



(12)发明专利

(10)授权公告号 CN 104102913 B

(45)授权公告日 2018.10.16

(21)申请号 201410337530.5

G06F 21/32(2013.01)

(22)申请日 2014.07.15

(56)对比文件

(65)同一申请的已公布的文献号

CN 101002682 A, 2007.07.25,

申请公布号 CN 104102913 A

CN 101093539 A, 2007.12.26,

(43)申请公布日 2014.10.15

CN 103646255 A, 2014.03.19,

(73)专利权人 无锡优辰电子信息科技有限公司

KR 20010000618 A, 2001.01.05,

地址 214043 江苏省无锡市北塘区兴源北路401号北创科技创业园712室

袁智.“手指静脉识别技术研究”.《中国优秀硕士学位论文全文数据库 信息科技辑》.2007,

(72)发明人 瞿博阳 梁静 李冀 岳彩通
肖岩 尚志刚

焦焰斌.“基于图像隐式语义分析与极限学习机的多生物特征识别”.《中国优秀硕士学位论文全文数据库 信息科技辑》.2013,

(74)专利代理机构 南京正联知识产权代理有限公司 32243

Shan Juan Xie等.“Feature Component-Based Extreme Learning Machines for Finger Vein Recognition”.《Cognitive Computation》.2014, 第6卷(第3期),

代理人 胡定华

审查员 熊晶

(51)Int.Cl.

权利要求书2页 说明书15页 附图6页

G06K 9/60(2006.01)

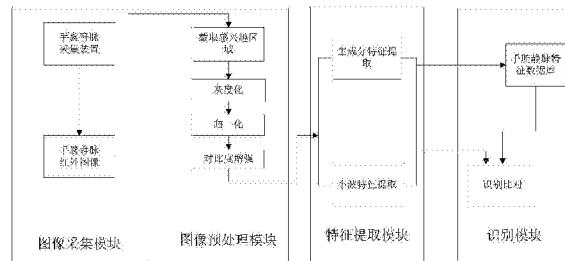
G06K 9/62(2006.01)

(54)发明名称

腕部静脉认证系统

(57)摘要

本发明提供一种腕部静脉认证系统，其特征在于包括图像采集模块、图像预处理模块、特征提取模块、识别模块；通过对采集图像预处理后，得到清晰特征明显的图像；通过分析多种图像特征提取方法，结合实际情况选用了主成分分析和小波分析进行图像特征提取；采用极限学习机对图像进行分类，经过多次试验结果对比，选择最佳参数，使识别率达到了95%以上。该系统，用图像信息的主成分与高频低频特征进行识别，具有操作简单，鲁棒性强的优点。



1. 一种腕部静脉认证系统,其特征在于:包括图像采集模块、图像预处理模块、特征提取模块、识别模块;

图像采集模块,通过手腕静脉采集装置采集手腕静脉红外图像;

图像预处理模块,对采集的手腕静脉红外图像截取感兴趣区域后,对该区域采用均值滤波方法进行滤波处理,进行灰度化、归一化,并采用直方图拉伸的方法进行对比度增强处理;对采集图像截取感兴趣区域,具体为:截取待处理图像:去除掉原始图像的背景,记下手腕静脉与背景交界点的坐标,然后截取交界以内的区域作为待处理图片;待处理图像上截取训练和测试的图像块:待处理图象上随机取一点作为中心,以为边长截取一个图像块作为训练和识别的样本;

特征提取模块,对预处理后的图像进行主成分特征提取、小波特征提取;主成分分析步骤为:

S1、对原始数据进行标准化处理;

S2、计算样本相关系数矩阵;

S3、用雅克比方法求相关系数矩阵的特征值和相应的特征向量;

S4、选择主成分,并写出主成分表达式;

S5、计算主成分得分;

S6、依据主成分得分的数据,提取得分高的主成分作为特征用于下面的分类中;

识别模块,利用极限学习机对手腕静脉图像进行分类识别,用图像信息的主成分与高频低频特征,与手腕静脉特征数据库进行识别比对;

极限学习机模型为:

$$\sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i \bullet x_j + b_i) = y_j$$

式中,j=1,2,3…N,w_i为所有输入与第i个隐层节点连接权重;

w_i=[w_{i1},w_{i2},…,w_{in}]^T;β_i为所有输出与第i个隐层节点连接权重;

β_i=[β_{i1},β_{i2},…,β_{im}]^T;

利用小波分析提取特征具体为,对手腕静脉图像采样后,在一个大的有限频带中的一个信号,对这个信号进行小波多尺度分解,把采到的信号分成两个信号,即高频部分和低频部分;

手腕静脉采集装置中,采用850nm和940nm波段混合作为照射光源,采用选择CMOS图像传感器,采用的是130万像素的USB网络摄像头,背景颜色设置为黑色。

2. 如权利要求1所述的腕部静脉认证系统,其特征在于:极限学习机模型的矩阵表示形式为:

$$H\beta = Y$$

式中,H为网络隐层输出矩阵,

$$H = \begin{vmatrix} g(w_1x_1 + b_1) & g(w_2x_1 + b_2) & \cdots & g(w_Lx_1 + b_L) \\ g(w_1x_2 + b_1) & g(w_2x_2 + b_2) & \cdots & g(w_Lx_2 + b_L) \\ \cdots & \cdots & \cdots & \cdots \\ g(w_1x_N + b_1) & g(w_2x_N + b_2) & \cdots & g(w_Lx_N + b_L) \end{vmatrix}_{N \times L};$$

$$\beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T; \quad Y = [y_1^T, y_2^T, \dots, y_N^T]^T.$$

3. 如权利要求2所述的腕部静脉认证系统，其特征在于，极限学习机训练前，随机产生w和b，只需确定隐含层神经元个数和激励函数g(x)，即算出β；具体步骤如下：

确定隐含层神经元个数L随机设定输入层和隐含层连接权值w与隐含层神经元偏置b；

选择一个无限可微的函数g(x)作为激励函数，计算隐含层输出矩阵H；

计算输出层权值： $\beta = H^{-1}Y$ 。

腕部静脉认证系统

技术领域

[0001] 本发明涉及一种腕部静脉认证系统。

背景技术

[0002] 静脉身份认证技术是将皮肤下的静脉血管作为身份特征进行身份识别的技术。由于人体静脉血管隐藏于皮肤之下，不易伪造，因此静脉特征识别技术是一种安全性很高的身份识别技术具有很好的应用前景。

[0003] 现代社会对于信息技术又提出了更新、更高的要求，例如计算机使得经济与金融网络化，而网络经济与金融又要求更可靠的信息安全系统。身份验证是人们进行加强信息安全性基本方法之一。传统的身份验证是基于标识物（如证件、钥匙等）或者知识（如密码、PIN等）来完成，然而这些方式不方便、不安全、不可靠的缺点不言而喻：证件、钥匙携带不便、容易丢失伪造；密码可能会被遗忘或被蓄意窃取。因此，急需一种不易被他人替代、仿制、方便、有效、安全的身份识别技术来保障人们的生活和社会的安全，这种技术就是基于人体生理特征的生物识别技术。

发明内容

[0004] 本发明的目的是提供一种腕部静脉认证系统，操作简单，鲁棒性强，解决现有技术中存在传统的身份验证是基于标识物或者知识来完成，然而这些方式不方便、不安全、不可靠的问题。

[0005] 本发明的技术解决方案是：

[0006] 一种腕部静脉认证系统，包括图像采集模块、图像预处理模块、特征提取模块、识别模块；

[0007] 图像采集模块，通过手腕静脉采集装置采集手腕静脉红外图像；

[0008] 图像预处理模块，对采集的手腕静脉红外图像截取感兴趣区域后，对该区域采用均值滤波方法进行滤波处理，进行灰度化、归一化，并采用直方图拉伸的方法进行对比度增强处理；

[0009] 特征提取模块，对预处理后的图像进行主成分特征提取、小波特征提取；

[0010] 识别模块，利用极限学习机对手腕静脉图像进行分类识别，用图像信息的主成分与高频低频特征，与手腕静脉特征数据库进行识别比对。

[0011] 进一步地，极限学习机模型为：

$$\sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j \quad (5.3)$$

[0013] 式中， $j=1, 2, 3 \dots N$ ； w_i 为所有输入与第*i*个节点连接权重；

[0014] $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ ； β_i 为所有输出与第*i*个节点连接权重；

[0015] $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 。

[0016] 进一步地，极限学习机模型的矩阵表示形式为：

[0017] $H\beta = Y \quad (5.4)$

[0018] 式中, H 为网络隐层输出矩阵,

$$[0019] H = \begin{vmatrix} g(w_1x_1 + b_1) & g(w_2x_1 + b_2) & \cdots & g(w_Lx_1 + b_L) \\ g(w_1x_2 + b_1) & g(w_2x_2 + b_2) & \cdots & g(w_Lx_2 + b_L) \\ \cdots & \cdots & \cdots & \cdots \\ g(w_1x_N + b_1) & g(w_2x_N + b_2) & \cdots & g(w_Lx_N + b_L) \end{vmatrix}_{N \times L};$$

$$[0020] \beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T_{M \times L}, \quad Y = [Y_1^T, Y_2^T, \dots, Y_N^T]^T_{M \times N}.$$

