

基于多模式 LBP 与深度森林的指静脉识别

刘广东, 邱晓晖

(南京邮电大学 通信与信息工程学院, 江苏 南京 210003)

摘要:深度森林(gcForest)是基于深度模型提出的级联随机森林集合方法,以解决深度学习网络模型中对大样本训练数据和对设备要求过高的问题。深度森林不像深度神经网络那样具有很多的调节参数,对训练模型的选取需要耗费大量的时间与精力,gcForest 允许使用者可以根据设备的资源决定训练的耗费,且能自适应地调节训练模型层数。指静脉图像含有丰富的纹理信息,文中基于多模式 LBP 提取指静脉图像的基本 LBP 特征,统一模式 LBP 分块直方图特征并将它们与深度森林结合取得的识别率达到 99.46%,训练时间大幅减少,并解决了 gcForest 在旋转适应性方面的不足。与随机森林分类器(random forest)、KNN 分类器、支持向量机分类器(SVM)、罗格斯特回归分类器(logistic regression)等进行比较,证明了深度森林识别器的有效性。

关键词:指静脉识别;深度森林;LBP;特征提取;随机森林

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2018)07-0083-05

doi:10.3969/j.issn.1673-629X.2018.07.018

Finger Vein Recognition Based on Multi-mode LBP and Deep Forest

LIU Guang-dong, QIU Xiao-hui

(School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China)

Abstract: The deep forest, named as gcForest, is a cascade random forest ensemble method based on the deep learning model, in order to solve the problem that the deep learning network model usually requires large scale of training samples and the threshold of the deep learning is too high for personal research. GcForest doesn't have lots of tuning parameters like convolution neural networks which cause the selection of the training models taking lots of time and effort. GcForest allows users to determine the cost of training based on the resources of the device, and can adjust the number of training model layers in an adaptive manner. The finger-vein image contains rich texture information. Based on multi-mode LBP, we extract the basic LBP features and unified model LBP partitioned histogram features in the finger-vein image and combine them with the depth of the forest to reach the recognition rate by 99.46%, sharply reducing training time and solving the shortcoming on the adaptability for gcForest. Compared with random forest, KNN classifier, SVM and logistic regression, the effectiveness of gcForest recognizer is proved.

Key words: finger vein recognition; deep forest; local binary pattern; feature extraction; random forest

0 引言

指静脉识别是近年来兴起的活体生物特征识别技术,其原理是基于人类手指中流动的血液可以吸收 720 ~ 1 000 nm 范围内的红外线,从而得到指静脉的清晰图像。相较于传统的生物识别方法,其自身存在独特的优点:特异性和唯一性。每个人的指静脉图像不同,同一人不同手指的静脉图像也不同,健康成年人的静脉形状不再发生变化;活体特征-指静脉存在于身体内部,被复制或盗用的机会很小,受生理和环境因

素的影响小,克服了皮肤表面异常、皮肤干燥、油污、灰尘等的影响,为指静脉识别提供了理论依据。据公安部某研究所的专家团队论证得出结论:指静脉生物特征技术是目前最为安全、可靠的一种生物识别技术。

近年来,研究者主要对指静脉图像的采集^[1-3]与特征提取进行了研究。其中特征提取的研究最早主要集中于静脉网络的分割算法提取出静脉骨架并采用模板匹配的方法进行识别^[4],模板匹配利用图像的整体信息但是计算量较大,宋显华引入 Hu 不变矩法取得

收稿日期:2017-07-31

修回日期:2017-12-27

网络出版时间:2018-03-07

基金项目:江苏省自然科学基金(BK2011789);东南大学毫米波国家重点实验室开放课题(K201318)

作者简介:刘广东(1990-),男,硕士,研究方向为图像处理与模式识别;邱晓晖,教授,通信作者,研究方向为信号与信息处理及模式识别。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.tp.20180307.1422.038.html>

