

张莉华. 基于 ARM 和深度学习的大数据指纹识别系统设计[J]. 湖南科技大学学报(自然科学版), 2019, 34(1): 77-84. doi: 10.13582/j.cnki.1672-9102.2019.01.012

Zhang L H. Design for Big Data Fingerprint Recognition System Based on ARM and Deep Learning [J]. Journal of Hunan University of Science and Technology(Natural Science Edition), 2019, 34(1): 77-84. doi:10.13582/j.cnki.1672-9102.2019.01.012

基于 ARM 和深度学习的大数据 指纹识别系统设计

张莉华*

(黄淮学院 信息工程学院, 河南 驻马店 463000)

摘要:针对传统指纹识别系统在面对大数据指纹图像时具有识别效率不高、需要手动设计提取的特征的缺点,提出了一种基于 ARM 和深度学习的大数据指纹识别系统.首先,描述了指纹识别系统的原理图.然后,设计了系统硬件框图,采用 S3C2410C 作为微处理器,采用 FPS200 指纹图像作为传感器,并设计了两者的接口电路;最后,重点设计了指纹识别的软件过程,建立一个可以进行指纹自动识别的通用多层深层神经网络.通过设计系统软硬件并进行测试,结果表明文中设计的指纹识别系统具有很高的指纹识别准确度,能有效处理大数据指纹图像的识别,且与其他基于人工提取特征的方法相比,具有更高的识别正确率和识别效率.

关键词:指纹;识别率;匹配;深度学习;大数据

中图分类号:TP391.4

文献标志码:A

文章编号:1672-9102(2019)01-0077-08

Design for Big Data Fingerprint Recognition System Based on ARM and Deep Learning

Zhang lihua

(School of Information Engineering, Huanghuai University, Zhumadian 463000, China)

Abstract: Aiming at the traditional fingerprint recognition system had the problems such as not high recognition rate and having to design the feature manually, a big data fingerprint recognition system based on ARM and deep learning was proposed. Firstly, the fingerprint system was specified. Then, the S3C2410C was used as the micro-processor and FPS200 as the fingerprint sensor, the interface circuit between them was also designed. Finally, the software process of fingerprint recognition was designed in detail, the input layer, convolutional layer, feature automatically extraction layer and the output layer was constructed to be a deep neural network. Via designing the system hardware and software and the test, the result shows the method has the high fingerprint recognition rate, which achieve the fingerprint figure for big data. Compared with the other methods which uses the feature extracted manually, the method has higher recognition rate and recognition efficiency.

Keywords: Fingerprint; recognition rate; match; deep learning; big data

指纹识别是一种实现智能监控的生物识别技术^[1].由于其具有唯一性、稳定性和采集的方便性的特

收稿日期:2018-08-06

基金项目:河南省科技厅发展计划资助项目(142102110088; 182102210100)

*通信作者, E-mail: zlw_gcxx@126.com

征,使其相对于其他生物识别技术如脸相、虹膜、视网膜和声纹等身份识别技术具有更安全、可靠和方便的特征^[2-3].同时随着硬件的成本降低和计算机软件技术的发展和进步,指纹识别系统具有更为快速和准确率高的优点,已经趋向于民用化,目前已经在金融系统、文件保密系统、门禁/考核系统、远程认证系统和保险管理系统中获得广泛的重视^[4-5].

虽然指纹识别系统目前已经获得了巨大的进步但仍未能得到普及的应用^[6]:

一方面是由于传统指纹往往采用细节点或方向场,只包含了识别的部分关键信息,指纹识别系统的识别性能也难以达到理想的要求,尤其是在条件的变化的情况下,如气候、光照以及其他噪声影响,使得被提取的指纹特征难以实现指纹识别;

另一方面是成本因素,指纹识别系统需要设计软硬件,较传统的射频考勤系统成本要高很多,因此,限制了指纹识别系统的进一步应用.

为了实现指纹的准确识别,文献[7]提出了1种基于模式汽配算法的改进算法,通过加入匹配权重系数,提高指纹识别的精确度,并设计了硬件结构,将其用于嵌入式应用中.文献[8]将方向场和灰度共生矩阵的纹理特征结合,并将LBP算子的纹理方法和细节点特征方法融合,形成了1种多特征融合的指纹识别方法.文献[9]设计了基于单DLP处理器的三维指纹识别系统,采用TMS320VC5402为处理器核心,将指纹识别过程分为DT网格构造、选取识别参考点、校正指纹姿势和对指纹进行匹配.

