

叶得学,韩如冰,颜鲁合.基于轻量级 DenseNet 和 ZigBee 的指纹识别方法[J].湖南科技大学学报(自然科学版),2023,38(4):78-87. doi:10.13582/j.cnki.1672-9102.2023.04.010

YE D X, HAN R B, YAN L H. Fingerprint Recognition Method Based on Lightweight DenseNet and ZigBee[J]. Journal of Hunan University of Science and Technology (Natural Science Edition), 2023, 38(4): 78-87. doi: 10.13582/j.cnki.1672-9102.2023.04.010

基于轻量级 DenseNet 和 ZigBee 的指纹识别方法

叶得学^{1*}, 韩如冰¹, 颜鲁合²

(1.兰州工商学院 信息工程学院,甘肃 兰州 730101;2.甘肃中医药大学 经贸与管理学院,甘肃 兰州 730000)

摘要:针对传统身份识别方法识别准确率低、模型复杂且运算速度慢等问题,提出一种新的基于轻量级密集连接卷积神经网络(DenseNet)和紫蜂协议(ZigBee)的指纹识别方法.首先,构建指纹识别系统的整体模型,并对该模型进行适当的裁剪以缩减模型复杂度.其次,通过筛选指纹图像、增强有效指纹以及扩充增强后的数据等操作,对采集到的 ZigBee 协议指纹信息进行预处理.然后,以传统深度残差网络的基本思想为依据,通过前馈的方式改变层间的连接关系并构建轻量级 DenseNet.最后,以相同的样本数据为基础分别对轻量级 DenseNet 模型、普通 DenseNet 模型和 3 种传统基于机器学习的身份识别算法模型进行训练.试验结果表明:所提出的基于轻量级 DenseNet 模型的识别准确度最高,为 98.24%,且该模型的运行速度最快,与普通 DenseNet 模型相比,其模型复杂度降低了 94%以上.

关键词:指纹识别;轻量级 DenseNet;密集连接卷积神经网络;ZigBee;深度学习

中图分类号:TP391 **文献标志码:**A **文章编号:**1672-9102(2023)04-0078-10

Fingerprint Recognition Method Based on Lightweight DenseNet and ZigBee

YE Dexue¹, HAN Rubing¹, YAN Luhe²

(1. School of Information Engineering, Lanzhou Technology and Business College, Lanzhou 730101, China;

2. School of Economics and Management, Gansu University of Traditional Chinese Medicine, Lanzhou 730000, China)

Abstract: With the gradual popularity of smart devices in daily life, traditional identification methods have low recognition accuracy, complex models, and slow calculation speeds. In response to the above problems, this paper proposes a fingerprint recognition method based on a lightweight densely connected convolutional neural network (DenseNet) and the ZigBee protocol (ZigBee). First of all, this paper theoretically constructs the overall model of the fingerprint recognition system, and appropriately tailors the model to reduce the complexity of the model. Secondly, through operations such as screening fingerprint images, enhancing effective fingerprints, and expanding the enhanced data, the collected fingerprint information of the ZigBee protocol is preprocessed. Then, based on the basic idea of the traditional deep residual network, the connection relationship between the layers is changed in a feedforward manner, and a lightweight DenseNet is constructed. Finally, based on the same sample data, the lightweight DenseNet model, the ordinary DenseNet model, and the other three traditional machine learning-based

收稿日期:2021-12-22

修改日期:2023-06-15

基金项目:甘肃省科技计划项目资助(20CX9ZA021;22JR5RA809;20CX9ZA068);兰州市科技计划项目资助(2019-ZD-167;2020-ZD-139)

*通信作者,E-mail: yedexue1978_1@163.com

identity recognition algorithm models are trained respectively. The experimental results show that the average recognition accuracy of the proposed lightweight DenseNet model is 98.24%, and the model runs the fastest. Compared with the ordinary DenseNet, its model complexity is reduced by more than 94%.

Keywords: fingerprint recognition; lightweight DenseNet; densely connected convolutional neural network; ZigBee; deep learning

随着通信技术的飞速发展,智能设备在各个领域中都得到了广泛应用,大大提升了当今社会生活的智能化程度.智能设备在为大众生活带来很多便利的同时,也面临着大众隐私易泄露等一系列问题^[1-2].传统基于加密技术的物联网识别方法一般是通过复杂的算法实现密码识别,存在易被黑客破解的问题^[3].因此,设计研发其他可靠性更高的密码识别方法是目前业内的研究重点.

