	69.3	92.53

显偏低；从图8可看出除ELM算法外的3种算法，其识别率都是随着训练样本数的增加而增加，ELM由于过拟合情况的出现使得识别率随着训练样本数的增加而减小；从表2可看出CNN还有着较好的抗噪性能。但是无论采取何种算法对污渍指纹进行识别，输入图像的有效性处理是提高识别率的关键，这在表1中有所体现。

单纯的识别率无法全部代表算法的优劣，为了验证本文算法的性能，我们在上述实验的基础上增加了误识率(FRR)与拒识率(FAR)的计算。误识率，为将原本匹配不成功的图误识为能匹配成功的概率；而拒识率正好与之相反，为将原本应该匹配成功的图拒识为不能匹配的概率。两者中的任一个较大，都说明算法的性能不理想。匹配的概念指的是两个样本间的欧式距离小于某一个阈值，否则即为不匹配。

预设阈值为TH，对于类内匹配，如果匹配值 $th > TH$ 就会错误拒绝；同理，对于类间匹配，如果匹配值 $th < TH$ 就会被认为是属于同一类，这种情

况就是错误接收。计算公式为 $FRR = NFR / NGRA \times 100\%$, $FAR = NFA / NIRA \times 100\%$ 。其中，NGRA是类内测试的总数，NIRA是类间测试的总数，NFR和NFA是错误拒绝和错误接受的次数。本实验随机选取20个人的任意10个样本作为测试数据，则 $NGRA = 20 \times (10 \times 9) / 2 = 900$, $NIRA = 200 \times 199 / 2 - NGRA = 19000$ 。

本实验中设定TH为55，并提取出所有图片的第7个全连接隐层。计算FRR时，对每一类的两两图片之间计算欧式距离，若计算结果大于TH，则错误拒绝，那么NFR加一；而计算NFA时，则需要计算类与类所有图片之间的欧氏距离，若计算结果小于TH，则错误接收，那么NFA加1。最终，我们得到NFR为14，NFA为276，则所得到的FRR和FAR分别为1.56%和1.45%，由此证明本算法的性能较为优越。

从时间方面来看，CNN算法需要较长的训练时间，一般半小时到一小时不等，这是特征提取充分程度与时间上的矛盾点。但识别时，CNN算法仅需要<1s的时间就可对一幅未知图像进行分类识别。因此，如何提高训练效率也是我们今后需要改进的地方。

5 结束语

本文研究污渍指纹分类识别，通过采用图像截取法对原污渍指纹图像进行截取完整的中心块图像和提取污渍指纹现有的特征点模糊化图作为训练图像，最后利用CNN算法进行分类识别。实验结果表明，相比于其他指纹识别算法，本文算法对污渍指纹的识别效果更佳。可以推知，CNN算法对于指纹图像不同的预处理图，识别效果差异很大。在以后的工作中，我们将对CNN深度神经网络的指纹特征识别原理进行更深入的分析，对参数等方面进行调整完善，争取获得更高的识别率及较短的训练时间，尤其是针对污渍指纹的训练识别。