上述工作均设计了指纹识别系统,推动了指纹识别技术的发展,但仍然需要手工提取特征,不能自动提取有效的特征,从而在环境变化或有噪声条件下,使得指纹识别的精确度降低.

因此,本文设计了1种基于ARM和深度神经网络(Deep Neural Network)的大数据指纹识别系统,能有限实现大量指纹的实时自动地识别,且相比其他方法,具有指纹识别精度高的优点.

1 指纹识别原理

指纹识别系统的主要功能就是从指纹数据库中查找出与某指纹匹配的指纹数据,从而实现身份的辨别^[10-14].指纹识别系统主要包括指纹图像的采集、指纹图像的预处理、特征的采集、特征的匹配和输出显示5个阶段.

指纹图像的采集是通过设计指纹硬件系统来实现图像的采集,然后对指纹图像进行预处理,预处理主要是通过Gabor滤波对指纹图像进行降噪,将其转换为二值图,然后通过设计深度信念网络,并采用指纹数据库中的指纹数据集对深度信念网络进行训练,得到能自动提取特征的深度学习模型,此时将指纹数据库输入到深度学习模型中可以得到特征数据库.对于需要进行匹配的指纹图像,将其输入到深度学习模型中就可以得到自动提取的特征,将此特征与特征数据库进行匹配,得到精确的匹配结果.

文中设计的手指识别系统的基本原理框图如图1所示.

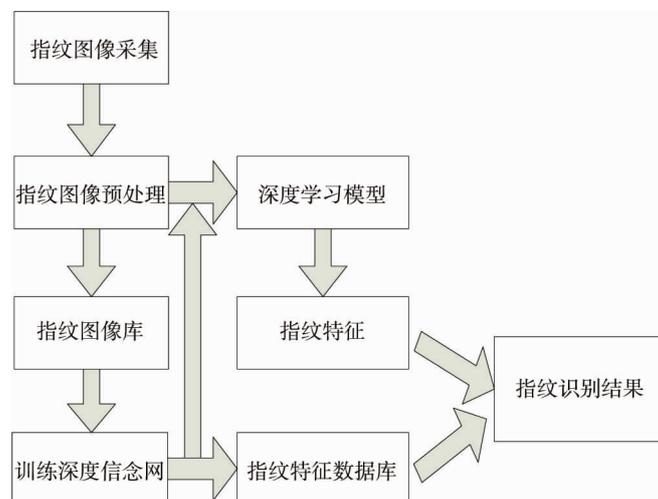


图1 指纹识别系统原理框图

2 系统硬件设计

2.1 微控制器和指纹传感器

指纹图像自动识别系统是对采集的指纹图像进行处理和识别.系统微处理采用由三星公司生产的基于 ARM920T 内核的 RISC 微处理器 S3C2410,主频为 203 MHz,S3C2410 集成了丰富的外围接口,具有处理能力高和成本低廉的优点,在信息控制、PDA 和移动手持终端领域都有广泛的应用.

指纹图像传感器采用 FPS200(见图 2),FPS200 是由 Veridicom 公司研发的具有体积小、功耗低和价格低廉的具有 CMOS 工艺的第三代半导体传感器,结构为 256 列和 300 行的电容阵列.FPS200 在待命模式下的操作电流小于 20 μ A,图像数据的传输速度接近 30 帧每秒.FPS200 具有很强的感知能力,能对皮肤表皮以下的指纹进行读取,能使得指纹识别不受皮肤表面脏和油腻等自然条件的影响,能使得采集的指纹图像具有较强的被识别能力.

