

# 双树复小波变换结合 LM 神经网络的掌纹识别方案<sup>①</sup>

卜宇<sup>1</sup>, 刘俊霞<sup>2</sup>, 唐学军<sup>1</sup>

<sup>1</sup>(新疆工程学院 计算机工程系, 乌鲁木齐 830052)

<sup>2</sup>(新疆工程学院 电气与信息工程系, 乌鲁木齐 830023)

**摘要:** 针对现有掌纹识别方案不能够很好的提取多分辨率特征的问题, 提出一种基于双树复小波变换(DT-CWT)和 Levenberg-Marquardt(LM)神经网络的掌纹识别方案. 首先, 将彩色手掌图像转换成灰度图像. 然后, 提取出手掌图像中的感兴趣区域(ROI), 并构建成直方图. 接着, 利用 DT-CWT 进行 6 层小波分解并获得特征系数, 分别计算特征系数的最大值、平均值和中值构建 36 维特征向量. 最后, 利用 LM 神经网络根据特征向量实现掌纹的识别分类. 在 CASIA 数据库上的实验结果表明, 相比其他几种较新的识别方案, 提出的方案的具有更高的识别率和更少的识别时间.

**关键词:** 掌纹识别; 双树复小波变换; 特征提取; LM 神经网络; 感兴趣区域(ROI)

## Palmprint Recognition Scheme Based on DT-CWT and LM Neural Network

BU Yu<sup>1</sup>, LIU Jun-Xia<sup>2</sup>, TANG Xue-Jun<sup>1</sup>

<sup>1</sup>(Department of Computer Engineering, Xinjiang Institute of Engineering, Urumchi 830052, China)

<sup>2</sup>(Department of Electrical and Information, Xinjiang Institute of Engineering, Urumqi 830023, China)

**Abstract:** For the issues that the existing solutions for palmprint identification can't be very good to extract multi-resolution characteristic, this paper proposed a palmprint recognition scheme based on dual-tree complex wavelet transform (DT-CWT) and Levenberg-Marquardt (LM) neural network. Firstly, it convertsthe color image into gray image. Then, the region of interest (ROI) is extracted from the palm image, and constructed a histogram. Then, this scheme uses DT-CWT for 6 layers of wavelet decomposition and obtains the characteristic coefficients, and calculatesthe maximum value, average value and median value of the characteristic coefficients respectively. Finally, it uses LM neural network to make recognition and classification of palmprint. Experimental results on CASIA database show that the recognition rate of the proposed scheme has high recognition rate and lower recognition time.

**Key words:** palmprint recognition; dual-tree complex wavelet transform; feature extraction; LM neural network; region of interest

生物识别技术是基于固有生理特征(如指纹、脸、手、虹膜、视网膜、等)或行为特征(如声音、步态、签名动力学等)的自动识别个体的方法<sup>[1]</sup>. 近年来, 基于掌纹的生物识别得到了越来越多的关注, 相比其他可用生物特征, 掌纹识别可以在较低分辨率下提取主线和褶皱等有效识别掌纹的特征, 且采集设备简单、可接受性和普适性强<sup>[2]</sup>. 因此, 掌纹识别具有更广阔的应用前景.

在掌纹识别中, 特征提取至关重要. 目前学者提出了多种掌纹特征提取的方法, 例如, 文献[3]提出一种利用 Sobel 算子来提取掌纹线特征, 如主线、单向皱纹和褶皱, 然后利用神经网络进行识别. 文献[4]使用 Contourlet 变换提取多分辨率点特征, 采用时间-频率联合表示数据.