参考文献

- [1] HAGHIGHAT M, ZONOUZ S, and ABDEL-MOTTALEB M. CloudID: Trustworthy cloud-based and cross-enterprise biometric identification[J]. *Expert Systems with Applications*, 2015, 42(21): 7905–7916. doi: 10.1016/j.eswa.2015.06.025.
 - [2] JAIN A K, FENG J J, and NANDAKUMAR K. Fingerprint matching[J]. *Computer*, 2010, 43(2): 36–44. doi: 10.1109/MC.2010.38.
 - [3] LIU Eryun, ZHAO Heng, LIANG Jimin, *et al.* Random local region descriptor (RLRD): A new method for fixed-length feature representation of fingerprint image and its application to template protection[J]. *Future Generation Computer Systems*, 2012, 28(1): 236–243. doi: 10.1016/j.future.2011.01.001.
 - [4] PAULINO A A, FENG J J, and JAIN A K. Latent fingerprint matching using descriptor-based hough transform [J]. *IEEE Transactions on Information Forensics and Security*, 2011, 8(1): 31–45. doi: 10.1109/IJCB.2011.6117483.
 - [5] FENG J J, ZHOU J, and JAIN A K. Orientation field estimation for latent fingerprint enhancement[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(4): 925–940.
 - [6] KRISH R P, FIERREZ J, RAMOS D, *et al.* Pre-registration for improved latent fingerprint identification[C]. International Conference on Pattern Recognition, Stockholm, Sweden, 2014: 696–701. doi: 10.1109/ICPR.2014.130.
 - [7] FANG B, WEN H, LIU R Z, *et al.* A new fingerprint thinning algorithm[C]. 2010 Chinese Conference on Pattern Recognition (CCPR), Changsha, China, 2010: 1–4. doi: 10.1109/CCPR.2010.5659273.
 - [8] KRIZHEVSKY A, SUTSKEVER I, and HINTON G. ImageNet classification with deep convolutional neural networks[C]. Proceedings of the 25th International Conference on Neural Information Processing Systems, Lake Tahoe, Nevada, USA, 2012: 1097–1105.
 - [9] HINTON G and OSINDERO S. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527–1554. doi: 10.1162/neco.2006.18.7.1527.
 - [10] SAINATH T N, KINGSBURY B, SAON G, *et al.* Deep convolutional neural networks for large-scale speech tasks[J]. *Neural Networks*, 2015, 64(4): 39–48. doi: 10.1016/j.neunet.2014.08.005.
 - [11] LAVIN A. maxDNN: An efficient convolution kernel for deep learning with maxwell GPUs[OL]. <https://arxiv.org/abs/1501.06633>, 2015.
 - [12] ARPIT D and NAMBOODIRI A. Fingerprint feature extraction from gray scale images by ridge tracing[C]. International Joint Conference on Biometrics, Washington DC, USA, 2011: 1–8. doi: 10.1109/IJCB.2011.6117533.
 - [13] CHANG C C, HWANG S M, and BUEHRER D J. A shape recognition scheme based on relative distances of feature points from the centroid[J]. *Pattern Recognition*, 1991, 24(11): 1053–1063. doi: 10.1016/0031-3203(91)90121-K.
 - [14] IWASOKUN G B and AKINYOKUN O C. Fingerprint singular point detection based on modified poincare index method[J]. *International Journal of Signal Processing Image Processing & Pattern Recognition*, 2014, 7(5): 259–272. doi: 10.14257/ijsp.2014.7.5.23.
 - [15] KUMAR R, HANMANDLU M, and CHANDRA P. An empirical evaluation of rotation invariance of LDP feature for fingerprint matching using neural networks[J]. *International Journal of Computational Vision & Robotics*, 2014, 4(4): 330–348. doi: 10.1504/IJCVR.2014.065569.
 - [16] WANG R, HAN C, WU Y, *et al.* Fingerprint classification based on depth neural network[OL]. <https://arxiv.org/abs/1409.5188>, 2014.
 - [17] KANAAN L, MERHEB D, KALLAS M, *et al.* PCA and KPCA of ECG signals with binary SVM classification[C]. IEEE Workshop on Signal Processing Systems, Beirut, Lebanon, 2011: 344–348. doi: 10.1109/SiPS.2011.6089000.
 - [18] HUANG G B, ZHU Q Y, and SIEW C K. Extreme learning machine: Theory and applications[J]. *Neurocomputing*, 2006, 70(1-3): 489–501. doi: 10.1016/j.neucom.2005.12.126.
- 吴震东: 男, 1976年生, 博士, 讲师, 研究方向为网络安全、人工智能、生物特征识别、自然语言处理。
- 王雅妮: 女, 1991年生, 硕士生, 研究方向为信号处理。
- 章坚武: 男, 1961年生, 博士后, 研究方向为移动通信与个人通信、多媒体通信技术、网络安全。