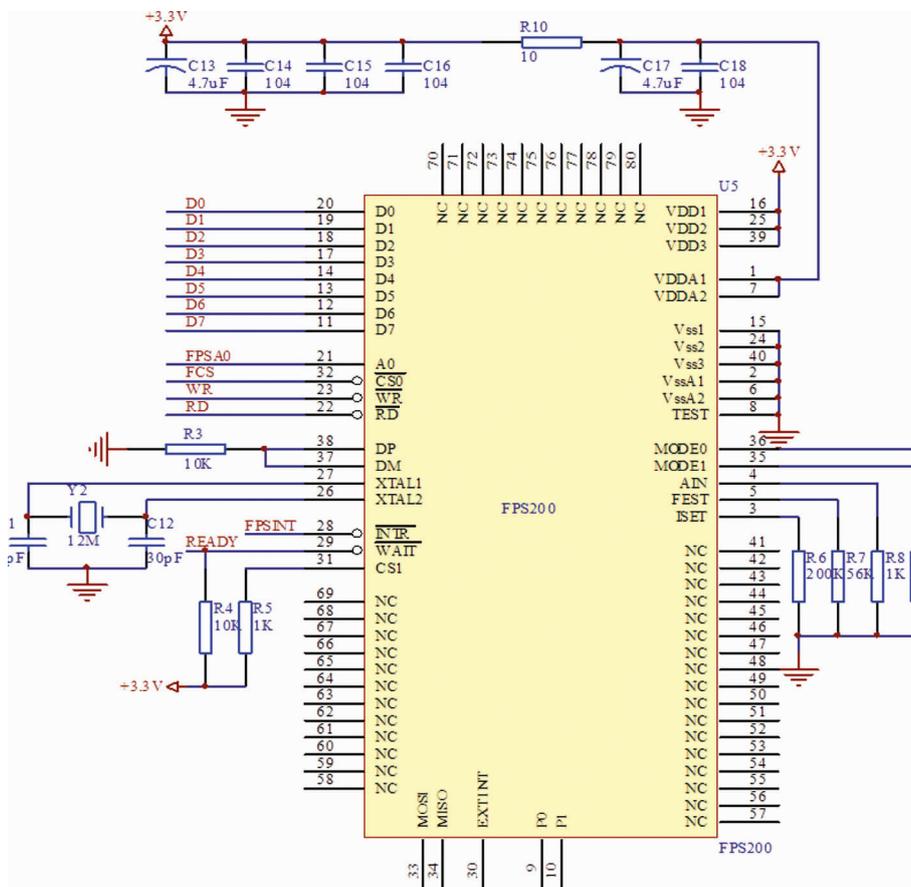


图 2 FPS200 指纹传感器电路图

2.2 系统硬件框图

系统硬件的设计采用了 S3C2410 微处理器和 FPS200 传感器,如图 3 所示.

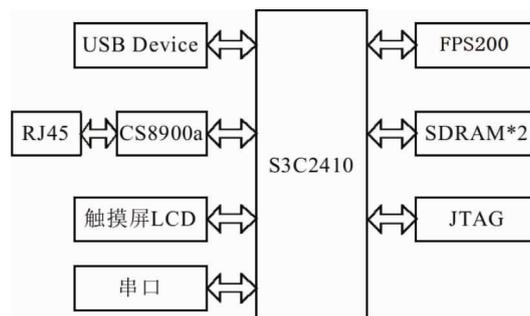


图 3 系统硬件框图

从图3中可以看出,S3C2410通过USB Device接口和以太网接口来实现PC机的连接,指纹数据库存储在PC机上.内存通过2片SDRAM来实现32位宽度的物理内存,通过1个32M Nand Flash来保存操作系统Windows CE.

FPS200和S3C2410的连接如图4所示.在图4中,采用GPIO3用于控制传感器电源,指纹传感器FPS200与微处理器S3C2410之间的有2组传输通道.2组通道都采用SPI串行外围总线时序(Serial peripheral interface),其中1组通道实现处理器到传感器之间的指令传送,传感器在接收到处理器发送的指令后,从另1组传感器到处理器的传输通道向传感器发送数据,由于指纹图像数据往往具有较大的数据量,因此,在传感器的接收端,采用SPI接口(CLK0, MOSIO, Nss0)来连接传感器,并采用直接存储器访问DMA(Direct memory access)来接收数据和提高性能.

