

基于连续小波变换的神经网络人脸识别研究

赵 静 夏良正

(东南大学自动控制系, 南京 210096)

摘 要 研究了基于连续小波变换的神经网络进行人脸识别的方法. 介绍了小波分析的理论基础, 详细讨论了根据小波变换系数的范数选取小波母函数的方法, 根据小波脊线确定网络神经元个数的方法以及神经网络的初始化和参数训练方法. 通过对人脸图像灰度的连续小波分析, 神经网络的自组织自学习能力, 调整连接权值和小波神经元的尺度、位移参数, 完成人脸识别的任务. 实验结果验证了该神经网络的识别性能明显优于用特征脸方法对相同人脸库进行的识别.

关键词 连续小波变换; 人脸识别; 模板值; 小波脊线

中图分类号 TP391 **文献标识码** A

0 引言

在人脸图像中, 灰度的不连续性通常提供了人脸中某一部分的边缘和特征, 这恰恰是理解图像最有意义的部分, 可以把突变部分理解为是人脸图像的高频分量形成的奇异点. 本文利用小波神经网络整合小波分析提取信号局部奇异特征和人工神经网络自适应学习分类的优点, 研究了基于连续小波变换的神经网络人脸识别方法. 该方法根据人脸图像灰度连续小波变换的模板值在多尺度下幅值及分布情况, 确定灰度奇异点, 利用小波神经网络自动提取、调整奇异点的特征信息并完成分类.

选取连续小波变换 (Continuous Wavelet Transform - CWT) 而不是离散小波变换 (Discrete Wavelet Transform - DWT) 的原因是 CWT 提供了优良的瞬变成分检测能力, 能够准确地提取图像中的非平稳分量. 而 DWT, 利用小波基函数支集计算单个位移栅格的小波系数, 然后将小波基函数平移某个量计算下个位移栅格处的小波系数. 这种方式可以形象地比作用手电筒在墙壁上寻找裂缝, 如果手电筒照射的区域没有发现裂缝, 就关掉手电移动到临近区域继续检测. 显然, 当裂缝位于手电筒照射区域中心时, 它将被准确的检测到, 而当裂缝位于手电筒区域边缘时, 它可能被忽略. 相反, CWT 在检测裂缝过程中, 手电筒始终处于打开状态, 并且整个扫描过程是连续进行的, 不存在任何位置上的跳跃. 因此, 只要墙壁存在裂缝, 不管在哪肯定能检测到.

1 基于连续小波变换的神经网络

1.1 网络结构

本文中使用的的小波神经网络 (WNN) 结构如

图 1. 在 WNN 中, 网络第一层的小波函数层提取并选择输入信号的时频特征, 网络的模式分类由 sigmoid 神经元完成. 这时网络的可调参数包括: 小波神经元的尺度因子, 位移因子和神经元之间的连接权值.




图 1 基于连续小波变换的神经网络结构
Fig. 1 Architecture of wavelet neural network based CWT

一般情况下, 神经网络的输入节点数对应人脸特征向量的维数, 而输出节点数由人脸类别数决定. 如果人脸类别越多, 网络的训练就越困难, 分类性能也越差. 因此, 我们对一般的小波神经网络做了一定的改进, 即整个神经网络由多个小波神经子网组成, 每一个子网的负责识别一个人脸模式, 其输出待识别样本与该类模式的匹配程度. 每个子网的输出再送入整个网络的最后一个比较层, 得到所有子网中最大输出值即为整个网络的输出, 而待识别样本属于具有最大输出的子网对应的模式类别. 这样, 单个子网仅需要很少的神经元节点就可以更简单、更快、更容易的进行训练, 而且识别结果也更准确. 当改变的人脸模式的数目时, 我们只需要动态的增减个别神经子网, 从而更灵活的调整网络结构.

1.2 网络输入

在人脸识别技术中, 假定人脸已经被比较准确的定位在图像中, 用图 2 所示的 88×88 象素的模板去除发型和背景的影响, 并将双眼瞳孔的位置固定

在(6,8)和(6,22)坐标附近. 利用人脸的水平对称性,我们由左到右、由上到下记录模板内白色区域内

的人脸灰度值,将表示每一副人脸的列向量归一化减去均值后,输入小波神经网络.



图2 人脸模板和 FERET 数据库中经过处理后的人脸图片
Fig.2 Face model and processed face images of FERET

1.3 小波神经元

小波函数层中对输入信号进行小波分析的神经元,我们称之为小波神经元. 小波神经元的输出是网络输入信号和神经元小波函数的内积模值. 它完成输入信号在特定尺度和位移处的连续小波变换. 小波函数和人脸模式越相似就越能识别属于该类模式的输入信号. 因此,小波函数的选择直接影响小波神经网络的分类性能. 由于信号连续小波变换值反映了信号和小波函数的相关信息,若小波变换值越大,则小波函数和信号就越相似. 因此,某个尺度下信号连续小波变换系数的范数表征了该尺度下信号和小波函数的相似度,而不同尺度下信号连续小波变换系数的范数反映了小波函数和信号的整体匹配程度.




图3 人脸向量
Fig.3 Face vector

为了提高网络的识别率,选取小波函数必须满足:

1)小波函数具有解析表达式(小波神经元可以在时域直接计算小波变换系数),在时域平滑,在频域快速衰减.