了很好的效果^[5]。基于静脉网络的分布结构提取端点与分叉点^[6]同样受到了研究者的青睐,这类方法利用了静脉网络的局部信息。多尺度几何特征^[7]和二值特征^[8]能够提取丰富的局部纹理信息,适用于指静脉等纹理描述的生物特征识别。使用空间投影变换等机器学习方法^[9-12]获取的指静脉特征,通过训练获得降维后的具有较高描述能力的特征符合图像处理与模式识别技术的潮流,具有自身独特优势。但是针对深度学习进行指静脉识别却鲜有人提出,这是因为深度网络模型的训练需要大量的样本,而目前指静脉的权威数据库难以达到需求。最近,深度森林模型的提取为解决这一问题提供了有效的解决途径。深度森林的提出为解决小样本的数据模型提供了可靠的途径并且有效减少了训练时间,同时文中提出了多模式 LBP 特征与深度网络相结合的方式,并通过实验进行验证。

1 指静脉识别系统框架

指静脉识别系统主要包括:指静脉图像采集、指静脉图像预处理、指静脉图像特征提取、指静脉图像识别^[13]。图像采集设备在整个图像识别系统中占有重要的地位,采集到的指静脉图像的质量直接影响整个

识别系统的安全性、可接受性和正确性。指静脉图像的采集主要依据红外成像理论,红外波长在 720 ~ 1 000 nm 的近红外 LED 光源照射到指静脉表面时,红外光线很容易透射过骨骼和肌肉组织,而手指血管中血红蛋白可以充分吸收该波段的近红外光线。在手指的另一侧 CMOS 摄像头可以拍摄到手指静脉图像。在图像的预处理阶段,主要是得到清晰有效的指静脉区域,这部分包含的步骤主要是感兴趣区域(ROI)的提取、尺寸归一化、灰度归一化,经过上述处理后可以得到大小统一且含有充分特征信息的指静脉特征。文中特征提取部分采用多模式的 LBP 特征,包含基本的 LBP 特征、统一模式分块直方图特征,同时结合深度森林进行指静脉的识别。

2 LBP 特征提取

LBP(local binary pattern,局部二值模式)是一种能够有效地描述图像局部纹理特征的算子。LBP 特征具有很强的分类能力、较高的计算效率并且对于单调的灰度变化具有不变性,这些特点使得它在很多图像分类问题中得到了应用并且不断被改进^[14]。

整个 LBP 的编码过程如图 1 左所示。




图 1 多模式 LBP 算子

用公式概括为:

$$LBP_{R,R}(x_c,y_c) = \sum_{i=0}^{P-1} 2^i * s(g_i - g_c)$$
$$s(g_i - g_c) = \begin{cases} 1, & g_i - g_c > 0 \\ 0, & g_i - g_c < 0 \end{cases}$$

其中, (x_c,y_c) 为所选邻域中心像素点的坐标;
 (x_i,y_i) 为邻域像素点坐标; g_i 为中心像素的灰度值;

g_c 为邻域像素的灰度值。

应用 LBP 算子的过程类似于滤波过程中的模板操作。逐行扫描图像,对图像中的每一个像素点,以该点的灰度作为阈值,对其周围的 3 * 3 模板进行二值化,按照一定的顺序将二值化的结果组成一个 8 位二进制数,以此二进制数的值(0 ~ 255)作为该点的响应。在整个逐行扫描结束后会得到一个 LBP 响应图

像,图 1 中 LBP 响应图像的二进制编码为 01100111,对应的十进制编码为 103。

统一模式 LBP:

对于一个局部二进制模式,在将其二进制位串视为循环的情况下,如果其中包含的从 0 到 1 或者从 1 到 0 的转变不多于两个,则称这个局部二进制模式为统一化模式。统一化 LBP 模式能够很好地解决基本 LBP 算子中那些受噪声影响的转变。对于采样点数为 P 的原始 LBP 产生的二进制模式为 2^P 种,而等价模式只有 $P(P-1)+3$ 种,当 $P=8$ 时,统一模式 LBP 的二进制模式仅有 59 种,见图 1 右。