小波变换(Wavelet Transform, WT)是对信号进行处理的有力工具, 已经在很多领域取得了较好的效

① 基金项目:新疆维吾尔自治区高校科研计划青年教师科研启动基金(XJEDU2014S074)

收稿时间:2016-01-07;收到修改稿时间:2016-03-03 [doi:10.15888/j.cnki.csa.005355]

果<sup>[5]</sup>。同时小波分析也是一种对多分辨率图像进行分析的有效方法,已经应用到掌纹的特征提取中。例如,文献[6]使用三种小波变换:双正交小波、symlet 小波和离散小波,同时计算出每一块小波系数,并将这三种小波的特征进行组合。通过计算输入特征矢量和模板特征之间的欧氏距离来完成掌纹识别。文献[7]使用含有多贝西小波的二级小波变换来分解图像,然后从一系列小波系数中计算出小波特征和小波变异特征作为两个定量特征。然而,这些方法不能够获得较好的多分辨率和多方向性特征。

现有基于小波变换的掌纹特征提取方法大都是基于离散小波变换(Discrete Wavelet Transform, DWT)<sup>[8]</sup>。但 DWT 具有平移变动性等缺点,所以基于 DWT 方法提取的掌纹特征会影响识别效果<sup>[9]</sup>。另外,二维 DWT 也只能提取掌纹在水平、垂直和对角方向的纹理特征,不能提取+45°和-45°方向的特征,因此二维 DWT 的方向选择性较差<sup>[10]</sup>。目前, DWT 有一种新的变体,称为双树复小波变换(Dual-Tree Complex Wavelet Transform, DT-CWT)<sup>[11]</sup>。DT-CWT 算法是一种更强健的信号处理算法,相比于 DWT 算法具有平移不变性,并在多维度中具有方向敏感性特性。另外,对于掌纹的特征分类,常用的是反向传播神经网络(BPNN)算法,其中基于 Levenberg-Marquardt(LM)<sup>[12]</sup>算法的 BP 神经网络收敛速度快且鲁棒性好。

为此,本文提出一种基于 DT-CWT 和 LM 神经网络的掌纹识别方案。首先,将手掌图像转换成灰度图像,提取出手掌图像中掌纹区域,即感兴趣区域(Region of Interest, ROI),并将 ROI 构建成直方图。然后,利用双树复小波变换(DT-CWT)提取 6 层特征系数,分别计算出特征系数的最大值、平均值和中值作为特征向量。最后,将特征向量输入到 LM 神经网络中,最终实现掌纹的识别分类。在 CASIA 数据库上的实验结果表明,本文方案在保持较低识别时间的同时,获得了较高的识别率。

## 1 基于DT-CWT的特征提取

### 1.1 双树复小波变换

双树复小波变换(DT-CWT)是一种改进的离散小波变换(DWT)。在 DWT 中,任何限定的能源模拟信号  $x(t)$  都可以由带通小波  $\alpha(t)$ 、尺度函数  $\beta(t)$ 、相关的尺度系数  $c(n)$  和小波系数  $d(j, n)$  表示:

$$x(t) = \sum_{n=-\infty}^{\infty} c(n)\beta(t-n) + \sum_{j=0}^{\infty} \sum_{n=-\infty}^{\infty} d(j, n)2^p\alpha(2^j t - n); p = j / 2 \quad (1)$$

$$c(n) = \int_{-\infty}^{\infty} x(t)\beta(t-n)dt \quad (2)$$

$$d(j, n) = 2^p \int_{-\infty}^{\infty} x(t)\alpha(2^j t - n)dt \quad (3)$$

在上式中的时间—频率分析中,  $j$  代表尺度因子、 $n$  代表时间变化。

然而传统 DWT 存在 4 个主要问题<sup>[13]</sup>: 1)奇异点周边的正负振幅; 2)微小的信号变化会引起小波系数的很大变化,从而导致能量容量的大变化; 3)大量的混淆现象; 4)在高维度方向选择性的缺失。根据傅里叶变换的某些性质,可使用一种复尺度函数和复小波构建一种复小波变换来克服上述问题。

$$\alpha_c(t) = \alpha_r(t) + i\alpha_g(t) \quad (4)$$

$$\beta_c(t) = \beta_r(t) + i\beta_g(t) \quad (5)$$

上式中,  $\alpha_r(t)$  为实数且为偶数,  $i\alpha_g(t)$  为虚数且为奇数,它们形成一个希尔伯特变换对。那么该复小波系数可以表示为:

$$d_c(j, n) = d_r(j, n) + id_v(j, n) \quad (6)$$

其中大小和相位如下:

$$|d_c(j, n)| = \sqrt{|d_r(j, n)|^2 + |d_v(j, n)|^2} \quad (7)$$

$$\angle d_c(j, n) = \arctan\left(\frac{d_v(j, n)}{d_r(j, n)}\right) \quad (8)$$

在复小波变换中,双树方法使用了两个独立的标准正交基  $\alpha_r(t)$  和  $i\alpha_g(t)$ , 即两个独立的实数 DWTs。第一个 DWT 给出了小波变换中实数部分,第二个 DWT 计算出虚数部分。两个实数小波变换使用两套不同的滤波器。图 1 显示了对用于转换的滤波器组(FB)结构,该转换中使用两种 DWTs 为给定的信号  $x(t)$  创造小波系数。