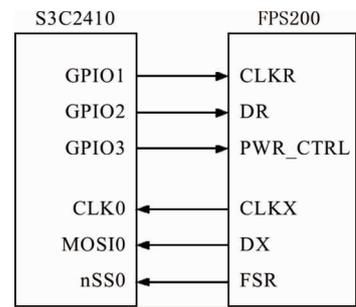


图4 FPS200和S3C2410连接

3 指纹识别系统的软件设计

3.1 指纹识别总体软件描述

指纹识别系统软件流程如图5所示.文中的指纹识别系统软件是在指纹数据被采集后,通过指纹图像的预处理后,并通过深度学习模型来学习指纹的本质特征,从而与指纹数据库进行特征匹配,将匹配的结果作为识别的结果.

指纹识别系统的软件流程主要包含2部分:

1)建立深度神经网络,并采用指纹数据库中的指纹来对深度神经网络进行训练和学习.

由于指纹图像数据的像素多,因此,第1层为输入层,第2层为卷积层,卷积核的形式采用Gabor小波,通过权值共享的方法减少需要训练的权值参数.

从第2层到 $n-1$ 层为RBM构成的对等层,实现特征的自动提取,并通过CD(Comparison Difference)算法实现每2层RBM的训练,最终训练出整个的自动特征提取的RBM深度网络;

第 n 层为标签层,对指纹数据库中不同指纹建立标签,同时增加一个未知类型的标签,并通过反向传播算法实现从第 $n-1$ 到第 n 层的权值训练.

2)指纹的匹配.对于指纹传感器新采集的指纹,经过预处理成灰度图后,就可以将其输入到多层的深度神经网络,经过深度神经网络中的Gabor卷积层进行降噪,并通过多层的RBM进行自动特征提取,最后在标签层被激活的神经元对应的标签即为检测的结果.

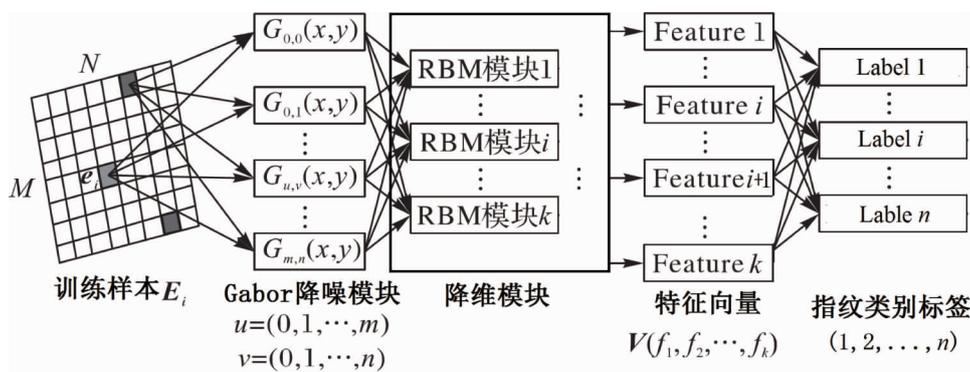


图5 指纹识别系统软件流程

3.2 基于Garbor滤波的指纹图像降噪

Gabor滤波器具有较好的方向和尺度选择特性,同时具有对边缘敏感和光照变化的不敏感性,较传统的傅里叶变换具有更好的时频局部化特性,因此,具有更好的时域和频域的分辨能力,能较好地去除噪声影响.Gabor小波变换可以表示为

$$y_{u,v}(x) = \frac{\|k_{u,v}\|}{\sigma^2} \exp\left(-\frac{\|k_{u,v}\|^2 \|p_x^2 + p_y^2\|}{2\sigma^2}\right) \left[\exp\left(ik_{u,v} \begin{pmatrix} p_x \\ p_y \end{pmatrix}\right) - \exp\left(-\frac{\sigma^2}{2}\right) \right]. \quad (1)$$

式中: σ 为与 Gabor 小波频率宽带相关的常数; $p = (p_x, p_y)$ 表示图像空间中某位置的图像坐标; $\exp\left(ik_{u,v} \begin{pmatrix} p_x \\ p_y \end{pmatrix}\right)$ 为实部为余弦、虚部为正弦的振荡函数; $\exp\left(-\frac{\sigma^2}{2}\right)$ 为使滤波器对照明不敏感的直流分量; $\exp\left(-\frac{\|k_{u,v}\|^2 \|p_x^2 + p_y^2\|}{2\sigma^2}\right)$ 为高斯函数,能准确表达时频结构和空间关系信息; $k_{u,v}$ 为 Gabor 内核的不同