在整个逐行扫描结束后会得到一个 LBP 响应图像,这个响应图像的直方图称为 LBP 统计直方图或 LBP 直方图,它常常作为后续识别工作的特征,因此也被称为 LBP 特征。由于 LBP 直方图大多是针对图像中的各个分区分别计算的,对于一个普通大小的分块区域,标准的 LBP 算子得到的二进制模式数目较多,而实际的位于该区域中的像素数目却相对较少,这将会得到一个过于稀疏的直方图,从而使直方图失去统计意义。因此应该设法减少一些冗余的 LBP 模式,同时又保留足够的具有重要描绘能力的模式。统一化模式的提出解决了上述问题,在随后的 LBP 直方图的计算过程中,只为统一化模式分配单独的直方图收集箱,而所有非统一化模式都被放入一个公用收集箱,这就使 LBP 的特征数目大大减少。一般来说,保留的统一化模式往往是反映重要信息的那些模式,而非统一化模式中过多的转变往往是由噪声引起的,不具有良好的统计意义^[15]。

3 深度森林

近年来,深度学习网络在许多领域取得了巨大的成功,尤其是在计算机视觉和语音识别方面。尽管深度神经网络优势突出,但是仍然存在明显的缺点。首先,深度神经网络需要大量的样本进行训练,这样就无法在小样本训练集上直接使用。同时,尽管在大样本数据集上,许多实际任务由于缺少标记样本(由于样本标记需要耗费大量的资源),使得深度学习网络在这些任务上的表现也不是很好。其次,深度学习网络是非常复杂的模型,训练处理的过程需要具有强大计算能力的设备,除了大公司以外,个人很难真正进入这一领域。更为重要的是,深度神经网络具有非常多的超参数,学习表现严重依赖对这些参数的调节。举例来说,即使一些作者使用卷积神经网络,他们也是根据不同的任务使用不同的学习模型,比如卷积层结构。这使得深度神经网络的训练非常棘手,而且深度神经网络的理论非常困难,因为具有几乎无限构型组合的

干扰因素太多。

研究者们普遍认识到,表征学习能力对于深度神经网络至关重要。值得注意的是,为了利用大量的训练数据,深度学习网络需要很大的容纳能力;这也是深度神经网络非常复杂的原因。gcForest 是一种新的决策树集合方法,该方法生成了一个深层森林集合,具有级联结构,可以使 gcForest 进行表征学习。当输入具有高维度时,可以通过多粒度扫描进一步增强其表征学习能力,使 gcForest 具有上下文或结构感知能力。此外,gcForest 可以自适应地确定级联层数,自动设置模型复杂性,使 gcForest 即使在小规模数据上也能执行良好,用户可以根据可用的计算资源来控制训练成本。gcForest 具有比深层神经网络少得多的超参数;更为重要的是,它的性能对于超参数设置具有健壮性,因此在大多数情况下,即使是来自不同域的不同数据,也可以通过使用默认设置获得出色的性能。这不仅使 gcForest 的训练方便,而且使 gcForest 的训练时间成本小于深度神经网络。

gcForest 采用级联结构,其中级联接收由其前一级别森林处理的特征信息,并将处理结果输出到下一级。每层包含两个随机森林和两个完全随机森林,这是基于多样性的考虑,每个层级都是集合的集合。每个随机森林包含 500 棵树,完全随机森林是由 1 000 棵决策树组成,每棵树随机选取一个特征作为分裂树的分裂节点,然后一直生长,直到每个叶节点细分到只有 1 个类别或者不多于 10 个样本。类似的,普通随机森林由 1 000 棵决策树构成,每棵树通过随机选取 \sqrt{d} (d 表示输入特征维度,即特征数)个候选特征,然后通过 gini 分数筛选分裂节点。所以两种森林的主要区别在于候选特征空间,完全随机森林是在完整的特征空间中随机选取特征来分裂,而普通随机森林是在一个随机特征子空间内通过 gini 系数来选取分裂节点。注意,每个森林里的树木数量是一个超参数。




图 2 类矢量产生的说明
(不同的标记表示不同的类别)

图 2 是每层森林中特征类矢量的产生过程:给定一个实例,每个森林将计算相关实例落叶的叶节点上不同类别的训练实例的百分比,然后对同一森林中的所有树进行平均,从而产生类分布的估计,其中虚线部分显示实例遍历到叶节点的路径。

为了方便起见,假设输入的样本包含三个类,估计的类分布形成一个类向量,然后将其与原始特征向量连接以输入到下一级级联。例如,假设有三个类,那么四个森林中的每一个将产生三维类向量;因此,下一级级联将获得 $12(3 \times 4)$ 增强特征。