在图 1 中,  $p_0(n)$  和  $p_1(n)$  分别代表一对左 FBs 的低通和高通滤波器,  $q_0(n)$  和  $q_1(n)$  分别代表一对右 FBs 的低通和高通滤波器。如果使用平方矩阵  $D_p$  和  $D_q$  来表示实数 DWTs, 那么可以使用矩形矩阵  $D$  来表示 DT-CWT。

$$D = \begin{bmatrix} D_p \\ D_q \end{bmatrix} \quad (9)$$

如果将一个实数信号表示为向量  $X$ , 那么给出的 DT-CWT 的实数部分为  $d_p = D_p X$ , 因此综合系数可以表示为:  $d_p + id_p$ 。矩阵  $D$  的属性可显著表示如下:

$$D^{-1}D = I \quad (10)$$

那么,

$$\mathbf{D}^{-1} = 0.5 [\mathbf{D}_p^{-1} \quad \mathbf{D}_q^{-1}] \quad (11)$$

综合系数表示如下:

$$\mathbf{D}_c = 0.5 \begin{bmatrix} I & iI \\ I & iI \end{bmatrix} \begin{bmatrix} \mathbf{D}_p \\ \mathbf{D}_q \end{bmatrix} \quad (12)$$

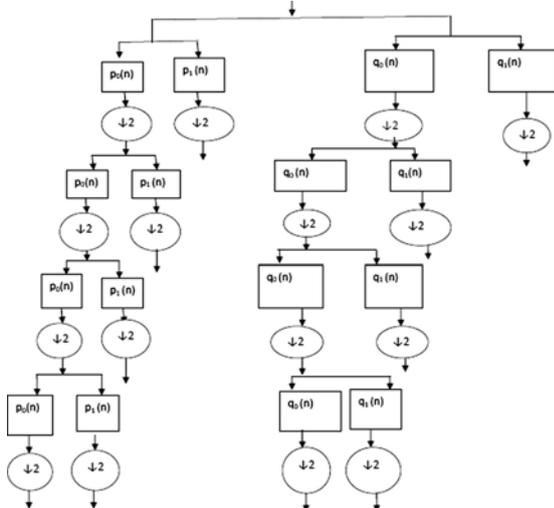


图 1 双树复小波函数的滤波器结构

为了得到一个实数  $M$  点信号, 公式(12)给出了  $2M$  复合系数, 但是这些系数的一半是另一半的复共轭系数. 这是因为使用两种实数 DWTs 来实施 DT-CWT. 然而需要设计新的滤波器, 使相应的小波形成一种近似分析对, 同时也是彼此的希尔伯特变换. 如果一个低通滤波器中样品转换是其他低通滤波器的一半, 那么上述设想就可以实现, 其他低通滤波器也按照 2:1 的比例采集低通信号, 从而通过减少样品来缓解混乱现象. 这在数学上可表示为:

$$q_0(n) \approx p_0(n - 0.5) \quad (13)$$

$$|Q_0(e^{j\omega})| = |P_0(e^{j\omega})| \quad (14)$$

$$\angle Q_0(e^{j\omega}) = \angle P_0(e^{j\omega}) - 0.5\omega \quad (15)$$

因此, 本文设计的 DT-CWT 滤波器拥有下述特性:

- 1) 近似一半的样品延迟;
- 2) 完美的重建能力(正交或双正交);
- 3) 有限支撑(FIR 滤波器);
- 4) 具有良好的阻带和线性相位滤波器.

### 1.2 预处理

掌纹图像的主要有三个重要特征, 即主线、较小的纹或褶皱和类似于指纹的脊, 当脊与背景皮肤相结合时可形成特定的纹理.