[0021] 进一步地,极限学习机训练前,随机产生w和b,只需确定隐含层神经元个数和激励函数g(x),即算出 β ;具体步骤如下:

[0022] 确定隐含层神经元个数L随机设定输入层和隐含层连接权值w与隐含层神经元偏置b;

[0023] 选择一个无限可微的函数g(x)作为激励函数,计算隐含层输出矩阵H;

[0024] 计算输出层权值: $\beta = H^{-1}Y$ 。

[0025] 进一步地,对采集图像截取感兴趣区域,具体为:

[0026] 截取待处理图像:去除掉原始图像的背景,记下手腕静脉与背景交界点的坐标,然后截取交界以内的区域作为待处理图片;

[0027] 待处理图像上截取训练和测试的图像块:待处理图象上随机取一点作为中心,以为边长截取一个图像块作为训练和识别的样本。

[0028] 进一步地,主成分分析步骤为:

[0029] S1、对原始数据进行标准化处理;

[0030] S2、计算样本相关系数矩阵;

[0031] S3、用雅克比方法求相关系数矩阵的特征值和相应的特征向量;

[0032] S4、选择主成分,并写出主成分表达式;

[0033] S5、计算主成分得分;

[0034] S6、依据主成分得分的数据,提取得分高的主成分作为特征用于下面的分类中。

[0035] 进一步地,利用小波分析提取特征具体为,对手腕静脉图像采样后,在一个大的有限频带中的一个信号,对这个信号进行小波多尺度分解,把采到的信号分成两个信号,即高频部分和低频部分。

[0036] 进一步地,手腕静脉采集装置中,采用850nm和940nm波段混合作为照射光源,采用选择CMOSS图像传感器,采用的是130万像素的USB网络摄像头,背景颜色设置为黑色。

[0037] 一种基于极限学习机的手腕静脉图像识别方法,利用极限学习机对手腕静脉图像进行分类识别,用图像信息的主成分与高频低频特征,与手腕静脉特征数据库进行识别比对。

[0038] 进一步地,极限学习机模型为:

$$[0039] \sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j \quad (5.3)$$

[0040] 式中, $j=1, 2, 3 \dots N$; w_i 为所有输入与第*i*个节点连接权重;

- [0041] $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$; β_i 为所有输出与第 i 个节点连接权重;
- [0042] $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$;
- [0043] 极限学习机模型的矩阵表示形式为:
- [0044] $H\beta = Y \quad (5.4)$
- [0045] 式中, H 为网络隐层输出矩阵,

$$[0046] H = \begin{vmatrix} g(w_1x_1 + b_1) & g(w_2x_1 + b_2) & \cdots & g(w_Lx_1 + b_L) \\ g(w_1x_2 + b_1) & g(w_2x_2 + b_2) & \cdots & g(w_Lx_2 + b_L) \\ \cdots & \cdots & \cdots & \cdots \\ g(w_1x_N + b_1) & g(w_2x_N + b_2) & \cdots & g(w_Lx_N + b_L) \end{vmatrix}_{N \times L};$$

$$[0047] \beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T_{M \times L}, \quad Y = [Y_1^T, Y_2^T, \dots, Y_M^T]^T_{M \times N}.$$

- [0048] 极限学习机训练前, 随机产生 w 和 b , 只需确定隐含层神经元个数和激励函数 $g(x)$, 即算出 β ; 具体步骤如下:
- [0049] 确定隐含层神经元个数 L 随机设定输入层和隐含层连接权值 w 与隐含层神经元偏置 b ;
- [0050] 选择一个无限可微的函数 $g(x)$ 作为激励函数, 计算隐含层输出矩阵 H ;
- [0051] 计算输出层权值: $\beta = H^{-1}Y$ 。
- [0052] 本发明的有益效果是: 该系统通过对采集图像预处理后, 得到清晰特征明显的图像; 通过分析多种图像特征提取方法, 结合实际情况选用了主成分分析和小波分析进行图像特征提取; 采用极限学习机对图像进行分类, 经过多次试验结果对比, 选择最佳参数, 使识别率达到了 95% 以上。该系统用图像信息的主成分与高频低频特征进行识别, 具有操作简单, 鲁棒性强的优点。

附图说明

- [0053] 图1是腕部静脉认证系统设计的总体框架图。
- [0054] 是原始图像与灰度图像的对比图。
- [0055] 图3是光照明归一化前后图像的对比图。
- [0056] 图4是分段线性变换图。
- [0057] 图5是直方图拉伸关系图。
- [0058] 图6是灰度归一化与对比度增强结果图。
- [0059] 图7是特征提取框图。
- [0060] 图8是极限学习机学习算法的一般步骤图。
- [0061] 图9是隐层结点对训练测试精度的影响示意图。
- [0062] 图10是对十种手腕静脉图像的识别精度示意图。

具体实施方式

- [0063] 下面结合附图详细说明本发明的优选实施例。
- [0064] 该腕部静脉认证系统, 首先通过对摄像头、光源和滤光片的学习后设计了手腕静

脉图像采集装置,在反复的试验和调节之后采集到了满足实验要求的图像。然后用Matlab语言编程完成了图像的预处理和特征提取过程。最后采用极限学习机完成了静脉图像的分类识别并设计了图形用户界面展现了该系统的功能。实验结果表明该系统的识别精度达到了95%以上。腕部静脉认证系统设计的总体框架如图1。

[0065] 图像采集模块,通过手腕静脉采集装置采集手腕静脉红外图像;

[0066] 图像预处理模块,对采集的手腕静脉红外图像截取感兴趣区域后,对该区域采用均值滤波方法进行滤波处理,进行灰度化、归一化,并采用直方图拉伸的方法进行对比度增强处理;

[0067] 特征提取模块,对预处理后的图像进行主成分特征提取、小波特征提取;

[0068] 识别模块,利用极限学习机对手腕静脉图像进行分类识别,用图像信息的主成分与高频低频特征,与手腕静脉特征数据库进行识别比对。用图像信息的主成分与高频低频特征进行识别,该方法具有操作简单,鲁棒性强的优点。

[0069] 手腕静脉采集装置中,采集设备要尽量封闭;背景颜色应该尽量选择灰度值比较低的颜色,比如黑色。采用红外发射二极管(LED)作为红外光源。实施例采用了三种波段的红外LED灯:850nm、880~900nm、940nm。采用光源单独照射和光源两两混合照射的试验,最后发现采用850nm和940nm混合作为照射光源效果最好。采用选择CMOSS图像传感器,采用的是130万像素的USB网络摄像头。这种摄像头最大的有点是拍照后传输方便,可以直接传入电脑中进行处理。采用800~1100nm的滤光片,其光学特性为允许波长在800~1100nm的光通过其他波段的光截止。

[0070] 红外采集原理:根据人体骨骼和肌肉组织的特点,700nm~1000nm NIR的光对人体组织有较强的穿透能力,通过测量人体组织的光学参数,能提取深层生理信息。同时,手腕静脉血管中的血色素相比于皮下的其他组织可以吸收更多IR放射线,可以很好地呈现出静脉血管结构。该波长范围属于近红外光线,根据中国国家医用红外监测光源的有关规定,红外光强处于峰值时,波长范围在800nm~1500nm之间。因此,可以选取750nm~900nm之间一个波段的光作为光源。这个波段的光既能较好地穿透手腕表皮组织,又能较多的被静脉血管所吸收。

[0071] 图像预处理模块,包括手腕静脉图像感兴趣区域提取,归一化,手腕静脉对比度增强。采集的近红外手腕图像是彩色图像并且包含背景和边缘信息的,所以对手腕静脉图像进行预处理是非常必要的。

[0072] 采集图像时采用的是0.85μm的近红外波段不可见光,由于设备很难做到完全封闭,所以采集的图片仍包含着颜色信息(即R、G、B信息),为了减少后期的计算量,首先将图像进行灰度化处理,以消除彩色信息。图像的灰度化,可以使图像的数据量仅为原来的1/3,从而减少了后续处理的计算量。

[0073] 在RGB颜色模型中,由颜色(R,G,B)三种颜色来表示彩色信息。通过计算(R,G,B)来转换得到256色的灰度图像。主要有如下3种方法:最大值法、平均值法、加权平均值法。

[0074] 其中,加权平均值法:根据重要性或其他指标给R,G,B赋予不同的权值,并使R,G,B的值加权,即:

[0075] $Gray = (W_R R + W_G G + W_B B) / (W_R + W_G + W_B)$ (3.3)

[0076] 式中,W_R,W_G,W_B分别为R,G,B的对应的权值,W_R,W_G,W_B取不同的值,加权平均值法将

形成不同的灰度图像。由于人眼对绿色的敏感度最高,对红色分量次之,对蓝色的敏感度最低,因此使 $W_G > W_R > W_B$ 将得到比较合理的灰度图像。

[0077] 在MATLAB中借助rgb2gray(I)函数将彩色图像I转换成灰度图像,它的实现原理是:依据人眼对R、G、B三个分量的敏感程度不同,且敏感程度由低到高依次是蓝、红、绿,所以这里采用的灰度图像的转换方法是根据R、G、B三个分量的重要性的比重对三个分量进行加权处理,三个分量的加权值分别为 $W_G=0.5870$, $W_R=0.2989$, $W_B=0.1140$ 时,可得到最佳的灰度变换图像:

$$I'(i,j) = 0.2989 \times R(i,j) + 0.5870 \times G(i,j) + 0.1140 \times B(i,j) \quad (3.4)$$