目前,移动终端使用最广泛的密码识别方法是指纹识别方法^[4-6].指纹识别一直被用于与个体相关联,其应用领域涵盖移动设备安全、医疗保健接入、金融系统和政府机构等,具有唯一性、持久性、普遍性和可采集性的特点.从发展历程看,指纹识别经历了力学指纹、光学指纹、电容性指纹和高端 3D 指纹等阶段,力学指纹是最原始和粗糙的指纹;光学指纹是光学成像的指纹,其特征较为明显;电容性指纹是将物理指纹转化为电信号,其特征更加细化;高端 3D 指纹可以将指纹信息以 3D 全景形式展开,其特征比 2D 信息更加全面.指纹具有稳定性、便携性和唯一性,相对于其他的身体特性而言,指纹更能被作为密码识别的依据且具有较高的可靠性^[7-9].孙汝杰^[10]以轻量化卷积神经网络为基础,提出一种可用于识别不同物联网设备的射频指纹识别方法,在信噪比较高的情况下,与传统基于机器学习的射频指纹识别方法相比,该方法具有更快的运行速度,但是准确度并没有明显提升,且在信噪比较低的情况下并不适用;刘念等^[11]以自动编码器为基本理论依据并结合射频链路双向通信中存在的互易规律,设计了一种可以将物联网设备学习任务转移到中心节点的射频指纹转换器,提出一种基于射频指纹识别的身份识别方法,该方法在信噪比较低的情况下仍然适用,但却使网络结构更为复杂,降低了运行速度;刘奇旭等^[12]以指纹识别的数据增强技术为基础构建相应的增强数据集,并搭建具有指纹特征不变性的基础模型,提出一种基于双向循环神经网络的指纹识别模型及监督学习框架,并通过对比试验证明模型的可行性,但是该方法通过随机采样采集数据,且采集到的数据量较小,存在一定的局限性;刘铭等^[13]以边缘计算为基本思想,通过考虑通信通道双向的互易性,提出一种以无线设备固有的射频指纹为依据的物联网终端设备身份识别方法,并结合深度学习实现双向设备身份识别,但是该方法中无线射频指纹的质量严重依赖于无线传播环境,有较大的局限性;XING 等^[14]提出一种适用于低信噪比环境的射频指纹识别新方法,以信息数据估计的叠加算法为基本依据,将重复的扩频序列进行叠加,通过对射频信号进行预处理消除噪声和干扰的影响,但是该方法对扩频序列的长度有一定要求,当扩频序列较短时会影响设备身份识别的准确度.

基于上述分析,针对移动终端设备用户的身份识别问题,本文提出一种基于轻量级 DenseNet 和 ZigBee 的指纹识别方法,基本思想:(1)以传统深度残差网络的基本思想为依据,通过前馈的方式改变层间的连接关系来构建轻量级 DenseNet;(2)通过筛选指纹图像、增强有效指纹和扩充样本数据等手段对指纹信息进行预处理;(3)以轻量级 DenseNet 模型和 ZigBee 为基础构建指纹识别系统.

与传统的身份识别方法相比,本文方法的创新点在于:

1) 构建轻量级密集连接卷积神经网络模型,并在此基础上结合 ZigBee 提出相应的指纹识别分类算法,较大程度地降低模型的复杂程度,提升算法的运行速度.

2) 通过对采集到的指纹信息进行预处理操作,大幅度提升指纹身份识别的准确度.

1 系统模型与指纹预处理

1.1 系统模型

基于轻量级 DenseNet 和 ZigBee 的指纹识别方法系统模型的基本结构如图 1 所示.所构建的模型在身份识别的过程中,首先收集 ZigBee 协议的信号建立射频指纹的数据集,然后构建 DenseNet 来识别采样信号,最后对模型进行适当裁剪来缩小模型的尺寸.信号通过型号为 BB50C 的频谱分析仪从信号收集装置

中进行收集.在信号数据的收集过程中,采用4个 ZigBee 设备共收集到信号样本 24 万个,每个信号样本都包含 1 000 个采样点.

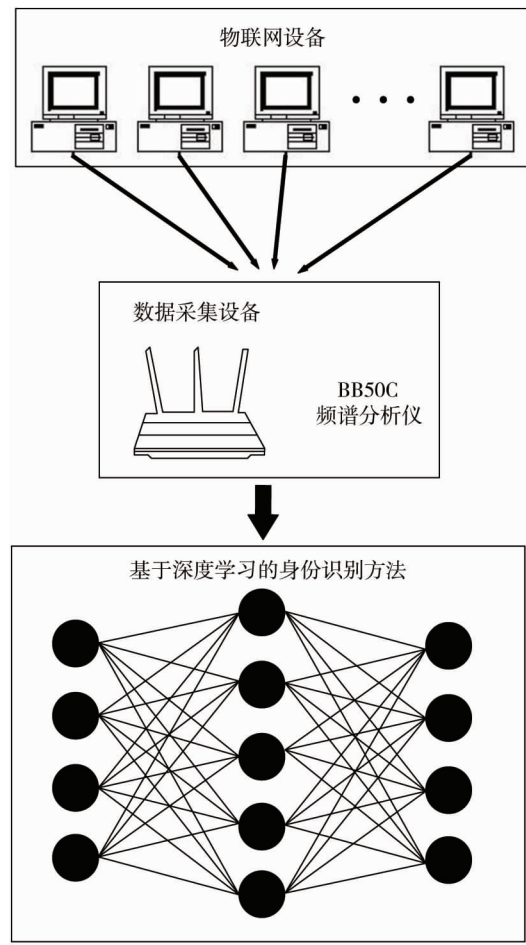


图1 本文方法的系统模型

1.2 指纹预处理

为了能够尽可能地提升指纹信息的匹配度,需要对采集到的指纹信息进行预处理,将虚假或残缺的指纹信息进行删除,并对部分遗漏的细节指纹信息特征进行恢复.指纹预处理主要包括以下3个步骤.