在特征提取之前, 首先需要对图像进行预处理,

即将彩色图像转换为相应的灰度图像, 在保留掌纹特征的同时减少后续数据处理的计算量. 利用下式实现红绿蓝(RGB)值到灰度值的转换:

$$I = 0.2989 \times R + 0.5870 \times G + 0.1140 \times B \quad (16)$$

在本文的系统中, 志愿者需要通过其将右手放于扫描仪的平板玻璃表面上进行扫描, 获得其右手掌的彩色图像. 由于获得的手掌图像较大, 所以先将每个灰度图像调整像素大小为  $1024 \times 1024$ , 使其刚好包含整个手掌, 作为数据集. 另外, 对于掌纹识别, 只有掌纹区域即感兴趣区域(ROI)是有价值的. 对于本文中  $1024 \times 1024$  大小的手掌图像, ROI 像素大小约为  $225 \times 225$ . 所以, 在每个手掌图像的中心提取像素大小为  $225 \times 225$  的 ROI. 然后, 为每一个提取的感兴趣区域构造直方图, 用于后续的特征提取.

图 2 显示了五个人的掌纹图像以及预处理结果, 其中, 图 2(a)为原始手掌图像, 图 2(b)为转换彩色图像获得的灰度图像, 图 2(c)为感兴趣区域, 图 2(d)为感兴趣区域的直方图.

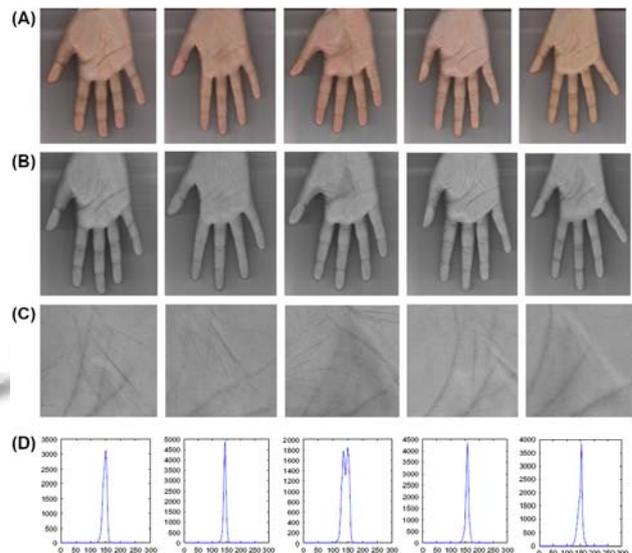


图 2 五个手掌图像的预处理过程, (A)原始手掌图像, (B)灰度手掌图像, (C)提取的感兴趣区域, (D)感兴趣区域的直方图.

### 1.3 特征提取

DT-CWT 系数的正确选择是一个需要慎重考虑的问题, 该系数需要适合于训练每个神经网络识别器, 因此选择合适的用于分解信号生成 DT-CWT 系数的信号分解层数和每层的系数是重要的.

首先, 对每一个图像直方图应用 DT-CWT 到 6 个

层,并计算出每层复小波系数的实数和虚数部分的最大值、平均值和中值.然后,形成三组大小为 12-by-1 的特征向量.这 12 个特征代表了 6 层中复系数的实数和虚数部分.每个手掌图像的特征向量为:

$$\begin{aligned}
 & Palmimage\_hist\_feature[l] \\
 & = [rep\_real\_coeff\_1, rep\_img\_coeff\_1, rep\_real\_coeff\_j, \\
 & \quad drep\_img\_coeff\_j, \dots, rep\_real\_coeff\_J, rep\_img\_coeff\_J]^T
 \end{aligned}
 \tag{17}$$