[0079] 式中 $I'(i,j)$ 为灰度转换后图像上 (i,j) 点的像素值; $I(i,j)$ 为原始图像上 (i,j) 点的像素值。原始图像(图2左边部分)经过函数rgb2gray(I)的处理后得到的灰度图像(图2右边部分)。

[0080] 对图像的截取分为两部分,第一部分是截取待处理图像;第二部分是在待处理图像上截取训练和测试的图像块。

[0081] 对原始图像进行截取:这一步操作是把原始图像的背景去除掉,保留信息比较丰富的区域。操作方法是,先对采集来的图像进行预览,记下手腕静脉与背景交界点的坐标,然后截取交界以内的区域作为待处理图片。

[0082] 截取训练测试的图像块:在上面得到的待处理对象上随机取一点作为中心,以一定的长度为边长截取一个图像块作为训练和识别的样本。该方块的边长是通过试验测试后得出的最佳长度,即要求满足一定识别率的情况下越小越好。这里有个问题是,由于中心点是随机的,所以中心点有可能落在边界上或离边界很近,这种情况再取方块的话就超出图形的范围了。所以在编程实现的时设置防出界程序,如果出界重新选取中心点直到取到合适的图像块为止。

[0083] 由于无法避免外在环境以及设备本身的影响,手背静脉图像存在一些噪声,这些噪声的不同可能会被误认为是静脉信息的不同,致使系统识别率降低,所以要对图像进行滤波去除噪声处理。实施例采用的是均值滤波的方法。

[0084] 均值滤波是一种典型的线性滤波算法,它是给目标像素一个模板,这个模板包括了目标像素周围的8个像素(不包括目标像素),这个模板被称为滤波模板,用这个模板中的全体像素的平均值来代替目标像素的值。

[0085] 均值滤波的公式表达:

$$[0086] I'(i,j) = \frac{1}{N} \sum_{i \in D, j \in D} I(x+i, y+j) \quad (3.5)$$

[0087] 式中 $I(i,j)$ 为原始图像上 (i,j) 点的像素值; $I'(i,j)$ 为均值滤波后图像上 (i,j) 点的像素值; D 为滤波窗口的大小,一般是 $3*3$ 或 $5*5$ 像素大小。

[0088] 对图像进行均值滤波后,图像中斑点类的噪声大大减少,图像看上去变得更加平滑,滤波处理为后面的图像处理奠定了基础。

[0089] 光照归一化,采集图像样本时,由于手腕到镜头的距离,手腕与镜头的相对位置,以及光强的不同都会造成同一个手腕的不同图像亮度不统一也称光照不统一。在后期分类的时候,分类器会把同一手腕不同光照强度的图像分成不同类别,这会影响分类的精确度。所以要对样本图像进行光照归一化处理。

[0090] 光照的强弱不同在样本图像上就反应为图像的明暗程度不同,而决定图像的明暗程度的内在因素是图像的像素值,所以这里用像素值的大小来反应光照的强弱。

[0091] 本实验对一个手腕采集了50张图片,光照归一化的算法描述如下:先求取每一张图片的平均像素值 $Mean_k$ ($k=1, 2, \dots, 50$) ,然后对这50个平均值再求平均Mean。最后的平均值Mean作为这个手腕的归一光照值,把这50张图片中每一张的均值都归一到最后的平均值上,就完成了光照的归一化。计算公式如下:

$$[0092] Mean_k = \frac{\sum I_k(i, j)}{m_k \times n_k};$$

$$[0093] Mean = \frac{\sum_{k=1}^{50} Mean_k}{50};$$

$$[0094] I_k(i, j)' = I_k(i, j) + Mean - Mean_k \quad (3.6)$$

[0095] 式中, $Mean_k$ 为第 k 幅图像像素的均值; $I_k(i, j)$ 为第 k 幅图像 (i, j) 点的像素值; $m_k n_k$ 为第 k 幅图像矩阵的行数和列数; $Mean$ 为所有图像像素均值; $I_k(i, j)'$ 为光照归一化后第 k 幅图像 (i, j) 点的像素值。

[0096] 从图3的处理结果看出光照归一化前上面几幅图光照比较强下边几幅光照比较弱,归一化后使得同一只手的不同图像光照统一了,即同一类在光照上没有区别了,这为后期的分类奠定了基础。

[0097] 灰度归一化,在截取了图像之后,由于光源较强烈,而且手腕各部分对近红外光的吸收效果存在差异,因而从手腕区域部分可以看到,手腕区域整体偏亮,而手腕静脉与肌肉组织图像对比度较差。为了便于图像的后续处理,在此使用一种图像灰度归一化的方法。处理对比图像见图6。

[0098] 灰度归一化主要借助于下式

$$[0099] I'(i, j) = \frac{I(i, j) - Min(I(i, j))}{Max(I(i, j)) - Min(I(i, j))} \quad (3.7)$$

[0100] 式中 $I(i, j)$ 为原图像上点 (i, j) 处的灰度值; $Max(I(i, j))$ 为原图像灰度最大值; $Min(I(i, j))$ 为原图像灰度最小值; $I'(i, j)$ 为归一化后图像上 (i, j) 处的灰度值。

[0101] 手腕图像对比度增强,灰度归一化之后要对图像进行增强。采用直方图拉伸的方法实现对比度增强。图像的直方图是图像的重要统计特征,是表示数字图像中每一灰度级与该灰度级出现的频数间的统计关系。通常一幅均匀量化的自然图像由于其灰度直方图分布集中在较窄的低值灰度区间,图像的细节看不清楚,为使图像变得清晰,可以通过变换使图像的灰度范围拉开或使灰度分布在动态范围内趋于均化,从而增加反差,使图像的细节清晰,达到图像增强的目的。直方图的变换分为线性、分段线性、非线性以及其他变换。

[0102] 分段线性变换,为了突出图像中感兴趣的目标或者灰度区间,相对抑制那些不感兴趣的灰度区域,而不惜牺牲其他灰度级上的细节,可以采用分段线性法,将需要的图像细节灰度级拉伸,增强对比度,压缩不需要的细节灰度级。常采用图所示的三段线性变换法,其数学表达式如下:

$$[0103] \quad I'(i,j) = \begin{cases} \frac{c}{a}I(i,j) & 0 \leq I(i,j) \leq a \\ \frac{d-c}{b-a}[I(i,j)-a]+c & a \leq I(i,j) \leq b \\ \frac{f-d}{e-b}[I(i,j)-b]+d & b \leq I(i,j) \leq e \end{cases} \quad (3.11)$$

[0104] 图4中对灰度区间[a,b]进行了线性扩展,而灰度区间[0,a]和[b,e]受到了压缩。通过调整折线拐点的位置及控制分段直线的斜率,可对任意一个灰度区间进行扩展和压缩。

[0105] 直方图拉伸对比度增强,实施例采用的对比度增强方法是分段线性变换。此方法使得血管处的灰度值更低,肌肉组织处的灰度值更高,这要血管纹路就变得更加清晰了。事实证明,通过图像直方图拉伸进行图像增强是一种有效的方法。处理对比图像见图6。

[0106] 图像的特征一般会关注于图像的一些变化较剧烈的部分,手腕静脉图像往往具有较为简单而且清晰的纹理特征,由手腕静脉典型图像可以看到,手腕静脉较肌肉组织具有较好的灰度区分性,显然这给手腕静脉的提取带来了极大的便利。

[0107] 特征选择,从一个待识别模式上形成特征数据,也即该模式的原始特征。特征的类型和数量在很大程度上影响着分类器的性能。由特征形成过程得到的原始特征可能很多,如果把所有的原始特征都作为分类特征送往分类器,不仅使得分类器更加复杂,分类计算判别量更大,而且分类错误概率也不一定小。因此需要减少特征的数目。至于减少特征数目方法就是这里涉及到的特征的选择与提取。特征的选择是从一组特征中挑选出一些最有效的特征以达到降低特征空间维数的方法。

[0108] 就图像所能提供的信息属性而言,大致能分为四个方面:结构特性、统计特性、模糊特性及知识特性。在静脉识别中,主要用到的是前两类特性,即与之对应的是几何特征和统计特征。

[0109] 特征提取就是要寻找图像中易于区分的环节,对于细节几何特征提取在静脉方面表现的是提取出静脉图像中的交叉点和端点,并将其表述出来。静脉细节特征主要包括静脉的端点和交叉点。采用细节特征具有识别精度高的优点,它的缺点是对前期图像的预处理的要求高。

[0110] 对于细化后的图像(灰度为0或255的单像素图像),端点的提取比较简单,思路非常清晰:逐行扫描图像,首先找到第一个黑点f(灰度为0),检查其周围八个相邻点中黑点的个数N,如果N=1,则证明f点为端点,迭代整个图像,直到整幅图像扫描完毕,找到所有端点。

[0111] 在静脉图像中出现交叉点的种类主要有三交叉点和四叉点,求三线交叉点的算法和求端点的算法类似,只是要求该黑点周围八相邻点中黑点的个数为三。

[0112] 对于四叉点,两线只有垂直交叉和非垂直交叉两种情况。对于垂直交叉的情况,中心交叉点八邻域内有四个点,只有这一种可能;对于非垂直交叉点的情况,将会产生两个三叉点,在这段图像中两线交叉应该只有一个交叉点,产生误差,排除方法是:如果求出某点是交叉点,那么限定其八邻域内不允许再有交叉点,既是周围八邻域内不再考虑交叉点。