1) 对指纹图像进行筛选

一般情况下,指纹特征信息的采集是通过被采集对象用手指对信息采集装置进行按压来完成,然而指纹采集装置的面积相对较小,因此,在手指按压的过程中难免会出现按压程度不够或不完全、手指按压时间较短或移动速度过快等情况,这就会导致手指指纹信息采集不足,信息采集不足时的指纹如图2所示.




图2 信息采集不足时的指纹

图2所示的指纹信息采集不充足、有残缺,若将此指纹信息作为深度学习算法模型的输入数据,将会在一定程度上降低身份识别的准确度,大大增加身份识别错误的可能性.为了尽可能地减少指纹信息采集不足带来的影响,首先需要对采集到的所有指纹进行筛选,将信息残缺的指纹进行删除.

在指纹筛选过程中,以采集到的指纹图像的梯度幅度图像为基础,通过计算指纹的有效面积对有效指纹和无效指纹进行区分和筛选.采集到的指纹图像在水平方向上的梯度 $\Delta x(a,b)$ 和垂直方向上的梯度 $\Delta y(a,b)$ 可用式(1)和式(2)进行计算.

$$\Delta x(a,b) = I(a + 1,b) - I(a,b); \tag{1}$$

$$\Delta y(a, b) = l(a, b + 1) - l(a, b). \quad (2)$$

式中: (a, b) 为指纹图像的像素值; $l(a, b)$ 为坐标.

根据式(1)和式(2)中不同方向上的梯度对指纹图像的梯度幅度图像进行计算,如式(3)所示.

$$F_{GM}(a, b) = \sqrt{\Delta x^2(a, b) + \Delta y^2(a, b)}. \quad (3)$$

在求得指纹图像的梯度幅度图像的基础上对有效指纹和无效指纹进行区分和筛选.首先,对指纹图像中的每一个点的有效性进行判断,设定指纹中某个点被判定为有效指纹点的阈值,记为 $S_D(a, b)$,然后将梯度幅度图像在特定长度窗口下进行求和的结果 $S(a, b)$ 与判据 $S_D(a, b)$ 进行对比,判断该指纹点是否为有效指纹点.当窗口长度为 k 时,梯度幅度图像在该窗口下的求和结果 $S(a, b)$ 为

$$S(a, b) = \sum_{a=0}^k \sum_{b=0}^k F_{GM}(a - k, b - k). \quad (4)$$

若 $S(a, b) \geq S_D(a, b)$,说明该指纹点是有效指纹点,否则为无效指纹点.

通过对指纹图像中的所有点进行计算和对比,可以得到采集到的指纹的有效面积 A_E ,计算方法如式(5)所示.

$$A_E = \frac{N_E}{N_S} \times 100\%. \quad (5)$$

式中: N_E 为有效指纹点的数量; N_S 为指纹图像中像素点的总数量.

针对采集到的某个指纹图像,通过对比计算得到指纹的有效面积 A_E 与设定的有效面积阈值 A_S ,即可确定该指纹是否为有效指纹.若 $A_E \geq A_S$,说明该指纹是有效指纹,进行保留,否则说明该指纹是无效指纹,进行删除.

2) 对有效指纹图像进行增强

除了指纹采集装置可能带来的指纹采集不充分的情况,指纹采集过程中外界的噪声干扰、手指按压过程中过于用力导致指纹线粘连、手指本身存在的伤疤和老茧,以及少数人指纹线本身不连续等也可能造成指纹特征识别结果不准确以及识别速度下降等问题.尤其是外界噪声干扰可能会使得指纹识别算法在计算过程中误将噪声干扰作为指纹的特征信息,造成身份识别准确率的下降.

为了解决以上问题,在指纹预处理过程中引入指纹的图像增强环节,通过归一化处理 and 带通滤波器对有效指纹进行增强,对上述情况下得到的指纹图像在一定程度上进行修复,有效指纹在增强处理前后的对比如图3所示.

3) 对增强处理后的数据样本进行扩充

在深度学习方法中,通常会用到数据扩充,其目的是为了在数据样本较少的情况下增加样本数据,并防止过度拟合的情况出现.对于采集到的指纹特征信息,每一条指纹线的角度都有一个微小旋转,以此为依据对增强处理后的有效指纹分别顺时针和逆时针旋转 5° 和 10° ,可将原本的数据样本的数量增加4倍.使用扩充后的数据样本进行训练学习可以在一定程度上提升指纹身份识别的准确率.