其中  $rep\_real\_coeff\_j$  表示第  $j$  层的实数小波系数,  $rep\_img\_coeff\_j$  表示第  $j$  层的虚数小波系数,  $j$  为进行分解的总层次数(最初,  $j = 6$ ).创建三个这种特征集,以各层中系数的最大值、平均值和中值来表示小波系数.因此,对于第  $l$  个手掌图像,可产生三个特征向量,表示如下:

$$\begin{aligned}
 & Palmimage\_hist\_feature[l] \\
 & = [max\_real\_coeff\_1, max\_img\_coeff\_1, \dots, max\_real\_coeff\_j, \\
 & \quad max\_img\_coeff\_j, \dots, max\_real\_coeff\_J, max\_img\_coeff\_J]^T
 \end{aligned}
 \tag{18}$$

$$\begin{aligned}
 & Palmimage\_hist\_feature[l] \\
 & = [mean\_real\_coeff\_1, mean\_img\_coeff\_1, \dots, mean\_real\_coeff\_j, \\
 & \quad mean\_img\_coeff\_j, \dots, mean\_real\_coeff\_J, mean\_img\_coeff\_J]^T
 \end{aligned}
 \tag{19}$$

$$\begin{aligned}
 & Palmimage\_hist\_feature[l] \\
 & = [median\_real\_coeff\_1, median\_img\_coeff\_1, \dots, median\_real\_coeff\_j, \\
 & \quad median\_img\_coeff\_j, \dots, median\_real\_coeff\_J, median\_img\_coeff\_J]^T
 \end{aligned}
 \tag{20}$$

图 3 显示了对于图 2 中的第 1 和第 4 个直方图,基于 DT-CWT 提取的掌纹小波系数(1-6 层)的实数和虚数特征.从图 3 可以看出,对于不同的人,每一层的系数都有较大的区别.

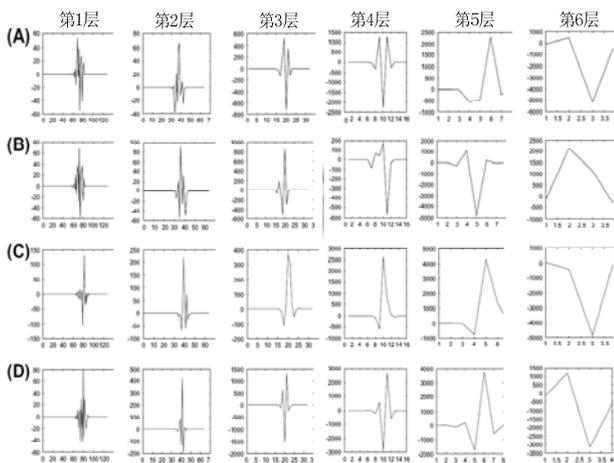


图 3 基于 DT-CWT 的特征提取. (a)手掌 1 的小波系数(1-6 层)的实数部分, (b)手掌 1 的小波系数(1-6 层)的虚数部分, (c)手掌 4 的小波系数(1-6 层)的实数部分, (d)手掌 4 的小波系数(1-6 层)的虚数部分.

## 2 基于LM神经网络的掌纹分类

反向传播(BP)算法是多层神经网络中使用最广泛的监督学习方法,由于其可以执行多维映射使其具有复杂模式分类的能力<sup>[14]</sup>.BP神经网络属于多层前向神经网络,其模型如图 4 所示.图 2 所示为一个三层结构的 BP 神经网络模型,包括输入层、隐含层和输出层.相邻两层的各个神经元通过一个传递函数彼此相连,传递函数对应产生一个连接权值.

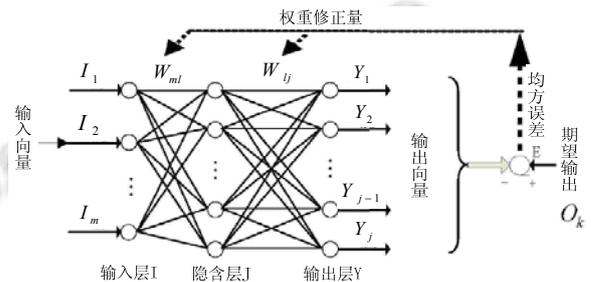


图 4 传统 BP 神经网络模型

标准的 BP 算法是基于梯度下降法,即误差单调减小,因此这种算法极易引起局部最优,当接近极值时,收敛速度就非常慢.为此,许多学者基于标准数值优化对传统 BP 算法进行了改进,如共轭梯度算法、高斯-牛顿算法、Levenberg-Marquardt(LM)算法等.其中 LM 算法收敛速度最快、鲁棒性最好,其既具有高斯-牛顿法的局部特性又具有梯度法的全局特性,其利用了近似的二阶导数信息,根据迭代结果动态地调整迭代的收敛方向,使每次的迭代误差都有所下降,因此比梯度法收敛速度快,并且算法稳定<sup>[15]</sup>.因此,本文利用 LM 反向传播神经网络(LM-NN)来构建分类器.