[0113] 把端点、交叉点提取出来后,匹配一般分为局部比对和全局比对两种方法。

[0114] 局部比对:不同的比对算法决定着不同的比对计算复杂性。

[0115] 采用的比对算法为:首先判断中心点的类型是否相同,如果相同则一一比对邻域特征点的参数是否匹配:包括邻域特征点的类型是否相同,两点间参数和三点间参数是否满足阈值范围(误差小于5%-10%)的要求。如果符合条件的星型结构的中心点保留下来仍然作为特征点,不符合条件的星型结构的中心点从特征点中删除。因此删除了不合格的特征点,留下的点作为下一步匹配的特征点。这样做的目的是避免同一类静脉图像中两个相差很大的星型结构之间进行匹配。

[0116] 全局匹配。首先统计出经过局部匹配之后保留下来的端点和交叉点,然后计算出所有这些端点之间的距离和交叉点之间的距离,按照从小到大的顺序排列,大概可以得出100多个距离,用这100多个距离进行匹配实验,计算累积误差,如果误差大于阈值则匹配失败,如果误差小于阈值则匹配成功,在这里阈值设为(5%)。可以看出此全局匹配方法对于伪细节和局部形变的影响很敏感,特别是当静脉特征点比较少时,这种影响是不能被忽视的。特征点数目越少,所受的影响程度就越大。影响主要有两种:

[0117] (1) 伪细节的影响:特征点类型的改变、增加的伪特征点或丢失的真特征点。

[0118] (2) 局部非线性形变的影响:不可预知的局部非线性形变,使得细节点对的相对距离、角度和方向角产生较大的改变,而超过匹配阈值范围,致使原本匹配的点不匹配;或者使得局部特征完全改变。

[0119] 在实际静脉图像中,这种伪细节和局部形变是普遍存在的。例如在实施例所使用的静脉图像中,每一幅都存在伪细节和局部形变,如果仅仅采用全局特征点匹配那么绝大多数的误判都是由于这两种影响所致。因此可以看出实施例的这种局部加全局的匹配方案是很合理的,而且实验证明识别率提高很多。

[0120] 静脉图像全局特征,随着智能计算机方法的高速发展,基于整体图像的全局相关性匹配的方法成为可能。这种匹配方法有如下特点:

[0121] (1) 基于全局相关性的匹配方法不需要提取图像的细节特征,进而去除了由于细节特征提取不准确对图像匹配带来的影响。

[0122] (2) 基于全局相关性的匹配方法相对于基于细节特征的匹配算法更加简单。

[0123] (3) 提取出的全局特征中包含了图像中隐含的一些特征。

[0124] 匹配方法采用变换的模板匹配的方法。与传统的模板匹配不同的是,在没有标准模板的情况下,采用移动的变换模板(在样本图像中从起始点开始选定特定大小模板,每一块模板都与待识别图像进行模板匹配。然后按照特定的大小逐点移动变换模板。)最后找出最接近的匹配结果。匹配过程中,模板每移动一次都计算出相对应部分的不变矩,然后匹配模板和待匹配图像相对应部分的不变矩。

[0125] 特征提取,大部分的认证系统(如指纹识别人脸识别系统)用的都是图像匹配的方法,它们提取的都是具体特征,如特征点的个数,图像纹路特征等。但是实施例研究的手腕静脉认证系统要求在信息不完全(不是整幅手腕静脉图像)时仍能完成识别工作,这就决定了实施例不能采用特征点等这类的具体特征。基于这方面考虑采用了主成分分析和小波分析两种方法提取图像内部特征,如图7。

[0126] 主成分分析是采取一种数学降维的方法,找出几个综合变量来代替原来众多的变量,使这些综合变量能尽可能地代表原来变量的信息量,而且彼此之间互不相关。这种将把

多个变量化为少数几个互相关联的综合变量的统计分析方法就叫做主成分分析或主分量分析。

[0127] 主成分分析所要做的就是设法将原来众多具有一定相关性的变量,重新组合为一组新的相互无关的综合变量来代替原来变量。通常,数学上的处理方法就是将原来的变量做线性组合,作为新的综合变量,但是这种组合如果不加以限制,则可以有很多,应该如何选择呢?如果将选取的第一个线性组合即第一个综合变量记为 F_1 ,自然希望它尽可能多地反映原来变量的信息,这里“信息”用方差来测量,即希望 $\text{Var}(F_1)$ 越大,表示 F_1 包含的信息越多。因此在所有的线性组合中所选取的 F_1 应该是方差最大的,故称 F_1 为第一主成分。如果第一主成分不足以代表原来 p 个变量的信息,再考虑选取 F_2 即第二个线性组合,为了有效地反映原来信息, F_1 已有的信息就不需要再出现在 F_2 中,用数学语言表达就是要求 $\text{Cov}(F_1, F_2) = 0$,称 F_2 为第二主成分,依此类推可以构造出第三、四···第 p 个主成分。

[0128] 主成分分析的数学模型,对于一个样本资料,观测 p 个变量, x_1, x_2, \dots, x_p , n 个样品的数据资料阵为:

$$[0129] X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} = (x_1, x_2, \dots, x_p) \quad (4.1)$$

$$[0130] \text{上式中: } x_j = \begin{pmatrix} x_{1j} \\ x_{2j} \\ \vdots \\ x_{nj} \end{pmatrix}, \quad j=1, 2, \dots, p.$$

[0131] 主成分分析就是将 p 个观测变量综合成为 p 个新的变量(综合变量),即

$$[0132] \begin{cases} F_1 = a_{11}x_1 + a_{12}x_2 + \cdots + a_{1p}x_p \\ F_2 = a_{21}x_1 + a_{22}x_2 + \cdots + a_{2p}x_p \\ \cdots \\ F_p = a_{p1}x_1 + a_{p2}x_2 + \cdots + a_{pp}x_p \end{cases} \quad (4.2)$$

[0133] 简写为:

$$[0134] F_j = a_{j1}x_1 + a_{j2}x_2 + \cdots + a_{jp}x_p$$

$$[0135] j = 1, 2, \dots, p$$

[0136] 要求模型满足一下条件:

[0137] (1) F_i, F_j 互不相关 ($i \neq j, i, j = 1, 2, \dots, p$)

[0138] (2) F_1 的方差大于 F_2 的方差大于 F_3 的方差,依次类推

[0139] (3) $a_{k1}^2 + a_{k2}^2 + \cdots + a_{kp}^2 = 1$ $k = 1, 2, \dots, p$.

[0140] 于是,称 F_1 为第一主成分, F_2 为第二主成分,依此类推,有第 p 个主成分。主成分又叫主分量。这里 a_{ij} 称为主成分系数。

[0141] 上述模型可用矩阵表示为: $F = AX$;

$$[0142] \quad F = \begin{pmatrix} F_1 \\ F_2 \\ \vdots \\ F_p \end{pmatrix} \quad X = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_p \end{pmatrix}, \quad A = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1p} \\ a_{21} & a_{22} & \cdots & a_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ a_{p1} & a_{p2} & \cdots & a_{pp} \end{pmatrix} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{pmatrix} \quad (4.3)$$

[0143] 式中:A为主成分系数矩阵。

[0144] 主成分分析的步骤,

[0145] 样本观测矩阵为:

$$[0146] \quad X = \begin{pmatrix} x_{11} & x_{12} & \cdots & x_{1p} \\ x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{np} \end{pmatrix} \quad (4.4)$$

[0147] 第一步:对原始数据进行标准化处理

$$[0148] \quad x_i^* = \frac{x_i - \bar{x}_j}{\sqrt{\text{var}(x_j)}} \quad (i=1,2,\cdots,n; j=1,2,\cdots,p) \quad (4.5)$$

$$[0149] \quad \text{其中}, \bar{x}_j = \frac{1}{n} \sum_{i=1}^n x_{ij}, \quad \text{var}(x_j) = \frac{1}{n-1} \sum (x_{ij} - \bar{x}_j)^2 \quad (j=1,2,\cdots,p)$$

[0150] 第二步:计算样本相关系数矩阵

$$[0151] \quad R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1p} \\ r_{21} & r_{22} & \cdots & r_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \cdots & r_{pp} \end{bmatrix} \quad (4.6)$$

[0152] 为方便,假定原始数据标准化后仍用X表示,则经标准化处理后的数据的相关系数为:

$$[0153] \quad r_{ij} = \frac{1}{n-1} \sum_{i=1}^n x_{ii} x_{jj} \quad (i,j=1,2,\cdots,p) \quad (4.7)$$

[0154] 第三步:用雅克比方法求相关系数矩阵R的特征值($\lambda_1, \lambda_2, \cdots, \lambda_p$)和相应的特征向量 $a_i = (a_{i1}, a_{i2}, \cdots, a_{ip})$, $i=1,2,\cdots,p$ 。