为了降低过度拟合的风险,每个森林产生的类矢量是通过 k -折交叉验证产生的。每个实例将被用作 $k-1$ 次的训练数据,产生 $k-1$ 个类向量,然后对其进行平均以产生最终类矢量作为下一级级联的增强特征。获得增强特征后,将对验证集进行整体级联性能评估,如果没有显著的识别率增长,训练程序将终止;因此,gcForest 能自动确定级联电平的数量。与模型复杂度固定的大多数深度神经网络相反,gcForest 通过适当地终止训练来自适应地决定其模型的复杂性。这使其能适用于不同规模的训练数据,不限于大规模训练数据。

4 实验与分析

实验的数据集来自 Sains Malymia 大学的指静脉数据集 FV_USM,该数据库共由两部分组成,每一部分均包含 2 952 个样本。这些样本来自 123 个不同性别、不同年龄阶段的志愿者,每个人分别采集双手的食指和中指的图片各 6 张,经过预处理后得到统一的像素为 100×300 的样本。

另一个数据库是由自己制作的采集设备采集得到,实验样本来自 35 位不同年龄段的人,按照正规的预处理流程制作标准的样本。每个样本的像素为 280×120 ,但是制作好的样本仍有微小的位移偏差,更符合实际情况,以验证算法的鲁棒性。

实验中分别将 gcForest 算法与其他典型的机器学习算法进行对比,结果见表 1 和表 2。其中,用于训练的样本数量分别选择 3 个样本和 4 个样本。decision

tree 分类器^[16]的最大深度设置为 10,节点数目为 100。支持向量机分类器^[17]使用台湾大学林智实验室开发的 LibSVM。FV_USM 数据库中 C 设置为 0.031 25, g 设置为 0.000 488 281 24;自制数据库上 C 设置为 0.125, g 设置为 0.000 122 007 031 25。logistic regression 分类器^[18]设置为 $C = 1.0$,惩罚因子设置为 l_2 范式。random forest 分类器^[19]最大深度设置为 10,包含 1 000 棵树。KNN 分类器^[20]中 K 的值设置为 3。gcForest 分类器中每层包含 4 个森林,其中两个森林为完全随机森林,两个为随机森林,每个森林包含 500 棵树,增益准则选择最小“gini”值,gcForest 自动设置训练级数,当识别率不再有明显增长时停止训练过程。

表 1 不同算法在 FV_USM 上的识别率对比 %

算法	3 images	4 images
gcForest	92.68	97.56
logistic regression	88.05	90.91
random forest	87.21	87.67
SVM	79.67	84.55
KNN	79.51	80.44
decision tree	15.69	20.05

表 2 不同算法在自制数据库上的识别率对比 %

算法	3 images	4 images
gcForest	90.24	92.68
logistic regression	83.45	89.75
random forest	89.75	89.81
SVM	76.51	80.83
KNN	70.08	79.57
Decision Tree	15.32	19.05

从表 1 与表 2 可以看出,gcForest 相比于其他算法取得了较高的识别率。

提出的基于 LBP 特征的深度森林框架如图 3 所示。




图 3 基于 LBP 特征的深度森林框架

将 LBP 特征输入到深度森林中,最终的实验结果见图 3 所示。

表 3。

表 3 不同 LBP 特征与深度森林结合
取得的识别率

特征	FV_USM	自制数据库
LBP 响应图像	92.68	90.24
未分块 LBP 直方图特征	85.10	85.77
3 * 1 分块 LBP 直方图特征	97.02	92.28
6 * 2 分块 LBP 直方图特征	98.64	94.31
9 * 3 分块 LBP 直方图特征	99.46	93.09
12 * 4 分块 LBP 直方图特征	99.46	93.50
15 * 5 分块 LBP 直方图特征	99.46	91.06
18 * 6 分块 LBP 直方图特征	98.37	87.40

从表 3 可以看出,相较于 LBP 响应图像,LBP 直方图能够取得更好的识别效果。在两个实验数据库上,基于统一模式 LBP 分块直方图特征比使用 LBP 响应图像在识别效果上的提升更加显著,在 FV_USM 数据库上识别率提高了 6.78%,在自制数据库上识别率提高了 4.07%。

