

DOI:10.15923/j.cnki.cn22-1382/t.2019.1.08

深度指静脉识别技术研究

李 璨, 李 亮, 王 昕*

(长春工业大学 计算机科学与工程学院, 吉林 长春 130012)

摘 要: 首先利用(Local Configuration Pattern, LCP)算法提取指静脉的纹理特征作为深度信念网络(Deep Belief Network, DBN)的输入,并通过逐层训练网络不断调整参数使网络达到最优化,从而实现指静脉图像的最优分类。将本算法与BP分类算法、SVM分类算法及KNN分类算法进行了比较。

关键词: 指静脉识别;深度学习;深度信念网络;LCP特征

中图分类号: TP 301.6 **文献标志码:** A **文章编号:** 1674-1374(2019)01-0044-06

Identification of deep finger vein

LI Can, LI Liang, WANG Xin*

(School of Computer Science & Engineering, Changchun University of Technology, Changchun 130012, China)

Abstract: Local Configuration Pattern (LCP) algorithm is used to extract the texture features of vein as inputs of Deep Belief Network (DBN). The network is trained layer by layer with parameters adjustment to realize optimization for finger vein image classification. The algorithm is compared with other ones such as BP classification, Support Vector Machine (SVM) classification and K-Nearest Neighbor (KNN) classification.

Key words: finger vein recognition; deep learning; Deep Belief Network (DBN); Local Configuration Pattern (LCP) mode.

0 引 言

生物识别技术^[1]就是利用人固有的生理特征(如指纹、脸部、虹膜等)和行为特征(如字迹、声音、步姿等)来进行个人身份的识别鉴定。但事实上这些技术存在还有许多亟待解决的问题,例如

在人脸识别方面,当人剃了胡子、戴了眼镜(或口罩)或者是胖了瘦了,这会使得人脸识别结果变得很不稳定^[2]。同样,因为指纹是一种外在的生物特征,对于脱皮、有伤痕等低质量指纹存在识别困难。而且有的人指纹特征少、难成像,更重要的是其很容易被仿制^[3],这使得指纹识别多了几分不

收稿日期: 2018-07-22

基金项目: 吉林省教育厅“十二五”科学技术研究项目(2014136)

作者简介: 李 璨(1994-),女,汉族,河北秦皇岛人,长春工业大学硕士研究生,主要从事图像处理与模式识别方向研究, E-mail: 978752386@qq.com. * 通讯作者: 王 昕(1972-),女,汉族,吉林长春人,长春工业大学副教授,博士,主要从事图像处理与模式识别方向研究, E-mail: wangxin315@ccut.edu.cn.

安全因素。而指静脉是一种内在生物特征,具有唯一性,不会磨损且极难仿制和盗用,具有很高的安全性,且在短时间内生物特征相对稳定^[4]。因此指静脉是新一代生物识别技术的典型代表。DBN^[5]作为一种典型的深度学习模型近年来被广泛应用,但由于其忽略了图像的二维空间结构信息,难以完全学习图像的局部特征^[6]。而LCP^[7-8]模型不仅可以提取图像的局部LBP^[9]纹理信息,而且可以提取图像邻域像素间的结构信息^[10]。

综上所述,文中提出了一种新的基于DBN与LCP相结合的深度指静脉识别算法,该方法利用LCP算法提取指静脉图像的局部纹理特征信息和局部构造信息,从而弥补了DBN模型易忽略图像局部结构信息的不足。同时由于LCP模型对图像的旋转和光照的影响具有较强的鲁棒性,因此,以LCP特征作为DBN网络的输入使得整个深度学习网络更加稳健,与传统的BP^[11]分类算法基于SVM^[12]和KNN^[13]的算法相比较,文中算法能实现对指静脉更加精确的识别。