[0155] 第四步:选择重要的主成分,并写出主成分表达式。

[0156] 主成分分析可以得到p个主成分,但是,由于各个主成分的方差是递减的,包含的信息量也是递减的,所以实际分析时,一般不是选取p个主成分,而是根据各个主成分累计贡献率的大小选取前k个主成分,这里贡献率就是指某个主成分的方差占全部方差的比重,实际也就是某个特征值占全部特征值合计的比重。即

$$[0157] \quad \text{贡献率} = \frac{\lambda_i}{\sum_{i=1}^p \lambda_i} \quad (4.8)$$

[0158] 贡献率越大,说明该主成分所包含的原始变量的信息越强。主成分个数k的选取,

主要根据主成分的累积贡献率来决定,即一般要求累计贡献率达到85%以上,这样才能保证综合变量能包括原始变量的绝大多数信息。

[0159] 另外,在实际应用中,选择了重要的主成分后,还要注意主成分实际含义解释。主成分分析中一个很关键的问题是如何给主成分赋予新的意义,给出合理的解释。一般而言,这个解释是根据主成分表达式的系数结合定性分析来进行的。主成分是原来变量的线性组合,在这个线性组合中个变量的系数有大有小,有正有负,有的大小相当,因而不能简单地认为这个主成分是某个原变量的属性的作用,线性组合中各变量系数的绝对值大者表明该主成分主要综合了绝对值大的变量,有几个变量系数大小相当时,应认为这一主成分是这几个变量的总和,这几个变量综合在一起应赋予怎样的实际意义,这要结合具体实际问题和专业,给出恰当的解释,进而才能达到深刻分析的目的。

[0160] 第五步:计算主成分得分。

[0161] 根据标准化的原始数据,按照各个样品,分别代入主成分表达式,就可以得到各主成分下的各个样品的新数据,即为主成分得分。具体形式可如下。

$$[0162] \quad \begin{pmatrix} F_{11} & F_{12} & \cdots & F_{1k} \\ F_{21} & F_{22} & \cdots & F_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ F_{n1} & F_{n2} & \cdots & F_{nk} \end{pmatrix} \quad (4.9)$$

[0163] 第六步:依据主成分得分的数据,提取得分高的主成分作为特征用于下面的分类中。

[0164] 利用主成分分析提取特征,本实验对图像矩阵进行主成分分析,经过多次试验结果分析,确定图像的大小为300*300,图像矩阵如下

$$[0165] \quad I = \begin{pmatrix} I_{(1,1)}, I_{(1,2)}, \dots, I_{(1,300)} \\ I_{(2,1)}, I_{(2,2)}, \dots, I_{(2,300)} \\ \vdots & \vdots & \vdots \\ I_{(300,1)}, I_{(300,2)}, \dots, I_{(300,300)} \end{pmatrix} \quad (4.10)$$

[0166] 提取到的特征值如下

$$[0167] \quad \lambda = \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_{300} \end{pmatrix} \quad (4.11)$$

[0168] 试验发现取前六个特征值作为特征就能达到理想的准确率,所以本实验只选取了前六个特征值 $\lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6$,结合后面的小波分析提取的特征作为总体的特征。

[0169] 小波分析特征提取,小波分析是时间(空间)频率的局部化分析,它通过伸缩平移运算对信号(函数)逐步进行多尺度细化,最终达到高频处时间细分,低频处频率细分,能自动适应时频信号分析的要求,从而可聚焦到信号的任意细节,解决了Fourier变换的困难问题。

[0170] 在构造正交小波基时提出多尺度的概念,给出离散正交二进小波变换的金字塔算法,任何函数 $f(x) \in L_2(\mathbb{R})$ 都可以根据分辨率为 2^{-N} 的 $f(x)$ 的低频部分(近似部分)和分辨率

为 2^{-j} ($1 \leq j \leq N$) 下 $f(x)$ 的高频部分 (细节部分) 完全重构。多尺度分析时只对低频部分作进一步分解, 而高频部分则不予考虑, 分解具有关系:

[0171] $f(x) = A_n + D_n + D_{n-1} + \dots + D_2 + D_1 \quad (4.12)$

[0172] 式中 $f(x)$ 为信号; A 为低频近似部分; D 为高频细节部分; n 为分解层数。

[0173] 连续小波变换与离散小波变换

[0174] 小波变换的出发点是通过对一个基本小波通过伸缩和平移而得到一组形状相似的小波。这个基本小波就是母小波, 伸缩和平移后得到的小波称作子小波或小波基函数^[18-19]。母小波的数学定义如下:

[0175] 设 $\psi(t) \in L^2(\mathbb{R})$, 其傅里叶变化为 $\psi(\omega)$, 如果满足

[0176]
$$\int_{-\infty}^{+\infty} \frac{|\psi(\omega)|^2}{\omega} d\omega < +\infty \quad (4.13)$$

[0177] 则称 $\psi(t)$ 为基本小波或母小波。上式也成为小波的允许条件, 一直基本小波 $\psi(t)$ 的函数满足 $\psi(\omega=0)=0$, 即具有带通性质, 有正负交替的振荡波形, 且平均值为零。一般选取紧支集的具有正则性的实函数, 使小波母函数在时、频两域同时具有局部化特性, 以满足时频分析的要求。通过对不 $\psi(t)$ 做平移和伸缩, 就可以生成小波基函数。

[0178]
$$\psi_{a,\tau}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-\tau}{a}\right), a > 0, \tau > R \quad (4.14)$$

[0179] 式中, a 为尺度因子; τ 为平移因子。

[0180] 由于 a 、 τ 都是连续变化的因此 $\psi_{a,\tau}(t)$ 也称作连续小波基函数。尺度因子的作用是将小波做伸缩, 对于不同的尺度 a , 基本小波被伸缩为 $\psi\left(\frac{t}{a}\right)$, a 较大时, $\psi\left(\frac{t}{a}\right)$ 变宽, 反之则变窄。即尺度因子变化时, 小波的时频分辨率也相应进行变化。

[0181] 时窗宽度和频窗宽度的变化时反向的, 时窗拉伸必然导致频窗压缩, 时窗压缩必然导致频窗拉伸。这种小波变换特有的时频窗结构很符合实际应用的需要: 低频信号持续时间长, 总是希望时窗尽量宽些, 而频率尽量精细一些; 分析高频信号时, 则希望时窗窄一些, 频域适当降低精度。

[0182] 有了连续小波基函数 $\psi_{a,\tau}(t)$, 将这些函数作用域能量有线信号 $f(t)$, 或者说在这些小波基函数下进行投影分解, 就得到连续小波变换。定义如下:

[0183]
$$WT_f(a, \tau) = \langle f(t), \psi_{a,\tau}(t) \rangle = \frac{1}{\sqrt{a}} \int_R f(t) \psi_{a,\tau}^*\left(\frac{t-\tau}{a}\right) dt \quad (4.15)$$

[0184] 式中, $WT_f(a, \tau)$ 为小波变换系数; $\langle f(t), \psi_{a,\tau}(t) \rangle$ 为 $f(t)$ 与 $\psi_{a,\tau}(t)$ 的内积; $\psi_{a,\tau}^*\left(\frac{t-\tau}{a}\right)$ 为 $\psi_{a,\tau}\left(\frac{t-\tau}{a}\right)$ 的复共轭。

[0185] 上面介绍的即为函数 $f(t)$ 的连续小波变换。

[0186] 由于现代计算机基本车采用数字处理模式, 因此需要对小波变换进行离散化, 以适合于数字计算机上的使用。离散小波变换 (Discrete Wavelet Transform, DWT) 是相对于连续小波变换 (CWT) 的变换方法, 本质上是对尺度因子 a 和平移因子 τ 进行离散化处理。一种

经典的被普遍接受的离散化方法是将尺度因子 a 按幂级数进行离散化,而平移因子 τ 按某间隔 τ_0 做均匀采样,分别如下所示

[0187] $a = a_0^j (a_0 > 0, j \in \mathbb{Z})$

[0188] $\tau = k\alpha_0^j \tau_0 (\tau_0 \in \mathbb{R}, k \in \mathbb{Z}) \quad (4.16)$

[0189] 其中母小波 $\psi(t)$ 的具体形式决定了 a_0 、 τ_0 的取值,则小波变为离散小波

[0190] $\psi_{a,x}(t) = a_0^{-j/2} \psi(a_0^{-j} t - k\tau_0) \quad (4.17)$

[0191] 则离散后的小波变换可以表示为:

[0192] $WT_f(a, \tau) = \langle f(t), \psi_{a,x}(t) \rangle = a_0^{-j/2} \int_R f(t) \psi_{a,x}^*(a_0^{-j} t - k\tau_0) dt \quad (4.18)$

[0193] 离散后的小波变换系数与连续小波变换系数相比,前者是关于 j, k 二维的离散序列,而后者是关于整数 a, τ 的二维连续变量。

[0194] 图像的多层小波分解,小波分解的低频带和高频带起着不同的作用,低频成份的作用主要对应于全局(整体)描述,而高频成份的作用主要对应于局部细节的描述。由此可见,将图像经小波变换后只要去除高频成分,保留低频成分就能够很好的保留手腕静脉信息。图像经过一层小波分解能够得到四个子带图像,即LL、HL、LH和HH,且每个子图的维数是原图像的四分之一,一幅手背静脉图像经一次小波分解后的结果。可知图像经过一层小波分解后产生了四个子带图像。子带图像LL代表图像在水平和垂直方向经过低通滤波后的低频分量;HL代表原始图像在水平方向的高频分量和垂直方向的低频分量;LH代表原始图像在水平方向上低频分量和垂直方向高频分量;HH代表了原始图像在水平和垂直方向的高频分量。所示,子带图像LL很好的保存了原图像的结构信息,所以去除子带图像HL、LH和HH,只保留LL。然后将LL再进行一次小波分解,仍保留第一个子带图像,去除其他子带图像。以此类推,通过对每一层子带图像LL进行一次小波分解便可得到多层小波分解结果。经两次小波分解后,手背静脉图像的主要结构信息保持不变,且图像中的噪声得到了降低,另外图像的维数也降低了16倍。可见在手背静脉识别系统采用小波变换为之后的特征提取提供了方便。