本文开发一个 C-个人掌纹识别系统,其中每一个分类器  $C(C = 1, 2, 3, \dots, C)$  用于确定识别信号是否属于个人 C.对于每个识别模块的二元分类问题,都可以表示如下,  $\psi = \{(y_1, f_1), (y_2, f_2), \dots, (y_G, f_G)\}$  且  $y_i \in R^s, f_i \in \{+1, -1\}$ .其中,  $y_i$  表示输入特征,  $f_i$  表示分类输出,  $s$  为特征矢量的维度,  $G$  为训练样本的数量.

LM 算法是前馈神经网络中最快速的算法之一,其成本函数是通过在给定时间点上( $k$ )所有训练数据集中的样品( $G$ )的平方差的总和来表示.LM 算法通过下式计算权重升级:

$$\mathbf{W}_{k+1} = \mathbf{W}_k - [\mathbf{H} + \mu \mathbf{I}]^{-1} \mathbf{g} \tag{21}$$

上式中  $\mathbf{W}_k$  为在第  $k$  时间点上的权向量,  $\mathbf{H}$  为

Hessian 矩阵,  $\eta$  为学习率,  $\mathbf{g}$  为梯度向量. 这里, Hessian 矩阵  $\mathbf{H}$  和梯度向量  $\mathbf{g}$  可以近似为:

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} \quad (22)$$

$$\mathbf{g} = \mathbf{J}^T \mathbf{e} \quad (23)$$

上式中,  $\mathbf{J}$  为包含了神经网络误差的一阶导数的雅可比矩阵,  $\mathbf{e}$  为神经网络误差的矢量, 用来确保 Hessian 矩阵不需要明确计算. 因此, LM 算法无需计算 Hessian 矩阵就可以处理二阶训练速度.

### 3 实验及分析

#### 3.1 不同特征集的性能分析

实验中采用了两种数据集: 中科院自动化研究所的 CASIA 掌纹图像数据库和香港理工大学的 PolyU 数据库. CASIA 数据库包含了采集自 301 个人的 5239 幅手掌图像, 所有图像为  $480 \times 640$  像素的 256 级灰度图像, 且均是基于 CCD 的采集设备采集得到. PolyU 数据库为一个高清数据库, 其掌纹图像像素大小为  $1280 \times 1024$ . CASIA 数据库中由于该掌纹库的掌纹采集设备简单, 采集的图像是否包含腕部、手指张开程度以及放置位置随意性都比较大, 具有一定的自由度, 故掌纹图像预处理的难度远比使用 PolyU 数据库时要大, 图 5 列出了 6 张典型的掌纹图像. 本文实验利用 MATLAB7, 在酷睿 i5-2.0GHz 的 CPU, 2G 内存, 软件环境为 Windows 7 的计算机平台上实现.

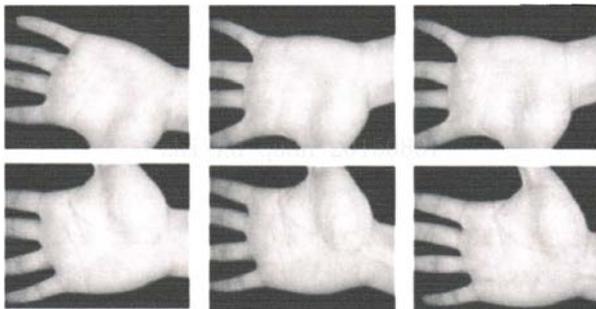


图 5 CASIA 数据库中掌纹图像

从 CASIA 数据库中随机选择 50 个人的手掌图像作为数据集并分为两部分, 一部分用于训练神经网络识别器, 另一部分用于测试其性能. 将本文提取的 3 个特征向量进行不同的组合, 并测试利用这些特征组合的效果. 表 1 显示了当使用不同特征矢量组合时, LM 神经网络识别器的性能. 可以看出, 当利用三个特征向量组合时, 识别精度最高, 达到了 98.3%.