图3 有效指纹增强前后对比

2 DenseNet 的构建

2.1 DenseNet 的基本思想

DenseNet 的基本思想始于传统的深度残差网络模型,通过前馈的方式把所有层的输出位置都与除本层之外的其他层进行连接,从而达到对传统深度残差网络中较短距离连接进行扩充的目的,实现对传统深度残差网络的改进.增长率为6的4层 DenseNet 的基本结构如图4所示.在 DenseNet 中,信息特征的重复利用可以起到加强特征传播的作用,同时也可以在一定程度上避免梯度消失等问题.

对于含有 N 层结构的 DenseNet 而言,若第 x 层结构的输出结果用 F_x 表示,那么第 x 层结构的特征为 $F_x = f_x([F_1, F_2, F_3, \dots, F_{x-1}])$. (6)

式中: $F_i(i = 0, 1, 2, \dots, x - 1)$ 为第 i 层结构层的特征图像; $[F_1, F_2, F_3, \dots, F_{x-1}]$ 为第 x 层之前所有结构层的特征信息组成的张量; f_x 为复合函数 BaNor_RL_C(1×1)_RL_C(3×3), 其中, BaNor 为批量归一化操作, RL 为整流线性化操作, C(1×1) 和 C(3×3) 分别为 1×1 和 3×3 的卷积操作。

由图 4 和式(6)可知:第 x 层结构接收了第 x 层之前所有结构层的特征信息,对输入数据采取 1×1 的卷积操作后,可以在一定程度上缩减输入数据的特征量,从而实现降维计算并将所有通道的特征量进行融合,最终可以大大地减少计算量。

以 DenseNet 为基础,搭建能够同时考虑指纹信息特征提取速度以及指纹信息特征匹配效率的轻量级 DenseNet 模型,其基本结构如图 5 所示。

图 5 所示的轻量级 DenseNet 模型中的增长率为 12,取像素为 96×96 的指纹特征图像作为样本,将该样本经过指纹预处理操作后作为模型的输入数据.数据输入模型后首先进行 5×5 的卷积操作,然后通过 3 个不同的密集连接卷积模块 (DenseMod),且每两个 DenseMod 之间都有一个过渡结构层,最终可计算出 384 个像素为 12×12 的特征模板.一般的神经网络以全局池化层作为全连接层的输入数据进行计算,该轻量级 DenseNet 模型对此进行了优化,通过提取特征模板的特征作为全连接层的输入数据进行计算。

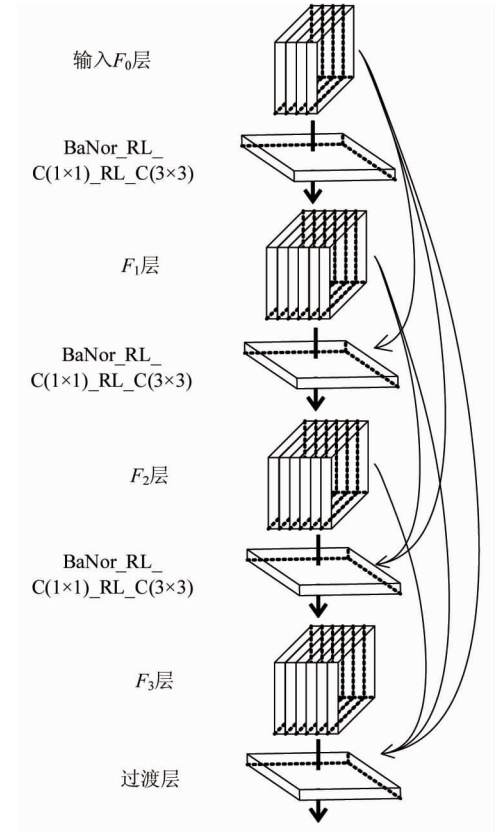


图 4 增长率为 6 的 4 层 DenseNet 的基本结构

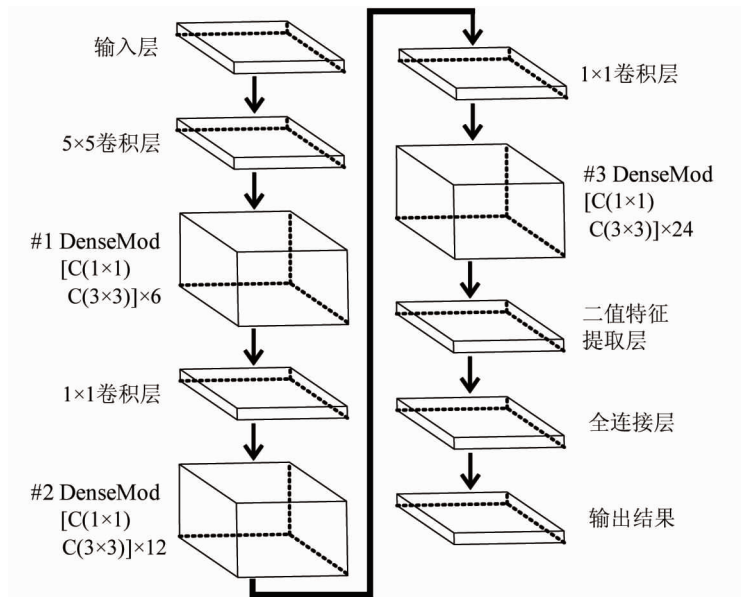


图 5 轻量级 DenseNet 模型基本结构

2.2 密集层

密集层的基本作用是将特征空间映射到样本空间,在分类模型中密集层是必不可少的.此外,特征数据在进入密集层之前需要经过压平处理,这就会导致模型中参数数量的增加以及模型训练时间的延长。