[0195] 利用小波分析提取特征,对手腕静脉图像采样后,可得到在一个大的有限频带中的一个信号,对这个信号进行小波多尺度分解,其实质就是把采到的信号分成两个信号,即高频部分和低频部分,而低频部分通常包含了信号的主要信息,高频部分则与噪音及扰动联系在一起。根据分析的需要,可以继续对所得到的低频部分进行分解,如此又得到了更低频部分的信号和频率相对较高部分的信号。

[0196] 实施例采用两层的小波分解,得到图像的高低频系数,包括两个低频系数和六个高频系数,然后对这八个系数分别取平均值得到8个特征值,所以小波分析得到了图像的8个特征。将这八个特征值与主成分提取的六个特征值组成一个特征矩阵,用于后期分类器的输入特征。

[0197] 特征结合与特征值矩阵的生成,将提取到的两种特征进行结合,并且加上期望输出形成特征值矩阵直接作为极限学习机的训练和识别样本。

[0198] 单独采用主成分分析提取的特征或者单独采用小波分析提取的特征用于后期的图像识别存在很多的缺点。一种方法提取的特征容易出现误差,使得后期的识别精度波动

比较大,随机性太强,识别结果不可靠。由试验得出特征个数越多识别精度越高,所以尽量多选几个特征,但是特征太多识别时间就会越长,存在矛盾现象,使用较少的特征值来完成高精度的识别。

[0199] 在主成分提取中,可以用很多的特征值,并且使用的特征值越多识别精度相对会有提高,但是试验发现,特征多样化会使识别精度提高幅度增大,比如增加一个主成分的特征和增加一个小波提取的特征后者测试的识别准确率高于前者,所以采用两种特征结合为一个特征矩阵作为后期的识别特征,这样就达到了用较少特征值完成高精度识别的目的。

[0200] 基于极限学习机的手腕静脉图像识别

[0201] 给定N个学习样本矩阵(x_i, y_i)

[0202] $x_i = [x_{i1}, x_{i2}, x_{i3}, \dots, x_{in}]^T$

[0203] $y_i = [y_{i1}, y_{i2}, y_{i3}, \dots, y_{in}]^T \quad (5.1)$

[0204] 给定构造网络的L个单隐层结点和单隐层结点激励函数 $g(x)$ 一般情况下:

$$[0205] g(x) = \text{sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (5.2)$$

[0206] 因此极限学习机模型可以表示为:

$$[0207] \sum_{i=1}^L \beta_i g_i(x_j) = \sum_{i=1}^L \beta_i g(w_i \cdot x_j + b_i) = y_j \quad (5.3)$$

[0208] 式中, $j=1, 2, 3, \dots, N$; w_i 为所有输入与第i个节点连接权重

[0209] $w_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$; β_i 为所有输出与第i个节点连接权重

[0210] $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$ 。

[0211] 由上面的分析,把ELM的模型写成矩阵的表示形式就是:

$$[0212] H\beta = Y \quad (5.4)$$

[0213] 式中,H为网络隐层输出矩阵

$$[0214] H = \begin{vmatrix} g(w_1 x_1 + b_1) & g(w_2 x_1 + b_2) & \dots & g(w_L x_1 + b_L) \\ g(w_1 x_2 + b_1) & g(w_2 x_2 + b_2) & \dots & g(w_L x_2 + b_L) \\ \dots & \dots & \dots & \dots \\ g(w_1 x_N + b_1) & g(w_2 x_N + b_2) & \dots & g(w_L x_N + b_L) \end{vmatrix}_{N \times L};$$

$$[0215] \beta = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T_{M \times L}, \quad Y = [Y_1^T, Y_2^T, \dots, Y_N^T]^T_{N \times M}.$$

[0216] 当任意给定w和b时有 $\beta = H^{-1}Y$ 。极限学习机训练之前,随机产生w和b,只需要确定隐含层神经元个数和激励函数 $g(x)$,即可算出 β 。

[0217] 极限学习机算法的一般步骤:

[0218] 1、确定隐含层神经元个数L随机设定输入层和隐含层连接权值w与隐含层神经元偏置b。

[0219] 2、选择一个无限可微的函数 $g(x)$ 作为激励函数,计算隐含层输出矩阵H

[0220] 3、计算输出层权值: $\beta = H^{-1}Y$ 。

[0221] 由于ELM在训练时不需要调整输入权值和偏置,参数选择较为简单,整个过程不需要迭代,所以ELM算法最为突出的优点就是,它的速度非常的快。训练速度得到显著提升。

速度提升的同时算法结果也得到较好保证。并且ELM算法克服了传统基于梯度算法(如BP算法)局部最小化以及过度拟合的问题。总之,ELM算法结构相对于其他前馈网络算法简单得多并且具有良好的泛化能力。

[0222] 极限学习机对手腕静脉图像分类,实施例采集了五个人的双手手腕图像,每只手选取了50张,总共500张手腕静脉图像作为原始数据。

[0223] 训练和测试数据的产生,原始图像I的大小是640*480,第一次截取图像I₁大小是332*604,分别以10、30、40...300为边长在I₁上随机选择一点作为中心截取正方形图像块。每一个手腕静脉图像截取50个图像块,然后33个作为训练样本17个作为测试样本。由边长的递增产生30组,训练和测试数据。

[0224] 隐层结点数的确定,极限学习机隐层结点的个数对测试训练精度影响是非常大的,所以要选择合适的结点个数。通过多次实验结果(图9)对比分析决定,当处理50张图片时选择隐层结点50个,此时精度基本达到理想值,并且时间在接受范围内。

[0225] 识别方块大小的确定,识别图像方块大小选定的原则是,保证一定识别精度的情况下越小越好。为保证识别精度最高,由隐层结点50个时精度随方块大小变化曲线可以看出,当方块大小为240*240左右时识别精度最高。所以这里确定最终用来识别的图像方块大小为240*240。

[0226] 对手腕静脉图像进行分类,在确定好了训练数据、测试数据的分配,极限学习机隐层结点为50,图像块的大小为240*240之后就开始对采集的10种手腕静脉图像进行分类。将提取的特征矩阵伴随期望值送入极限学习机后,开始训练,用训练好的输入权值,隐层偏置及输出权值对测试样本进行分类。把极限学习机测试样本的实际输出值导出就是分类的序号。实施例对10种手腕进行了集中分类,并绘制了测试和训练精度的曲线。由图10可见在所选条件下,训练精度始终为1,测试精度虽然有波动但是整体在0.95以上,已经满足了识别精度的要求。

[0227] 通过设计用户界面,让操作者根据界面上的文字提示或者一些对话框通过单击一些简单的按钮完成该系统的功能。

[0228] 实施例设计了一个静脉识别的用户界面,使用者可以通过简单的操作完成待测试手腕静脉的识别。在运行GUI后出现的界面中,第一步点击“读图”,点击后会弹出一个对话框供用户选择要识别的手腕静脉图像,选定后点击打开,图像数据就读入程序了。第二步点击“读模式”,该步是读取事先训练好的数据(如极限学习机的输入权值、隐层偏置和输出权值等),为下一步的识别做准备。第三步点击“识别”,把读入的图片送入极限学习机的测试程序中进行测试,在左侧会显示处理后的图像,并在“识别结果”栏显示出识别的结果如图。第四步点击“退出”关闭GUI界面。