1 算法原理

1.1 LCP模型

LCP模型所描述的图像特征包含两部分:传统的LBP纹理特征和Microscopic Configuration Operator(MIC)微观构造特征。两种特征相辅相成,使得LCP模型对图像特征信息的表达十分详尽。LBP模型通过比较某一像素点与其邻域点的像素值的差异来计算LBP特征,表达式如下:

$$\text{LBP}_{P,R} = \sum_{p=0}^{P-1} S(g_p - g_c) 2^p \quad (1)$$

$$S(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (2)$$

式中: g_p ——邻域像素点的灰度值;

g_c ——中心像素的灰度值;

P ——邻域点个数;

R ——邻域半径。

Mic算子能很好地表达图像的局部微观性质,定义如下:

定义一个 P 维的矢量

$$\mathbf{A} = (a_0, a_1, \dots, a_{P-1})^T$$

将其作为权重矢量对邻域周边的像素进行加权,从而实现邻域中心像素重构,当重构的中心像

素 $\sum_{i=1}^{P-1} a_i g_i$ 与原始中心像素 g_c 的误差 E 达到最小时得到最优参数矢量,即是如下方程的解:

$$E(a_0, a_1, \dots, a_{P-1}) = \min |g_c - \sum_{i=1}^{P-1} a_i g_i| \quad (3)$$

式中: g_c, g_i ——分别表示中心点像素与邻域点像素;

a_i —— g_i 的权重参数。

若在图像 I 的LBP模式中 $\text{LBP}_{P,R}^{(*)} = m$ ($*$ 表示任一LBP模式)的模式次数为 O_m ,即图像中有 O_m 个像素具有 m 模式,用 $g_{m,i}$ ($i=0, 1, \dots, O_m-1$)表示具有 m 模式的第 i 个像素的灰度值,则如果用所有这 O_m 个像素点的灰度值构成灰度矢量 \mathbf{G}_m ,则

$$\mathbf{G}_m = (g_{m,0}, g_{m,1}, \dots, g_{m,O_m-1})^T$$

如果用 $V_{i,0}, V_{i,1}, \dots, V_{i,P-1}$ ($i=0, 1, \dots, O_m-1$)表示以第 i 个具有 m 模式的像素为中心的邻域点像素的灰度值,则图像中所有模式近邻像素的灰度值构成矩阵 \mathbf{V}_m :

$$\mathbf{V}_m = \begin{bmatrix} V_{0,0} & V_{0,1} & \dots & V_{0,P-1} \\ V_{1,0} & V_{1,1} & \dots & V_{1,P-1} \\ \dots & \dots & \dots & \dots \\ V_{O_m-1,0} & V_{O_m-1,1} & \dots & V_{O_m-1,P-1} \end{bmatrix} \quad (4)$$

若用 $\mathbf{A}_m = (a_{m0}, a_{m1}, \dots, a_{mP-1})^T$ 表示模式的参数矢量,则最优参数矢量应该满足:

$$\mathbf{G}_m = \mathbf{V}_m \mathbf{A}_m \quad (5)$$

因式(5)是超定方程,采用最小二乘法可求其唯一解:

$$\mathbf{A}_m = (\mathbf{V}_m^T \mathbf{V}_m)^{-1} \mathbf{V}_m^T \mathbf{G}_m \quad (6)$$

同时为了克服图像旋转引起 \mathbf{A}_m 的周期变化,引入傅里叶变换。用 F_m 表示 \mathbf{A}_m 的 P 点一维傅里叶变换。

$$F_m(k) = \sum_{i=0}^{P-1} A_m(i) \cdot e^{-j2\pi ki/P} \quad (7)$$

式中: $F_m(k)$ —— F_m 的第 i 个元素;

$A_m(i)$ —— \mathbf{A}_m 的第 i 个元素,且 F_m 具有旋转不变性,取其幅度作为图像的局部微观构造Mic特征,则Mic定义如下:

$$|F_m| = [|F_m(0)| |F_m(1)| \dots |F_m(P-1)|]^T \quad (8)$$

最终将LBP特征与Mic特征进行融合用于表示LCP特征:

$$\text{LCP} = \{[|F_0|; |O_0|]; [|F_1|; |O_1|]; \dots; [|F_{M-1}|; |O_{M-1}|]\} \quad (9)$$