表 1 使用六层 DT-CWT 提取的不同特征的识别性能

序号	使用的特征	特征数	平均识别率(%)	标准偏差(%)
1	最大值	12	98.01	0.88
2	平均值	12	97.65	0.95
3	中位数	12	96.70	1.31
4	最大值和平均值	24	97.94	0.97
5	最大值和中值	24	97.60	0.93
6	平均值和中值	24	97.52	1.05
7	最大值、平均值和中值	36	98.33	0.83

#### 3.2 性能比较

在生物识别系统中, 通常以错误接受率(FAR)和错误拒绝率(FRR)来表示每个系统的识别性能. 系统的 FAR 通常被定义为错误接受次数与识别次数之间的比例, 用来衡量系统错误地接受一个未经授权用户的访问. FRR 通常定义为错误拒绝次数与识别次数之间的比例, 用来衡量系统错误地拒绝一个授权用户的访问.

首先, 进行不同小波变换方法之间的比较, 将本文 1 维 DT-CWT 提取的特征和利用 1 维 DWT 和 2 维 DWT 所提取的特征进行比较, 其中, DWT 没有进行生成图像直方图的预处理过程, 其使用 Daubechies 小波将图像分解为四层, 并计算每层的水平、垂直和细节系数. 然后计算系数的平均值、最大值和中值, 并组成 36 维特征矢量, 作为神经网络的输入特征. 表 2 给出了基于 DT-CWT 和 DWT 特征提取的识别结果, 可以看出, 本文 DT-CWT 获得了较高的识别精度和较低 FAR、FRR. 这证明, 本文采用的 DT-CWT 所提取的特征更能够表征不同掌纹之间的差异性.

表 2 基于小波变换特征提取的识别性能比较

序号	特征提取方案	平均识别率(%)	FAR%	FRR%
1	2D DWT	97.15	2.74	6.62
2	1D DWT	98.02	2.21	5.27
3	1D DT-CWT	98.35	1.98	3.45

接下来, 将本文方案与现有几个先进的基于掌纹的识别系统进行比较, 分别为文献[3]提出的基于 Sobel 算子提取特征的识别方法、文献[4]提出的基于 Contourlet 变换的识别方法、文献[6]提出的基于三种小波特征组合的识别方法和文献[7]提出的基于多贝西小波特征提取的识别方法.

随机选择 50 个人的手掌图像作为数据集, 每个人都有 10 张右手手掌图像, 其中 5 张用于训练神经网络识别器, 剩余 5 张用来测试识别的精确度. 进行 5 次实验, 取识别率的平均值作为实验结果, 计算每张图片的识别时间, 结果如表 3 所示.

表3 不同方法在 CASIA 数据集上的掌纹识别性能比较

方法	平均识别率(%)	识别时间(s)	FAR%	FRR%
文献[3]	93.49	0.84	3.84	6.31
文献[4]	91.52	1.06	4.17	8.52
文献[6]	96.28	0.64	3.06	5.25
文献[7]	97.95	0.48	2.78	4.46
本文方案	98.29	0.43	2.01	3.82

从表 3 可以看出, 本文方案获得了最优的性能, 平均识别率达到了 98.29%, 且具有较低的 FAR 和 FRR. 同时, 本文方案获得了最低的识别时间. 这是因为本文 DT-CWT 提取的特征具有多分辨率和多方向性, 而且本文没有之间将特征系数作为特征集, 而是计算 6 层系数的最大值、平均值和中值, 在保持有效性的同时, 大大减少了特征维度.

为了验证本文方法对于高分辨率手掌图像的识别效果, 在香港理工大学的 PolyU 掌纹图像库上进行实验. 由于现有方案中只有文献[7]能够处理高分辨率的图像, 所以将本文方案和其进行了比较, 结果如表 4 所示. 可以看出, 对于高清图像, 各种方案的识别率都有所降低, 这是因为将高清图像转换成规格图像, 一定程度上影响了图像的清晰度. 不过, 本文方案总体上达到了 95.38% 的识别率, 高于文献[7]方案.