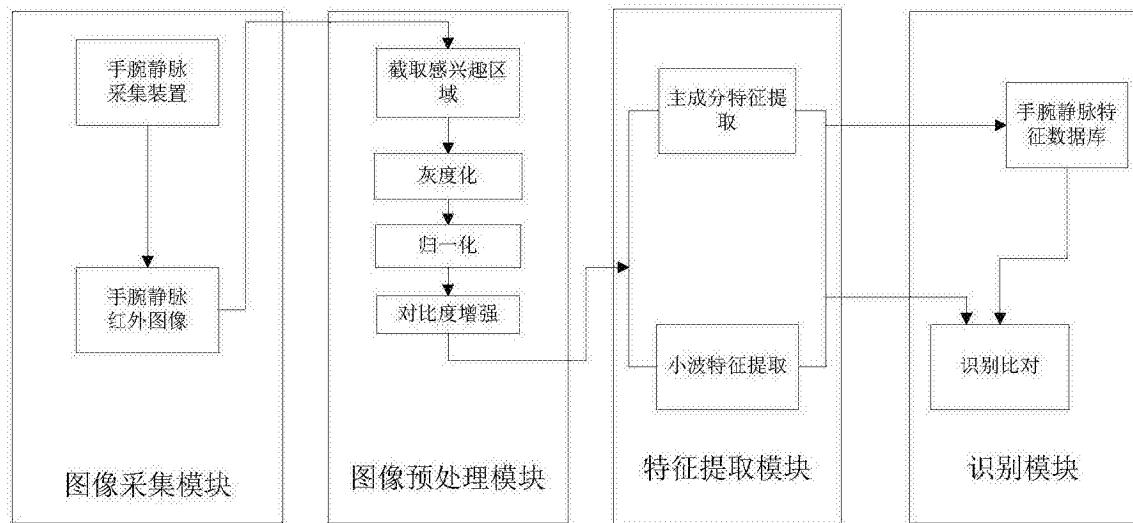


图1

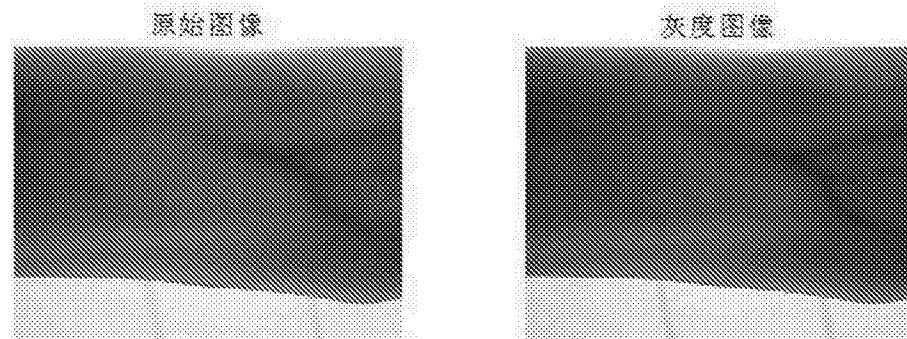


图2

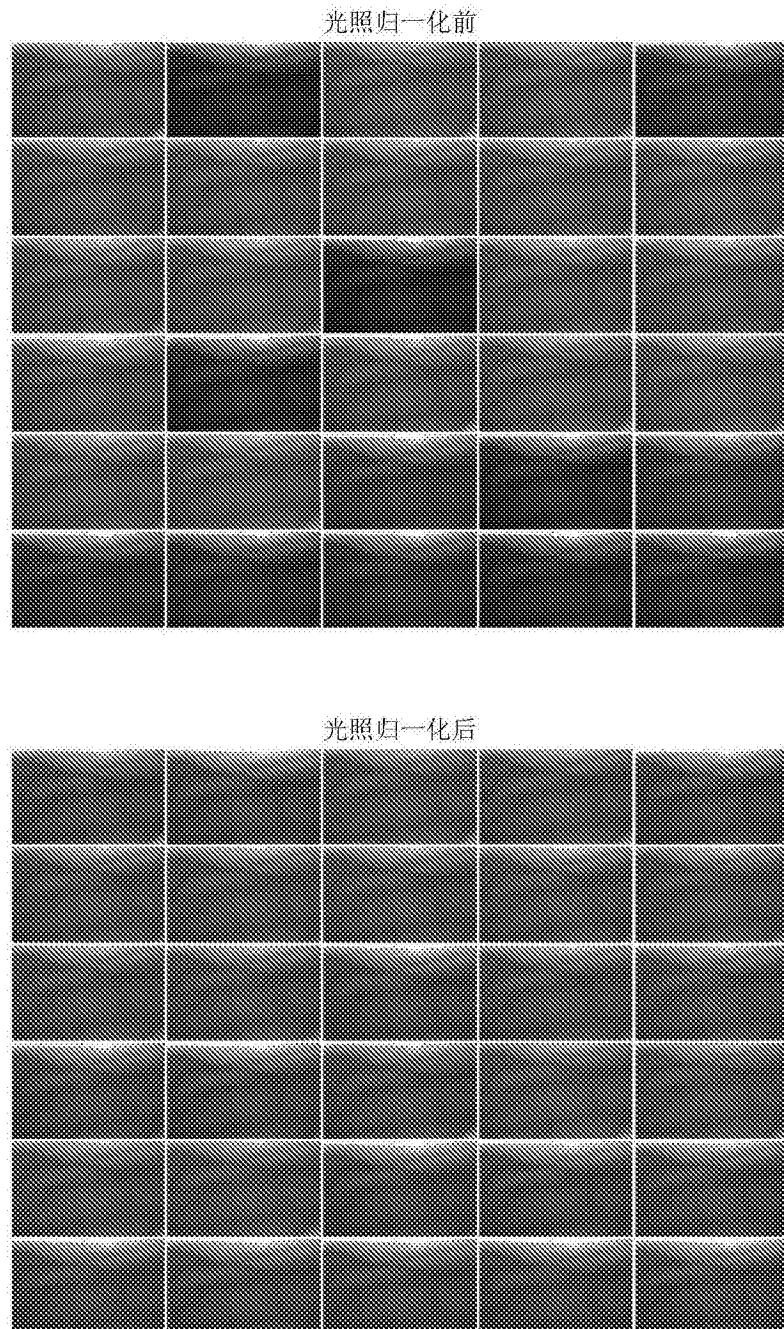


图3

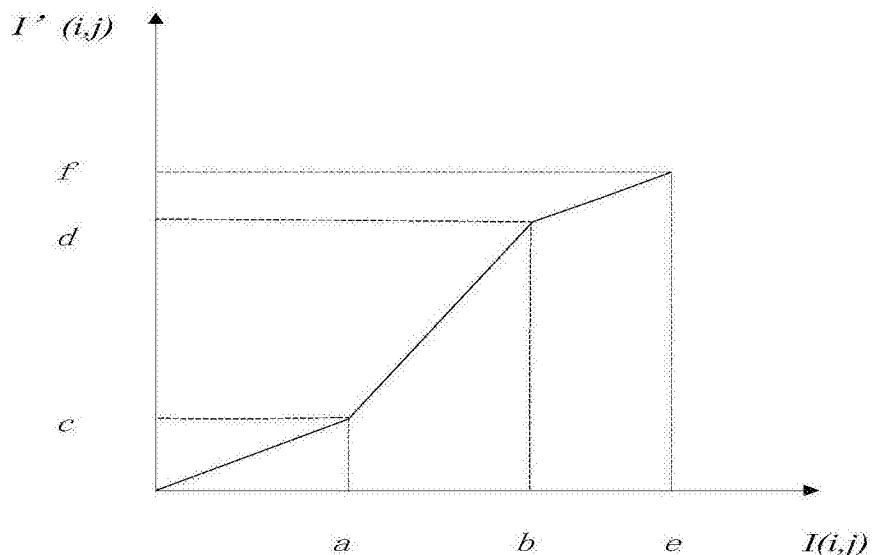


图4

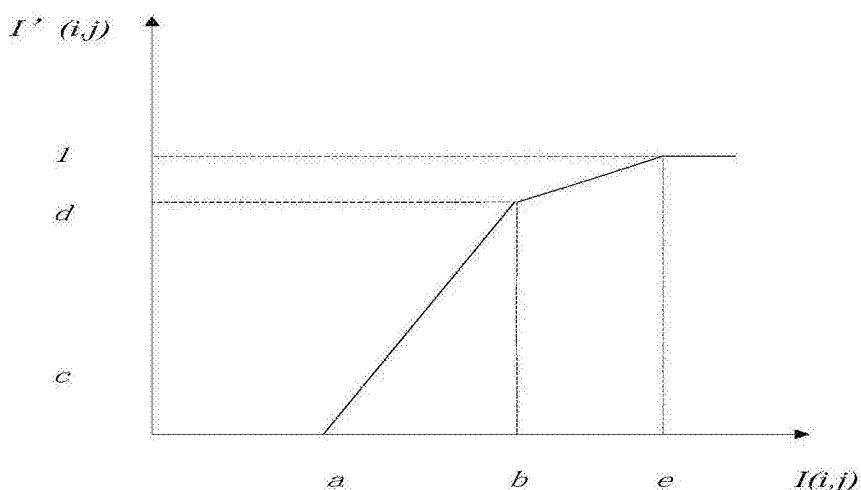


图5

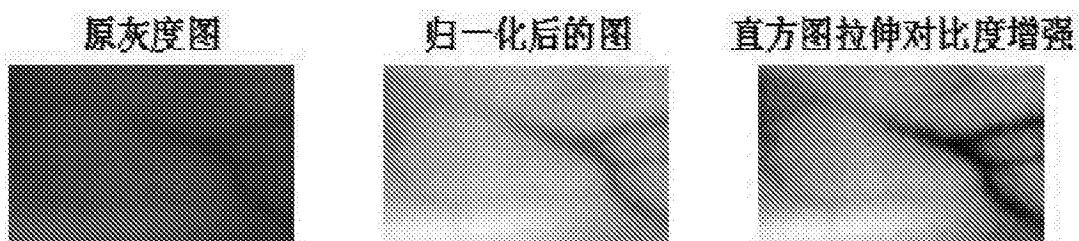


图6