综合考虑输入数据样本集合的大小,模型中的神经网络采用卷积层和密集层而不使用池化层.深度学习方法的主要目的是利用若干神经元堆积函数,并以大量的样本数据为基础,通过反向拟合该函数的各个未知参数来实现对该函数的拟合,最终通过该函数的反向拟合结果绘制出其完整曲线.为了尽可能地扩大神经网络的表达能力,神经网络应当除了具有线性激活功能之外还应当具有非线性激活能力.深度学习中常用的非线性激活函数有 ReLU 函数和 Softmax 函数,表达式分别如式(7)和式(8)所示。

$$h_R(x_i) = \max(x_i, 0); \quad (7)$$

$$h_S(x_i) = \frac{\exp(x_i)}{\sum [\exp(x_i)]}. \quad (8)$$

式中: \max 为在函数中选择最大值; x_i 为训练样本.

ReLU 函数通常用于图层之间,而 Softmax 函数通常用于多重分类问题中.通过对比式(7)和式(8)所示的 2 个非线性激活函数可以看出:Softmax 函数存在“渐变消失”的问题,并且 Softmax 函数在 $|x| > 4$ 的情况下梯度非常小,此外,ReLU 函数的计算速度要远远高于 Softmax 函数.

ReLU 函数通常被应用于稀疏性问题中且具有良好的效果,它可以在最大限度地发挥每个神经元的筛选作用的同时,将符合一定功能的中间值进行多倍放大,而不符合此功能的中间值将会被直接删除.但是在某些特定情况下,如梯度过大或者学习率设置过大,权重会在一次更新中的变化很大,此时对于任何数据而言,训练样本 x_i 的值都是负数并且带有 ReLU 函数的神经网络的输出结果将为零.这种情况下可以用 Leaky ReLU 函数来代替 ReLU 函数.

根据公式可以知道 Softmax 函数输出值的总和为 1,这个特点使得 Softmax 函数适合用于多重分类问题.例如,如果神经网络用于识别具有 4 类的目标数据,那么 Softmax 函数就可以输出 1×4 的向量,而这些输出向量分别代表该数据属于哪个类别的可能性大小.

为了尽可能地减小过度拟合的可能性,一般通过 Dropout 使随机神经元“死亡”.Dropout 中的参数代表“存活”神经元中已经“死亡”的神经元的比率.Dropout 随机地“杀死”一些神经元,从而降低神经网络过度依赖某些局部特征以适应其功能的可能性.神经网络的 Dropout 过程示意图如图 6 所示.

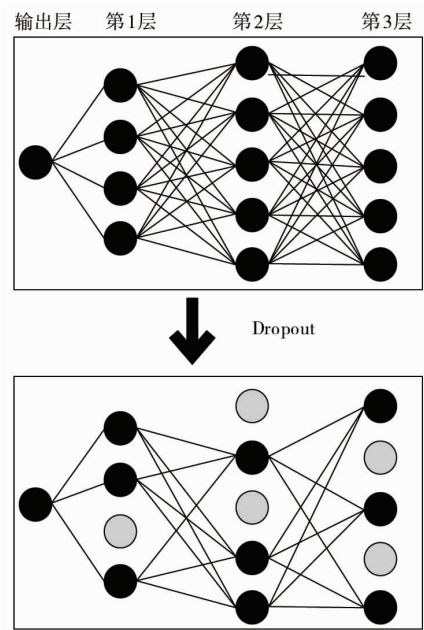


图 6 Dropout 过程

本文选择分类交叉熵作为模型的损失函数,其主要原因是在神经网络的训练过程中,相比于绝对值、均方误差等损失函数,交叉熵可以使训练收敛得更快,减少调参的幅度震荡,不会出现梯度消失的问题.交叉熵的表达式如式(9)所示.

$$L_{\text{CCE}} = - \sum_{k=1}^K m_k \log[p_k(n)]. \quad (9)$$

式中: K 为分类的类别数量; m_k 为输入数据的真实标签; $p_k(n)$ 为模型的预测,在识别问题中表示标签; n 为输入数据.

2.3 指纹识别

目前,市场上应用指纹识别技术的智能设备一般首先需要用户利用自身的指纹信息进行身份注册,完

成身份注册后,在日后的使用过程中就可以利用指纹信息与注册信息进行匹配,完成对设备的解锁.基于指纹身份注册的指纹信息识别过程如图7所示.