表4 不同方法在 PolyU 数据集上的掌纹识别性能比较

方法	平均识别率(%)	识别时间(s)	FAR%	FRR%
文献[7]	92.46	0.83	4.52	5.64
本文方案	95.38	0.61	3.09	4.35

#### 4 结论

本文针对掌纹图像识别提出了一中新颖的方法, 包括三个阶段: 首先, 对图像进行预处理, 确定 ROI 位置并获得其直方图; 然后, 利用 DT-CWT 提取 36 维特征; 最后, 将特征向量输入到 LM 神经网络分类器, 对掌纹进行识别. 与其他小波变换提取特征相比, 提出的方案利用最大值、平均值和中值特征组合时, 其识别精度高达 98.3%, 这说明了 DT-CWT 的优越性. 在 CASIA 数据库中与现有 4 种方法的实验比较结果表明, 提出的方案在精确度、稳定性和时间效率方面具有更好的性能, 在该数据库中可获得高达 93% 的平均识别精确度.

在今后工作中, 考虑将本文方案应用到实际掌纹识别应用中, 由于实际环境中摄像机拍摄的掌纹图像的光线和背景较为复杂, 这对形成直方图以及提取的 DT-CWT 系数有一定影响. 所以, 需对本文方法进一步改进, 使其能够对背景变化具有鲁棒性, 提高其适

用范围.

#### 参考文献

- 苑玮琦, 范永刚, 柯丽. 相位一致性和对数 Gabor 滤波器相结合的掌纹识别方法. 光学学报, 2010, 31(1): 147-152.
- 李春燕, 卢光明, 黎伟. 基于曲面曲率和 RLDA 的 3D 掌纹识别方法. 中国图象图形学报, 2011, 16(5): 807-812.
- Wong KYE, Chekima A, Dargham JA, et al. Palmprint identification using sobel operator. 10th International Conference on Automation, Robotics and Vision. IEEE. 2009. 1338-1341.
- Vijilious MAL, Bharathi VS. Palmprint recognition using contourlet transform energy features. Indian Journal of Computer Science & Engineering, 2011, 2(6): 158-167.
- 刘玉芹, 苑玮琦, 郭金玉. 基于小波分解和高低帽变换的在线掌纹识别. 计算机应用研究, 2011, 28(6): 2355-2357.
- Udayakumar R, Khanaa V. Improved palmprint authentication using contactless imaging. Middle East Journal of Scientific Research, 2013, 25(5): 1-6.
- Daugman J. Iris encoding and recognition using gabor wavelets. Encyclopedia of Biometrics, 2015, 32(8): 787-797.
- 李春芝, 陈晓华, 蒋云良, 等. 基于掌纹、人脸关联特征的身份识别算法. 电路与系统学报, 2010, 15(3): 86-90.
- 王连加. 基于 PCA-LBP 特征的掌纹识别研究. 计算机仿真, 2011, 27(11): 254-257.
- Liu YQ, Yuan WQ, Guo JY. On-line palmprint recognition based on wavelet decomposition and high and low hat transform. Application Research of Computers, 2011, 28(6): 2355-2357.
- Chakraborty S, Chatterjee A, Goswami SK. A dual-tree complex wavelet transform-based approach for recognition of power system transients. Expert Systems, 2015, 32(9): 132-140.
- 张峤, 邓贵仕. Levenberg-Marquardt 神经网络在煤矿作业人员人因可靠性评价中应用研究. 大连理工大学学报, 2015, 55(4): 424-430.
- 杨凯峰, 牟莉, 许亮. 基于离散小波变换和 RBF 神经网络的说话人识别. 西安理工大学学报, 2011, 27(3): 368-372.
- Ibrahimy MI, Ahsan MR, Khalifa OO. Design and optimization of levenberg-marquardt based neural network classifier for EMG signals to identify hand motions. Measurement Science Review, 2013, 13(3): 142-151.
- Rodriguez-Quinonez JC, Sergiyenko O, Gonzalez-Navarro F F, et al. Surface recognition improvement in 3D medical laser scanner using Levenberg-Marquardt method. Signal Processing, 2013, 93(2): 378-38.