式中: $|F_i|$ ——由式(8)计算而来;

O_i ——第 i 个相应 LBP 模式出现的次数;

M —— LBP 模式数量。

1.2 DBN 模型

DBN^[7] 深度信念网络是由 Hinton 与其学生在 2006 年提出的, 其由一系列无监督受限玻尔兹曼机 (Restricted Boltzmann Machines, RBMs)^[14] 和输出层的前馈反向传播 (Feed Forward Back Propagation, BP)^[15] 神经网络构成。它本质上就是一个包含多个隐藏层的概率模型。整体结构如图 1 所示。

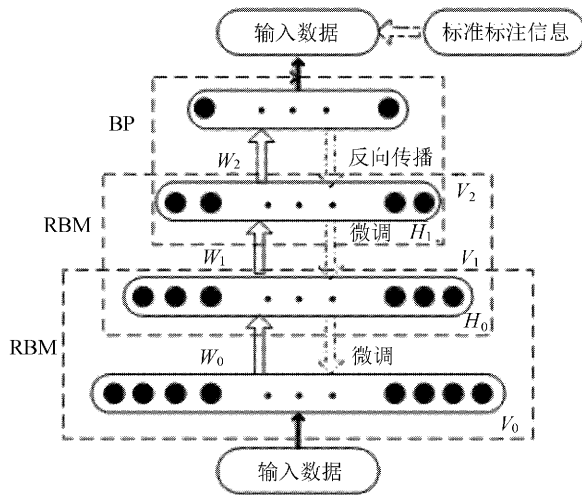


图 1 DBN 模型结构图

这一系列的 RBMs 通过层叠的关系将前一层 RBM 的输出作为后一层 RBM 的输入, 从而构成了深度 RBMs 网络。在 DBN 网络的最后一层采用有监督的 BP 神经网络实现对整体网络的参数进行调整与分类。并且通常把一系列 RBMs 的无监督训练称之为预训练, 而把深层 RBMs 训练得到的网络参数作为整体网络参数赋给 BP 的阶段称为微调。对于一个具有 l 层隐藏层的 DBN 来说, 可视单元与隐藏单元之间的联合分布可表示为:

$$P(v, h^{(1)}, h^{(2)}, \dots, h^{(l)}) = P(v | h^{(1)}) p(h^{(2)} | h^{(1)}) \dots P(h^{(l-1)} | h^{(l)}) \quad (10)$$

式中: v —— DBN 的可视单元, $v = h^{(0)}$;

$h^{(k)}$ ——第 k 层隐藏单元, $k = 1, 2, \dots, l$ 。

第 k 层与第 $k+1$ 层的隐藏单元满足:

$$P(h^{(k)} | h^{(k+1)}) = \prod_i P(h_i^k | h^{(k+1)}) \quad (11)$$

$$P(h_i^{(k)} = 1 | h^{(k+1)}) = \sigma(b_i^{(k)} + \sum_j W_{ij}^{(k)} h_j^{(k+1)}) \quad (12)$$

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (13)$$

式中: $b_i^{(k)}$ ——第 k 层偏置;

$W_{ij}^{(k)}$ ——第 k 层与第 $k+1$ 层之间的权值;

$\sigma(x)$ ——激活函数, 在 DBN 网络中将 $P(h^{(l-1)}, h^{(l)})$ 称为一个 RBM 模型。

2 基于 LCP 和 DBN 的深度指静脉识别

对于局部纹理及局部微观特征, LCP 模型能很好地完成特征描述, 且该模型对光照变化及图像的旋转都有较好的鲁棒性。而对深度 DBN 网络而言, 当光照和姿态发生改变时, DBN 网络将无法学习到理想的特征。且图像以向量的形式输入到网络, 因此局部的结构特征也无法很好学习到。如果以 LCP 特征作为 DBN 网络的输入就可以有效弥补深度 DBN 网络的缺陷。为了对指静脉图像的特征表达的更加具体, 采用多尺度的 LCP 特征提取方法对指静脉图像进行分块提取 LCP 特征, 指静脉图像的微模式信息、区域特征及其连接形成的全局特征均可以在分块 LCP 特征的直方图中很好地表现出来。然后将各子块 LCP 特征进行整合, 输入到 DBN 深度网络中。