图7中基于指纹身份注册的指纹信息识别过程包括身份注册和身份匹配2个阶段.在身份注册阶段,首先通过指纹信息采集装置对用户的指纹信息进行采集,由于设备中植入的指纹信息采集装置的面积相对于手指一般较小,而指纹识别的准确度与采集到的指纹有效面积息息相关,所以在身份注册阶段的指纹信息采集过程中,一般需要进行多次多角度地采集以获得更为完整的指纹信息.然后根据1.2节的方法对采集到的指纹信息进行预处理,接着通过深度学习算法对预处理后的指纹信息特征进行提取,最后再以提取到的有效指纹特征信息为基础建立相应的指纹信息数据库,完成身份注册.

在身份匹配阶段,通过指纹信息采集装置对解锁人的指纹信息进行采集,对采集到的指纹信息进行预处理,接着通过深度学习算法对预处理后的指纹信息特征进行提取,再将提取到的有效指纹特征信息与指纹信息数据库中的指纹信息分别进行粗匹配和精匹配,根据提前设定好的判据值输出判定结果,完成身份识别.

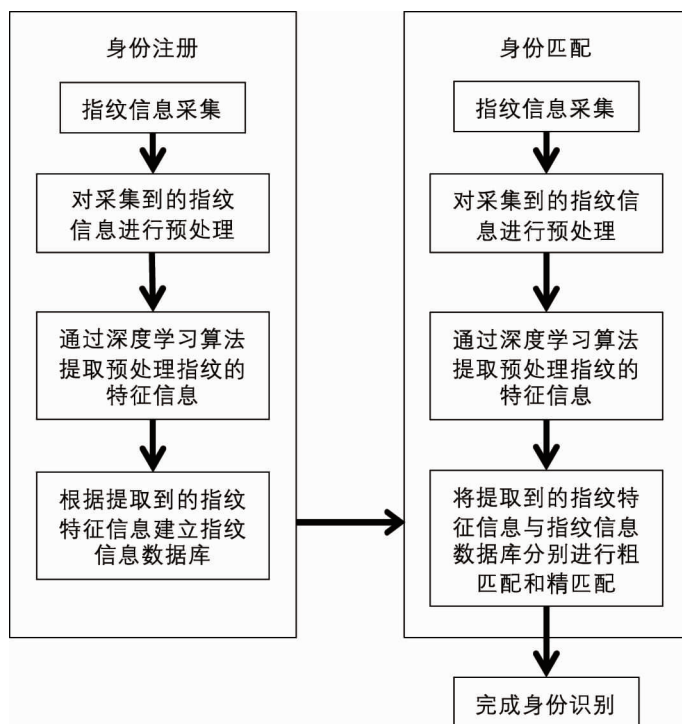


图7 基于指纹身份注册的指纹信息识别过程

3 试验结果与分析

DenseNet 和轻量级 DenseNet 模型的仿真过程以后端为 Tensorflow 的 Keras 为基础实现.采集到的指纹信息的预处理过程基于 MATLAB 实现,传统的机器学习算法和混淆矩阵以 sklearn 为基础实现.

3.1 数据处理

对数据进行处理的过程主要是对采集到的指纹图像进行增强,包括对指纹图像进行合理角度的旋转、对指纹图像中指纹线的对比度进行适当的加强和对指纹图像进行一定程度的直方图均衡化操作等.人类的指纹一般包括弓型、弓帐型、左箕型、右箕型和斗型这5种类型,分别如图8所示.




图8 5种不同的指纹类型

在对指纹图像进行旋转前,需要考虑旋转不变性原则并不适用于所有指纹类型图像.由图8可知:左箕型和右箕型指纹在旋转后无法进行准确区分,因此,在对指纹图像采取旋转操作时应当主要避免指纹类别的混淆,不在水平或垂直方向上旋转,只在合理的小角度范围内对指纹进行旋转,或者在小范围内对指纹进行适当地放大和缩小,目的是为神经网络的训练提供足量的训练样本.

指纹数据处理的具体过程如下:

1) 首先针对5种类型的指纹分别采集1000张指纹图像,然后在每一种类型的指纹图像中随机抽取

50 张共 250 张指纹图像作为单独分类测试的样本指纹图像,对其进行保留且该数据集不参与网络模型的训练学习。

2) 在每一类指纹图像中,从剩余的 950 张图像中各随机抽取 250 张共 1 250 张指纹图像,对这 1 250 张指纹图像进行直方图均衡化操作,每一类指纹图像最终得到 500 张数据图像数据集,该数据集不参与网络模型的训练学习。

3) 对每一类剩余的 700 张指纹图像分别进行 9 次小角度微旋转和适当倍率的缩放,使得样本数据量增加 9 倍,变为 35 000 张。

指纹数据处理后的效果如图 9 所示。




图 9 指纹图像的不同处理效果

3.2 损失和准确性分析

对采集到的指纹样本数据进行处理后,利用搭建完成的轻量级 DenseNet 网络模型对该数据集进行训练.训练过程中分别抽取 5 类指纹类型的样本图像各 500 张进行训练,每一种类型指纹训练的分类结果及分类准确率如表 1 所示.主对角线元素为不同类型分类的准确结果.如对于弓型,其准确率计算: $483 \div (483 + 8 + 2 + 3 + 4) = 96.6\%$.其他依此类推.