方向和尺度,通过选取不同的 $k_{u,v}$ 可得到不同的 Gabor 滤波器,如当 $k_{u,v}$ 中的 φ_u 取 $\sqrt{2}\pi$ 时, $k_{u,v}$ 可以表示为

$$k_{u,v} = \begin{bmatrix} k_v \cos\varphi_u \\ k_v \sin\varphi_u \end{bmatrix}. \quad (2)$$

式中: v 表示频率; u 表示采样方向; $k_v = 2^{\frac{v+2}{2}\pi}$ 和 $\varphi_u = u\pi/K$. 当选择 8 个方向和 5 个尺度后的 Gabor 滤波器,如 $v \in \{0,1,2,3\}$, $u \in \{0,1,2,3,4,5,6,7\}$.

指纹图像的 Gabor 特征即为该图像的灰度图与选取的 Gabor 滤波器的卷积,如式(3)所示:

$$\text{Gabor}_{u,v}(p) = I(p) * y_{u,v}(p). \quad (3)$$

3.3 多层 RBM 的神经网络训练

由于指纹图像数据较大,新建 1 个多层的 RBM 神经网络,对其进行降维.RBM (Restricted Boltzmann machine) [10-12] 是一个二部图,其结构如图 6 所示.

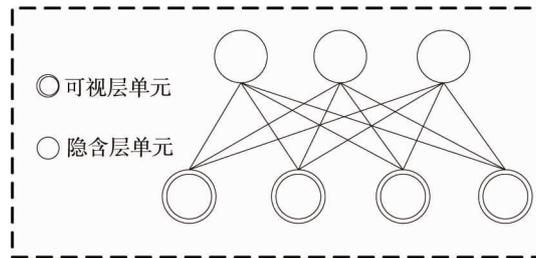


图 6 RBM 模型

RBM 的联合模型的能量可以表示为

$$E(\mathbf{v}, \mathbf{h}; \theta) = -\mathbf{v}^T \mathbf{W} \mathbf{h} - \mathbf{b}^T \mathbf{v} - \mathbf{a}^T \mathbf{h} = \sum_{i=1}^m \sum_{j=1}^n W_{ij} v_i h_j - \sum_{k=1}^m b_k v_k - \sum_{k=1}^n a_k h_k. \quad (4)$$

从式(4)可以看出,1 个 RBM 的联合概率分布可以表示为

$$\text{Pro}(\mathbf{v}, \mathbf{h}; \theta) = \frac{\exp(-E(\mathbf{v}, \mathbf{h}; \theta))}{\sum_{\mathbf{v}, \mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h}; \theta))} = \frac{\prod_{ij} e^{W_{ij} v_i h_j} \prod_i e^{b v_i} \prod_i e^{a h_i}}{\sum_{\mathbf{v}, \mathbf{h}} \exp(-E(\mathbf{v}, \mathbf{h}; \theta))}. \quad (5)$$

由于 RBM 中同层节点之间的相互独立性,因此,式(6)成立.

$$\begin{cases} \text{Pro}(\mathbf{h} | \mathbf{v}) = \prod_j \text{Pro}(h_j | v_j); \\ \text{Pro}(\mathbf{v} | \mathbf{h}) = \prod_i \text{Pro}(v_i | h_i). \end{cases} \quad (6)$$

由此可以得到任意隐含层单元 h_j 和 v_i 为 1 的概率为

$$\begin{cases} p(h_j = 1 | v) = [1 + \exp(-\sum_j W_{ij} v_i - a_j)]^{-1}; \\ p(v_i = 1 | h) = [1 + \exp(-\sum_j W_{ij} h_j - b_i)]^{-1}. \end{cases} \quad (7)$$

根据式(7)可以计算单个 RBM 中隐含层和可视层中神经元被激活的概率,此时,通过极大似然法求解模型参数 $\theta = \{\mathbf{W}, \mathbf{a}, \mathbf{b}\}$, 似然函数可以描述为

$$L(\theta | \mathbf{v}) = \prod_{\mathbf{v}} \text{Pro}(\mathbf{v}). \quad (8)$$