5 结束语

提出了基于深度森林的指静脉识别方法,并与经典的机器学习识别器在性能上进行比较,结果表明基于深度学习模型改进的深度森林识别器比其他的分类器具有更好的表现,与深度神经网络相比更适用于小规模数据集,具有更少的调节参数,同时能够自适应地优化选取网络层数。同时,将基本 LBP 响应图像、统一模式 LBP 分块直方图特征与深度森林结合的方法在提取丰富的指静脉纹理特征的基础上结合深度学习的模型,进一步提高了深度森林的识别效果。相较于深度网络等深度学习模型探索了基于深度学习模型用于图像识别的新领域,实验表明深度森林能够在指静脉图像识别等图像识别领域取得理想的效果。

参考文献:

[1] 梁爱华,付 航. 近红外指静脉图像采集系统设计[J]. 传感器与微系统,2014,33(1):113-115.

[2] 管凤旭,姜智超,吴秋雨,等. 指静脉与折痕双模态图像采集系统设计[J]. 传感器与微系统,2013,32(2):124-127.

[3] 吴 飞,杨广达,王凤兰,等. 手指静脉识别传感器的光源设计[J]. 传感器与微系统,2017,36(4):74-77.

[4] MIURA N,NAGASAKA A,MIYATAKE T. Feature extraction of finger-vein patterns based on repeated line tracking and its application to personal identification[J]. Machine Vision & Applications,2004,15(4):194-203.

[5] 宋显华. 指静脉图像的特征提取和匹配[D]. 长春:吉林大学,2007.

[6] 庞晓红. 指静脉身份识别算法的研究[D]. 天津:河北工业大学,2015.

[7] 孙 磊. 手指静脉图像的特征提取算法[D]. 杭州:杭州电子科技大学,2013.

[8] 杨文文,毛建旭,陈姜嘉旭. 基于分块 LBP 和分块 PCA 的指静脉识别方法[J]. 电子测量与仪器学报,2016,30(7):1000-1007.

[9] WU Jianda,LIU C T. Finger-vein pattern identification using principal component analysis and the neural network technique[J]. Expert Systems with Applications,2011,38(5):5423-5427.

[10] GUAN Fengxu,WANG Kejun,MO Hongwei,et al. Research of finger vein recognition based on fusion of wavelet moment and horizontal and vertical 2DPCA[C]//International congress on image and signal processing. Tianjin,China:IEEE,2009:1-5.

[11] 管凤旭,王科俊,刘靖宇,等. 归一双向加权(2D)2PCA 的手指静脉识别方法[J]. 模式识别与人工智能,2011,24(3):417-424.

[12] 王科俊,袁 智. 基于小波矩融合 PCA 变换的手指静脉识别[J]. 模式识别与人工智能,2007,20(5):692-697.

[13] 杨 颖,杨公平. 手指静脉识别技术[J]. 计算机科学与探索,2012,6(4):343-354.

[14] 肖 霄. 图像 LBP 特征提取的研究与应用[D]. 长春:吉林大学,2011.

[15] 张 铮. 基于二维 MB-LGBP 特征的表情识别及其光照检测研究[D]. 天津:天津大学,2010.

[16] HASSAN M,BERMAK A. Gas classification using binary decision tree classifier[C]//IEEE international symposium on circuits and systems. Melbourne VIC, Australia:IEEE,2014:2579-2582.

[17] KHELLAT-KIHEL S,ABRISHAMBAF R,CARDOSO N,et al. Finger vein recognition using Gabor filter and support vector machine[C]//Image processing,applications and systems conference. Sfax,Tunisia:IEEE,2015:1-6.

[18] KOSTADINOV D,BOGDANOVA S. Logistic regression classifier for palmprint verification[C]//19th international conference on systems,signals and image processing. [s. l.]:IEEE,2012:413-416.

[19] 杨 颖,刘华明,曹红兵,等. 基于随机森林的手指静脉识别方法研究[J]. 阜阳师范学院学报:自然科学版,2016,33(1):78-82.

[20] NASSIH B,HMINA N,AMINE A. Face classification under different kernel function compared to KNN classifier[C]//International conference on computer graphics,imaging and visualization. Beni Mellal,Morocco:IEEE,2016:232-236.