网络训练的好坏决定了对 LCP 特征学习的准确度。DBN 的训练过程如下:

首先, 以全局的 LCP 特征作为输入, 对第一层 RBM 进行无监督训练, 得到第一层的最优参数。

然后, 以第一层 RBM 的输出数据作为第二层的输入进行无监督训练得到第二层 RBM 的参数值。以此类推, 逐层训练得到每一层的参数值。

最后, 通过全局训练对各层参数进行微调, 从而实现 DBN 收敛并达到全局最优, 并进行回归分类。该训练过程规避了目标过拟合的现象。

此时深度 DBN 网络的联合分布表示如下:

$$P(H, h^{(1)}, h^{(2)}, \dots, h^{(l)}) = P(H | h^{(1)}) p(h^{(2)} | h^{(1)}) \dots P(h^{(l-1)} | h^{(l)}) \quad (14)$$

式中: H —— LCP 特征;

$h^{(1)}, h^{(2)}, \dots, h^{(l)}$ —— DBN 网络对 H 特征学习到不同层次下的高级特征, 其影响到 DBN

网络学习的有效性。

因此 LCP 的纹理特征部分我们选择统一模式的 LBP,这样做有两大好处:

1)非统一模式 LBP 具有 2^p 种模式。而统一 LBP 只有 $(p(p-1)+3)$ 种模式,即特征维数大大降低。而且虽然模式减少了很多,但其仍然包含了 90% 以上的 LBP 模式信息。

2)统一 LBP 对灰度平移变换具有不变性,且能更好描述局部纹理特征。

文中的整体实现步骤如下:

- 1)对指静脉图像进行尺度归一化处理为 128×128 , 然后对图像进行 4×4 分块;
- 2)提取各子块的 LCP 特征;
- 3)将各子块的 LCP 特征连接成全局的 LCP

特征;

4)对特征向量进行归一化处理并输入到 DBN 网络;

5)对 DBN 网络进行逐层训练以获得最优网络参数;

6)利用 BP 神经网络进行全局微调;

7)在网络顶层进行回归分类并计算识别率。

3 实验过程与结果

实验图像数据库包含 64 个手指共 960 幅图像,每个手指有 15 幅图像。所有图像均已作了尺度归一化处理。

经过归一化处理后的部分指静脉图像如图 2 所示。




图 2 指静脉图像实例

实验中随机取每个手指的 10 幅图像作为训练样本,余下的 5 幅图像作为测试样本。实验平台是 Windows10 专业版 PC 机处理器为 intel(R) core(TM)i5-3470cpu@3.20 GHz,内存是 4 GB,

软件版本 MATLAB2013a(64 位)。

3.1 DBN 中各参数的确定

DBN 网络构建完成后需要设定模型的最佳参数,经过反复验证,文中实验 DBN 的层数设置

为 4, 学习率设置为 0.001, 每层迭代次数为 30 次。

隐含层节点数的学习曲线如图 3 所示。




图 3 隐含层节点数的学习曲线

从图 3 可以看出, 当隐藏层节点数大于 90 以后, DBN 的训练集误差趋于稳定。因此, 各层隐含节点的个数设置为 100, 为了进一步确定整个 DBN 网络的结构, 进行了 RBM 深度测试实验, 实验结果见表 1。

表 1 不同 RBM 深度对识别率的影响 %

RBM 深度	识别率
2	93.46
3	94.68
4	91.87
5	91.56

由表 1 的实验结果可以看出, 当 DBN 网络的 RBM 深度为 3 时, 识别率达到最大 94.68%。

所以本实验构建的 DBN 结构为 $m-100-100-100-64$ 。其中, m 表示输入 DBN 的 LCP 特征向量的维数。文中取 $P=8, R=1$, 所以最终 $m=2240$ 。