对式(8)求对数,然后求到的梯度为

$$\begin{cases} \frac{\partial \ln \text{pro}(v)}{\partial W_{ij}} = \text{pro}(h_j = 1 | v) v_i - \frac{1}{n} \sum_{j=1}^n \text{Pro}(h_j = 1 | v_j) v_{yi} \\ \frac{\partial \ln \text{pro}(v)}{\partial a_i} = \text{pro}(h_j = 1 | v) - \frac{1}{n} \sum_{j=1}^n \text{Pro}(h_j = 1 | v_j) \\ \frac{\partial \ln \text{pro}(v)}{\partial b_i} = v_i - \sum_v \text{Pro}(v) v_i - \frac{1}{n} \sum_{i=1}^n v_{yi} \end{cases} \quad (9)$$

根据式(9)可以对单个RBM进行权值和偏置参数的调整,迭代的算法可以描述为

Algorithm 1 单层RBM训练算法

Input: $\text{RBM}(v_1, \dots, v_m, h_1, \dots, h_n)$, 指纹图像样本集 \mathbf{S} ;

Output: 模型参数 \mathbf{W}, \mathbf{a} 和 \mathbf{b} .

Initialize: 模型参数 \mathbf{W}, \mathbf{a} 和 \mathbf{b} .

Step 1: 根据概率生成隐含层神经元的状态:将 v_1 输入到RBM中,得到每个隐含层神经元 $h_j (1 \leq j \leq n)$ 被激活的概率:

$$\text{pro}(h_{1j} = 1 | v_1) = \sigma(b_j + \sum_i v_{1i} w_{ij}). \quad (10)$$

式中: σ 通常为 sigmoid 激活函数.根据激活概率 $\text{pro}(h_{1j} = 1 | v_1)$ 来抽取 $h_{1j} \in \{0, 1\}$;

Step 2: 重构可视层状态:根据隐含层的输入值 $h_{1j} \in \{0, 1\}$, 得到重构的可视层激活概率:

$$p(v_{2i} = 1 | h_1) = \sigma(a_i + \sum_j w_{ij} h_{1j}). \quad (11)$$

根据 $p(v_{2i} = 1 | h_1)$ 对可视层神经元进行采样,从而抽取 $v_{2i} \in \{0, 1\}$;

Step 3: 重构隐含层状态:采用 $v_{2i} \in \{0, 1\}$ 输入重构的隐含层神经元,得到神经元激活的概率:

$$p(h_{2j} = 1 | v_2) = \sigma(b_j + \sum_i v_{2i} w_{ij}). \quad (12)$$

根据 $p(h_{2j} = 1 | v_2)$ 此时根据式(3)得到隐含层神经元的状态 $h_{2j} \in \{0, 1\}$;

Step 4: 估计参数 \mathbf{W}, \mathbf{a} 和 \mathbf{b} :

$$\begin{cases} \mathbf{W} \leftarrow \mathbf{W} + \varepsilon(p(h_{1\cdot} = 1 | v_1) \mathbf{v}_1^T - p(h_{2\cdot} = 1 | v_2) \mathbf{v}_2^T); \\ \mathbf{a} \leftarrow \mathbf{a} + \varepsilon(\mathbf{v}_1 - v_2); \\ \mathbf{b} \leftarrow \mathbf{b} + \varepsilon(p(h_{1\cdot} = 1 | v_1) - p(h_{2\cdot} = 1 | v_2)). \end{cases} \quad (13)$$

3.4 基于多层深度神经网络的指纹识别

算法1可以实现单个RBM的 \mathbf{W}, \mathbf{a} 和 \mathbf{b} 的学习,而多层深度神经网络是由多个单个RBM经过堆叠组成,如图7所示,经过多层的训练,可以得到自动提取的特征.

在图7所示的特征提取终端,再增加一个标签层,从而构成一个有输出的深度神经网络,并通过指纹数据的标签,通过反向传播算法对标签层与图7所示的特征提取层之间的权值和偏置进行调整,从而训练出具有识别能力的多层神经网络.

此时,只需要将预处理后的灰度指纹图像输入有标签的多层神经网络,根据输出层被激活的神经元来确定是否有匹配的指纹图像.