表 1 5 种类型指纹基于轻量级 DenseNet 模型的分类结果

样本类型	分类结果				
	弓型	弓帐型	左箕型	右箕型	斗型
弓型	483	11	0	1	1
弓帐型	8	480	2	1	0
左箕型	2	2	498	2	0
右箕型	3	3	0	496	0
斗型	4	4	0	0	499
准确率/%	96.6	96.0	99.6	99.2	99.8
平均准确率/%	98.24				

由表 1 可知:分别对 500 张弓型、弓帐型、左箕型、右箕型和斗型的指纹样本图像进行模型训练后,它们的准确率都在 96.5% 以上,平均准确率为 98.24%.分类准确率最低的是弓型和弓帐型指纹,这主要是由于样本中的弓型和弓帐型指纹图像存在 2 种类别标记的模糊分类,是采样数据本身存在的问题。

为了进一步说明该轻量级 DenseNet 模型在指纹图像分类问题上的优越性,在训练相同样本数据的前提下,分别通过基于轻量级 DenseNet 模型、普通 DenseNet 模型以及 3 种传统的机器学习模型(支持向量机模型、决策树模型以及随机森林模型)对该样本数据进行训练学习,5 种算法模型指纹分类结果的准确率如表 2 所示。

表 2 基于不同算法模型的指纹分类准确率

算法模型	指纹分类的平均准确率/%
轻量级 DenseNet 模型	98.24
普通 DenseNet 模型	98.38
支持向量机模型 ^[15]	56.23
决策树模型 ^[16]	60.47
随机森林模型 ^[17]	71.49

由表 2 可知:与 3 种传统的机器学习模型相比,轻量级 DenseNet 模型和普通 DenseNet 模型均显示出极好的指纹分类准确性.这主要是由于基于深度学习的算法模型在指纹身份识别问题上具有明显的优势,相对于传统基于机器学习算法而言,基于深度学习的算法模型能够更加准确地地区分指纹图像中的干扰因素并加以剔除,同时在不同类型指纹的特征提取及特征匹配方面更加精准.因此,轻量级 DenseNet 模型和普通的 DenseNet 模型能够大幅度提升指纹分类的准确率.

此外,与普通 DenseNet 模型相比,轻量级 DenseNet 模型的指纹分类准确率只相差 0.06%,由此可知轻量级 DenseNet 模型在分类的准确程度上并没有明显的优越性.但是轻量级 DenseNet 模型的网络框架相对更加简洁,其运行速度和计算速度相对更快,使得 DenseNet 模型的整体性能有了较大的提升.

普通 DenseNet 模型和轻量级 DenseNet 模型在模型训练过程中,训练样本和测试样本的损失曲线和准确率曲线分别如图 10 和图 11 所示.




图 10 普通 DenseNet 模型的样本损失和准确率

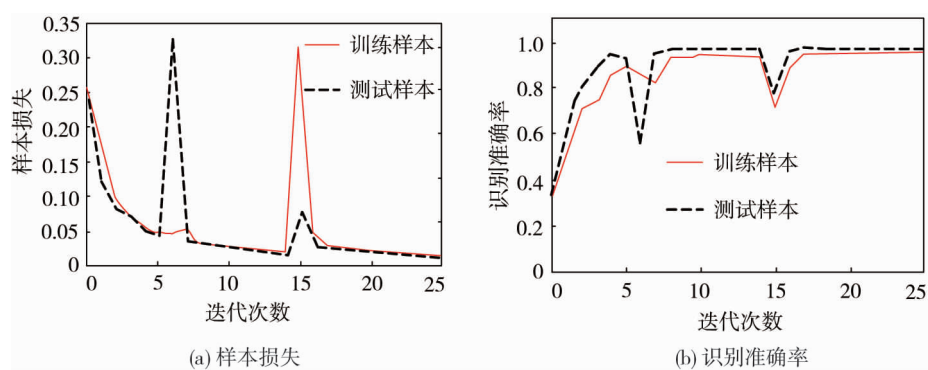


图 11 轻量级 DenseNet 模型的样本损失和准确率

由图 10 和图 11 可知:不论是普通 DenseNet 模型还是轻量级 DenseNet 模型,训练样本和测试样本的损失曲线和识别准确率曲线都有相同的趋势,且样本损失曲线的下降速度很快,说明这 2 种 DenseNet 模型都具有相对良好的指纹分类性能.