3.2 对比实验

为了验证文中提出的深度指静脉识别算法的有效性, 设置了两组对比实验。分别选取有监督的 BP 神经网络和 SVM 及 KNN (K 值取 3) 三种分类算法作为对比。实验中各组均采用相同的测试集和训练集, 所用特征向量均为 LCP 特征。实验结果见表 2。

表 2 不同分类算法识别率对比 %

相关算法	识别率
BP	81.25
SVM	86.87
KNN	82.76
文中算法	94.68

由表 2 的实验结果可以看出, DBN 网络明显优于传统有监督的分类学习模型, 这是因为 DBN 作为一种深度学习模型, 能够通过多层非线性结构对输入数据自主地提取具有分类能力的特征再分类学习, 从而提高了对指静脉的识别。这正是浅层 BP 网络、KNN 分类算法及 SVM 所不具备的。而且, 随着图像库中指静脉图像数目的增加, 文中算法的识别率将更高。

4 结 语

经过多年研究努力, 指静脉识别的研究获得了很大进展, 在门禁、考勤、图书馆、银行、监狱、汽车安全等领域得到了一定的应用。文中所提出的深度指静脉识别方法相较于传统的有监督分类算法有着明显的优势, LCP 特征与 DBN 网络相结合使得该模型能通过多层非线性结构对输入数据进行自主的再分类学习, 从而对指静脉的识别率更高。将文中算法与传统的 BP 分类算法、SVM 分类算法及 KNN 分类算法进行了对比实验, 证明文中算法的优越性。

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] 潘芬兰. 基于人脸识别技术的智能考勤系统研究[D]. 杭州: 浙江大学, 2014.
- [3] 臧亚丽, 杨鑫. 指纹识别技术研究热点与新方向[J]. 警察技术, 2015(5): 3-7.
- [4] 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.
- [5] Chen B, Yin Q, Guo P. A study of deep belief network based Chinese speech emotion recognition [C]// Tenth International Conference on Computational Intelligence and Security IEEE, 2014: 180-184.
- [6] 吴进, 严辉, 王洁. 采用局部二值模式与深度信念网络的人脸识别[J]. 电讯技术, 2016, 56(10): 1119-

- 1123.
- [7] Yimo Guo, Guoying Zhao, Matti Pietika Inen. Texture classification using a Linear configuration model based descriptor[C]// In Jesse HoeyStephen McKenna and Emanuele Trucco, Proceedings of the British Machine Vision Conference,2011.
- [8] 徐俊彦,苗壮,谭佳伟,等.解线性互补问题的组合同伦方法[J].长春工业大学学报:自然科学版,2010,31(3):269-274.
- [9] Shen Y K, Chiu C T. Local binary pattern orientation based face recognition[C]// IEEE International Conference on Acoustics, Speech and Signal Processing IEEE,2015:1091-1095.
- [10] 喻丽春,刘金清.基于改进的 VGGNet 算法的人脸识别[J].长春工业大学学报,2018,39(4):378-385.
- [11] 张怡君,左颖婷,刘近春,等.GA-BP 与 BP 神经网络在医学研究中的应用与比较[J].中国卫生统计,2018(2):239-241,245.
- [12] Myerson J. Machine learning models and algorithms for big data classification: thinking with examples for effective learning[J]. Computing Reviews,2016,57(5):283-284.
- [13] 毋雪雁,王水花,张煜东.K 最近邻算法理论与应用综述[J].计算机工程与应用,2017,21:1-7.
- [14] 柴瑞敏,侣称称.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.
- [15] Tiwari S, Singh A K, Shukla V P. Statistical moments based noise classification using feed forward back propagation neural network[J]. International Journal of Computer Applications,2011,18(2):36-40.