如果神经元激活概率大于0.5,则与该输出神经元对应的类别该指纹数据对应的类别.

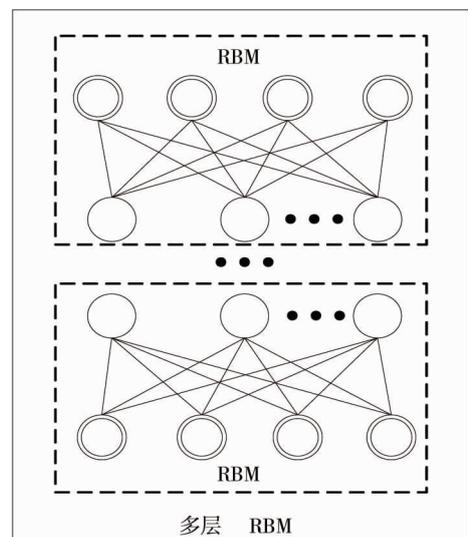


图7 多层RBM深度神经网络

4 系统测试

为了验证文中方法的有效性,根据图 3 所示的硬件系统框图,设计了硬件系统,然后通过指纹传感器采集 1 000 副原始图像构成指纹图像数据库,指纹图像的像素为 200×200 ,在此 1 000 副图像上增加均值为 1,方差为 5 的高斯噪声,使每副指纹图像生成 4 幅带噪声图像,则每幅图像均有 5 幅图,一共可以构成 5 000 幅指纹图像数据作为训练样本.

从 1 000 幅原始指纹图像中抽取 100 幅并加入均值为 2,方差为 6 的高斯噪声,每幅图像生成 5 幅图像,一共生成 400 副指纹图像数据组成测试样本,将测试样本集均分为 4 份为 D_1, D_2, D_3, D_4 .

建立深度神经网络,第一层为输入层,第二层为卷积层,第 3 到第 6 层为 3 层堆叠的 RBM,最后一层为输出层,输出层的标签数为 1 001,因此深度神经网络共 7 层.采用训练样本集输入到第一层中,采用算法 1 进行逐层训练,直到网络收敛,此时根据第 6 层输出的特征和第 7 层对应的激活标签,通过 BP 算法训练第 6 层与第 7 层之间的权值.

当网络训练完毕后,就将指纹测试数据集 D_1, D_2, D_3, D_4 输入训练好的多层的深层神经网络,得到的识别结果如表 1 所示.

表 1 指纹匹配结果

| 方法名称 | $D_1/\%$ | $D_2/\%$ | $D_3/\%$ | $D_4/\%$ |
|------|----------|----------|----------|----------|
| FRR | 0.18 | 1.57 | 0.26 | 1.24 |
| FAR | 0.22 | 0.14 | 0.36 | 0.51 |
| GAR | 99.6 | 98.39 | 99.48 | 98.25 |

在表 1 中, FRR (False Reject Rate) 为错误拒绝率, FAR (False Accept Rate) 为错误接受率, GAR (Genuine Accept Rate) 为正确识别率, FRR 表示为原本为同一指纹的图像匹配到不同指纹的概率. FAR 表示原本不属于同一指纹的图像匹配为相同指纹的概率. GAR 表示原本为同一指纹的图像匹配到相同指纹的概率,由表 1 可以看出,文中方法的平均错误拒绝率 FRR 和错误接受率 FAR 分别仅为 0.307 5% 和 0.812 5%,而正确识别率 GAR 则高达 98.93%.

为了验证本文方法识别效率和识别率的优越性,将本文方法分别与文献[8]的多特征融合方法和文献[9]中基于 Delaunay 网格的前期工作进行比较,3 种方法得到的指纹识别正确率随着识别时间变化的情况如图 8 所示.