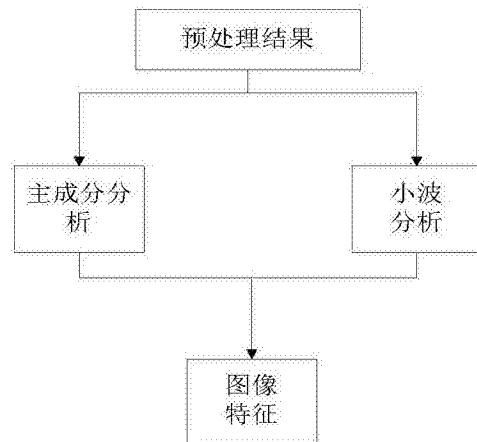


图7

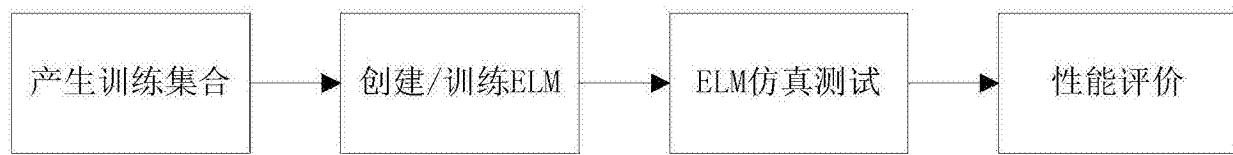
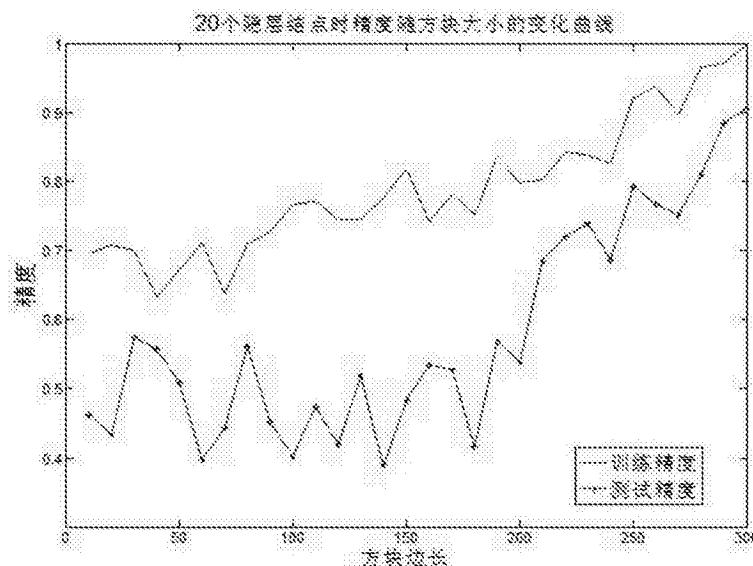
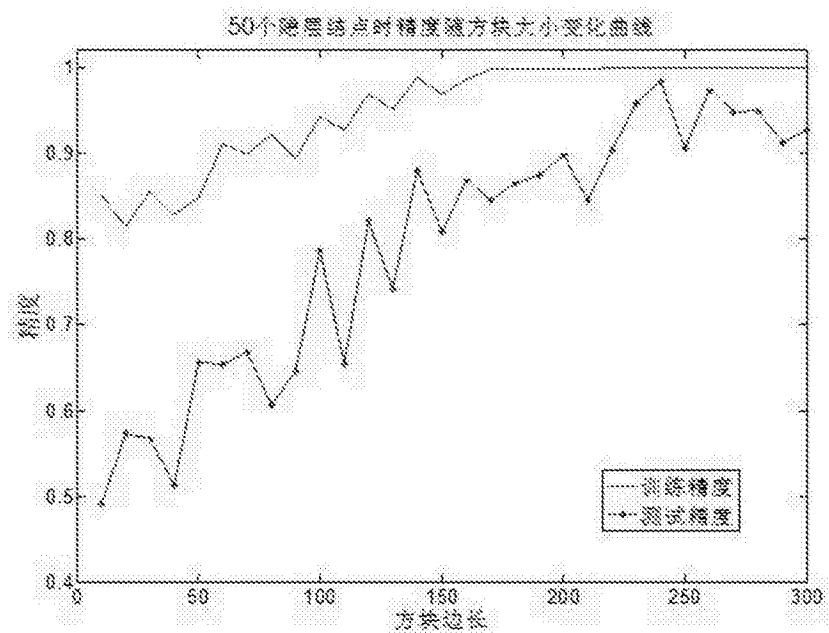
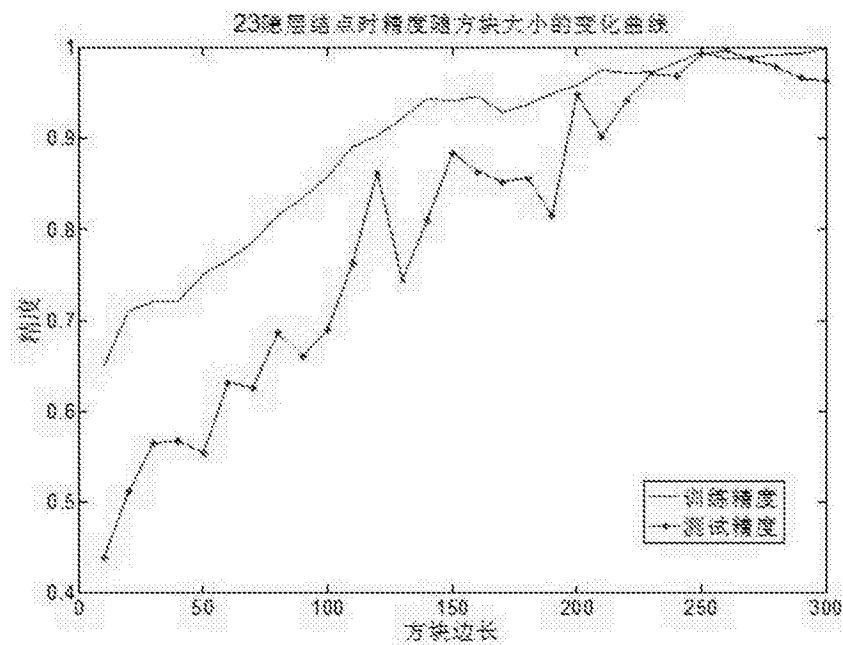


图8





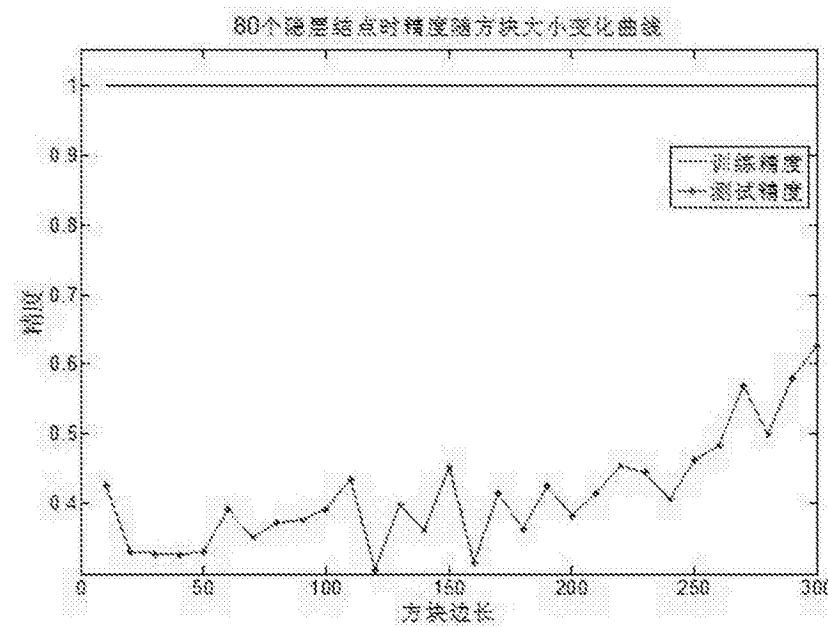


图9

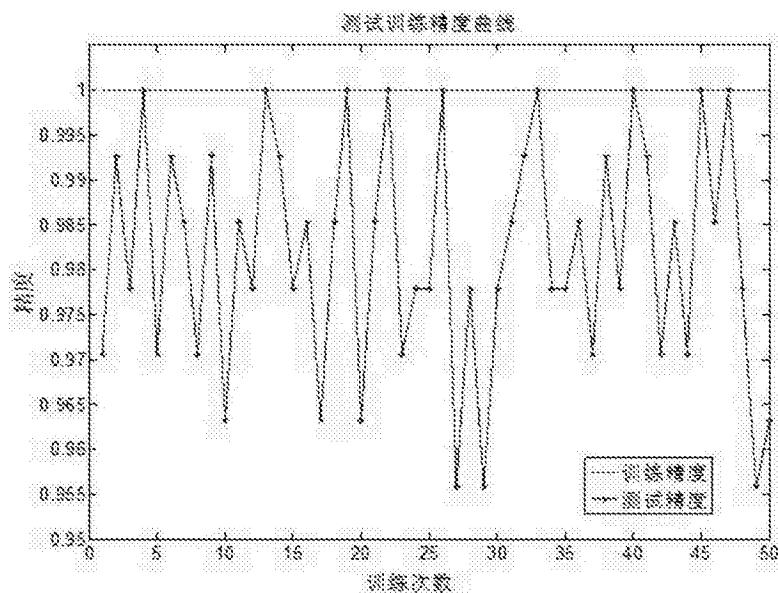


图10