3.3 复杂度分析

由前面的分析可知,轻量级 DenseNet 模型分类的准确率与普通 DenseNet 模型的差别不大,但理论上讲,轻量级 DenseNet 模型具有更快的运行速度和计算速度.下面分别以模型中参数的数量、训练模型的大小以及模型中的浮点运算量为标准,对轻量级 DenseNet 模型和普通 DenseNet 模型计算过程的复杂度和模型网络结构的复杂度进行分析.

轻量级 DenseNet 模型和普通 DenseNet 模型中不同标准参数的详细数据如表 3 所示.

表 3 轻量级和普通 DenseNet 模型中相关数据对比

参数	轻量级 DenseNet 模型	普通 DenseNet 模型	复杂度相对下降率/%
参数的数量	226 949	4 169 854	94.56
模型的大小	2 964	50 135	94.09
浮点运算量	496 357	8 497 354	94.16

表3中的参数数量和模型的大小表述了模型网络空间结构的复杂程度,而浮点运算量表述了该模型在运算过程中的复杂程度.由表3可知:轻量级 DenseNet 模型相对于普通 DenseNet 模型而言,模型中参数的数量和模型的大小分别下降 94.56% 和 94.09%,而模型中的浮点运算量下降 94.16%,这表明轻量级 DenseNet 模型具有更加简洁的空间结构,更快的运行速度和计算速度.

4 结论

1) 通过筛选、增强以及扩充等操作对采集到的指纹信息进行预处理,并通过改进传统深度残差网络构建轻量级 DenseNet 模型.

2) 轻量级密集连接卷积神经网络模型结合 ZigBee,可以在一定程度上降低模型的复杂程度.

3) 在同一条件下对不同算法模型进行训练,所得结果表明基于轻量级 DenseNet 模型的准确率高,运算速度最快且复杂程度最低.

4) 未来,将针对指纹采集装置面积较小的情况以及外界噪声因素对所提算法模型的影响展开进一步研究.

参考文献:

- [1] ÖZÇAKMAK B, ÖZBILEN A, YAVANOĞLU U, et al. Neural and quantum cryptography in big data: A review[C]//2019 IEEE International Conference on Big Data (Big Data). IEEE, 2019: 2413-2417.
- [2] LUO W F, XU X C, DENGW, et al. A RFF access authentication technology based on k-nearest neighbor method[C]//2019 International Conference on Intelligent Computing, Automation and Systems (ICICAS). IEEE, 2019: 852-855.
- [3] ZHANG Y N, DU Y R, ZHEN A R, et al. The intelligent parking lot based on ZigBee technology and SVM[C]//2017 14th IEEE Annual Consumer Communications & Networking Conference (CCNC). IEEE, 2017: 620-621.
- [4] 孙丽婷,黄知涛,王翔,等.辐射源指纹特征提取方法述评[J].雷达学报,2020,9(6):1014-1031.
- [5] 俞佳宝,胡爱群,朱长明,等.无线通信设备的射频指纹提取与识别方法[J].密码学报,2016,3(5):433-446.
- [6] YANG K, KANG J, JANG J, et al. Multimodal sparse representation-based classification scheme for RF fingerprinting[J]. IEEE Communications Letters, 2019, 23(5): 867-870.
- [7] 张敏,罗正华,黄建刚,等.一种基于 I/Q 失配的辐射源指纹提取方法[J].电子学报,2020,48(4):717-722.
- [8] ZENG F F, HU S D, XIAO K. Research on partial fingerprint recognition algorithm based on deep learning[J]. Neural Computing and Applications, 2019, 31(9): 4789-4798.
- [9] 余沁,程伟,李敬文.利用小波变换特征提取的通信辐射源个体识别方法[J].信号处理,2018,34(9):1076-1085.
- [10] 孙汝杰.基于轻量级 CNN 的射频指纹识别[J].电子技术与软件工程,2021(4):7-8.
- [11] 刘念,任佳鑫,韩晓艺,等.基于射频指纹的物联网设备身份识别方法[J].现代计算机,2020(19):3-8.
- [12] 刘奇旭,刘心宇,罗成,等.基于双向循环神经网络的安卓浏览器指纹识别方法[J].计算机研究与发展,2020,57(11):2294-2311.
- [13] 刘铭,刘念,韩晓艺,等.一种基于射频指纹的电力物联网设备身份识别方法[J].中国电力,2021,54(3):80-88.
- [14] XING Y X, HU A Q, ZHANG J Q, et al. On radio frequency fingerprint identification for DSSS systems in low SNR scenarios[J]. IEEE Communications Letters, 2018, 22(11): 2326-2329.
- [15] 陈子骁,周小明,李钊,等.一种基于射频指纹的电网无线设备入侵检测算法[J].无线电工程,2021,51(5):352-359.
- [16] 南世慧,魏伟,吴华清,等.基于 KNN 和 GBDT 的 Web 服务器指纹识别技术[J].计算机科学,2018,45(8):141-145.
- [17] 蔡满春,王腾飞,岳婷,等.基于 ARF 的 Tor 网站指纹识别技术[J].信息安全,2021,21(4):39-48.