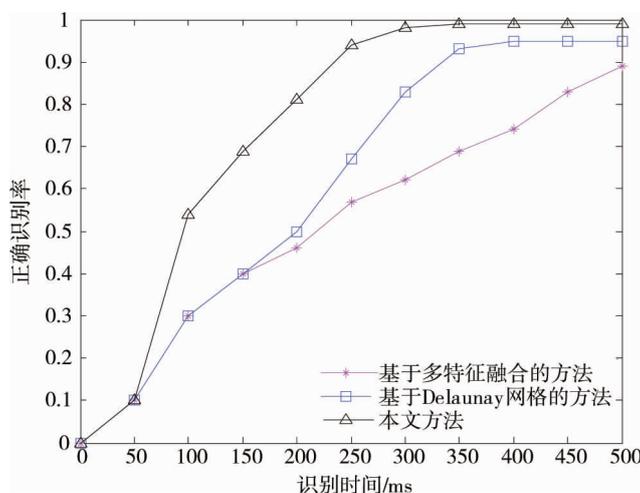


图 8 正确识别率随识别时间比较

从图 8 可以看出,文中方法在仿真时间为 350 ms 时,所得到的正确识别率就已经收敛,最终得到的正确率为 98.93%,基于多种特征融合的方法在识别时间达到 500 ms 时仍未能收敛,在 500 ms 时的正确识别

率也仅为 89%,而基于 Delaunay 网格的方法虽然能在仿真时间为 400 ms 时收敛,但最终达到的正确识别率仅为 95%,仍不如文中方法.

5 结论

为了实现指纹大数据的有效识别,提出了一种基于 ARM 和深度学习的指纹识别系统.该系统采用指纹数据库作为训练数据,得到的平均错误拒绝率和错误接受率仅为 0.307 5%和 0.812 5%,同时文中方法的收敛速度最快,在仿真时间为 350ms 时,正确识别率就已经达到 98.93%,因此,具有更高的指纹识别效率.本文提出的指纹识别系统是一种多层深度网络模型,神经网络的层数为 6,需要 GPU 的支持才能进行网络的训练.为了进一步提高训练的效率和模型的通用性,下一步的工作是通过更好利用并行化的结构来在 CPU 上训练模型,解除对 GPU 的依赖.

参考文献:

- [1] Maltoni D, Maio D, Jain A K, et al. Handbook of fingerprint recognition [M]. New York: Springer Verlag, 2003:1-9.
- [2] 钦小平, 潘炼. 基于 ARM 的 QNMV 指纹识别系统的研究[J]. 计算机测量与控制, 2012, 20(4): 1076-1078.
- [3] Fons M, Fons F, Canto E. Design of an embedded fingerprint matcher system [C]//St. Petersburg: IEEE Tenth International Symposium on Consumer Electronics, 2006:1-6.
- [4] 傅磊, 史延东, 李飞, 等. 一种新型指纹识别系统的设计与实现 [J]. 电子技术应用, 2010(2): 16-18.
- [5] Fu Q, Mansjur D S, Juang B H. Empirical system learning for statistics pattern recognition with non-uniform error criteria [J]. Signal Processing, 2010, 58(9): 4621-4633.
- [6] 孙萍. 基于 AT89S52 的指纹识别系统的设计[J]. 电气应用, 2010, 29(9): 74-80.
- [7] 陈书谦, 傅扬烈. 改进的指纹识别算法嵌入式应用研究 [J]. 微电子学与计算机, 2012(10): 181-184.
- [8] 韩智, 刘昌平. 基于多种特征融合的指纹识别方法[J]. 计算机科学, 2010, 37(7): 254-259.
- [9] 许沪敏, 杨森, 朱涛. 基于 Delaunay 网格和 DLP 的三维指纹识别系统设计[J]. 计算机测量与控制, 2014, 22(10): 3429-3432.
- [10] Deng L, Yu D. Deep learning for signal and information processing[J]. Microsoft Research monograph, 2013.
- [11] Bengio Y, Courville A. Deep learning of representations [M]. Handbook on Neural Information Processing. Springer Berlin Heidelberg, 2013.
- [12] 杨钊, 陶大鹏, 张树业, 等. 大数据下的基于深度神经网络的相似汉字识别[J]. 通信学报, 2014, 35(9): 184-189.
- [13] 张玉清, 董颖, 柳彩云, 等. 深度学习应用于网络空间安全的现状、趋势与展望[J]. 计算机研究与发展, 2018, 55(6): 1117-1142.
- [14] 林付春, 刘宇红, 张达峰, 等. 基于深度学习的智能路牌识别系统设计[J]. 电子技术应用, 2018, 480(6): 74-77.