2)在所有尺度下,小波函数和输入信号要有足够的相似度,即信号的小波变换系数的范数在所有

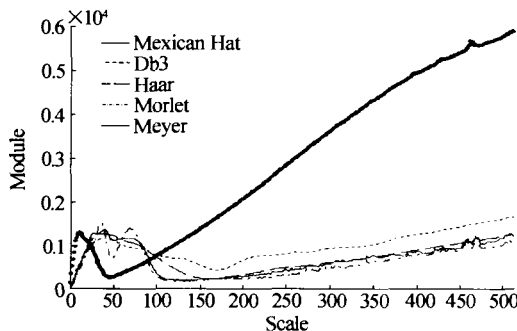


图4 人脸图像的 五种小波 CWT 范数尺度分布
Fig.4 Five CWT module-scale spread of a face image

尺度下要足够大.

图4给出了一种人脸模式图像分别对 Mexican Hat、Db3、Haar、Morlet 和 Meyer 小波的范数尺度分布,可以看出 Mexican Hat 小波在大多数尺度下,对人脸图像灰度信号的小波变换系数明显大于其它小波函数,因此在小波神经网络中选取 Mexican Hat 小波: $\Psi(t) = (1-t^2)e^{-\frac{t^2}{2}}$ 作为小波神经元的激励函数.

1.4 神经元个数

由图1可知,小波神经子网都可以分为三层:小波函数层、Sigmoid 函数层和输出层,其中输出层只含一个 Sigmoid 神经元. 假设小波函数层和 Sigmoid 函数层的神经元个数分别为 M 和 P ,经过实验我们发现,当 $P=2M$ 时,整个小波神经网络具有最佳的识别效果. 这样,小波神经子网一共有 M 个小波神经元和 $2M+1$ 个 Sigmoid 神经元.

小波神经元个数取决于人脸图像灰度的时频特性. 灰度的急剧变化处常是分析其特征的关键之处. 我们可以用小波变换模极值在多尺度上的分布来分析人脸灰度变化,下面给出其理论依据.

信号的突变点与其小波变换系数之间的关系可由下面两条性质描述.

假设 $\theta(t)$ 为一低通平滑函数, $\int \theta(t) dt \neq 0$, 用 $\theta(t)$ 对信号 $f(t)$ 作平滑后得到 $g(t)$, 即 $g(t) = f(t) * \theta(t)$.

性质(1):若 $\Psi^{(1)}(t)$ 是平滑函数 $\theta(t)$ 的一阶导数,即 $\Psi^{(1)}(t) = \frac{d\theta}{dt}$, 用 $\Psi^{(1)}(t)$ 对信号 $f(t)$ 作小波变换得到 $Wf^{(1)}(t)$, 则 $Wf^{(1)}(t)$ 的过零点是 $g(t)$ 的极值点(即 $\frac{dg}{dt} = 0$ 处); $Wf^{(1)}(t)$ 的极值点是 $g(t)$ 的拐点(即 $\frac{d^2g}{dt^2} = 0$ 处),在阶跃输入时它就是阶跃点.

性质(2):若 $\Psi^{(2)}(t)$ 是平滑函数 $\theta(t)$ 的二阶导数,即 $\Psi^{(2)}(t) = \frac{d^2\theta}{dt^2}$, 用 $\Psi^{(2)}(t)$ 对信号 $f(t)$ 作小波变换得到 $Wf^{(2)}(t)$, 则 $Wf^{(2)}(t)$ 的过零点是 $g(t)$ 的拐点(即 $\frac{d^2g}{dt^2} = 0$ 处),在阶跃输入时它就是阶跃点.

这些性质对基本小波函数 $\Psi^{(1)}(t)$, $\Psi^{(2)}(t)$ 的伸

$$\text{缩变换 } \Psi_a^{(1)}(t) = \frac{1}{\sqrt{a}}\Psi^{(1)}\left(\frac{t}{a}\right), \Psi_a^{(2)}(t) = \frac{1}{\sqrt{a}}\Psi^{(2)}\left(\frac{t}{a}\right)$$

同样适用。

上述两条性质是用小波变换过零点和极值点检测信号局部突变的基础。图 5 以信号 $f(t)$ 为例, 说明了其结果。由图可见, 突变点位置既可由过零点反映, 也可由极值点描述。Mallat 认为利用极值点更能准确地刻画突变点, 这是因为过零点易受噪声干扰, 而且有时过零点反映的不是突变点, 而是信号变化最慢的点(如图中 $Wf^{(2)}(t)$ 对应的 t_1 处); 而小波变换极大值点对应信号突变点(如图中 $Wf^{(1)}(t)$ 对应的 t_0 和 t_2 处), 小波变换极小值点对应信号缓变点(如图中 $Wf^{(1)}(t)$ 对应的 t_1 处)。因此, 极值点描述能准确区分两类不同性质的点。




图 5 利用 $\Psi^{(1)}(t), \Psi^{(2)}(t)$ 检测信号 $f(t)$ 的突变点
Fig. 5 Detecting the breakpoints of $f(t)$ using $\Psi^{(1)}(t), \Psi^{(2)}(t)$

由此可得, CWT 系数的局部模极值点对应图像灰度变化显著之处, 所以 CWT 的模极值图反映了灰度突变点在尺度空间的分布信息。为了获取突变点的多尺度分布信息, 可以从最大尺度(粗分辨率)开始, 搜索每一尺度的模极值点, 并将上一尺度模极值点与和它距离最近的下个尺度的极值点连接起来, 如此继续下去, 直至搜索到最小尺度(精细分辨率)。这样, 图像灰度的单个突变点在所有尺度空间中对应的模极值点都被连接在一起, 形成一条条曲线。我们把这些跨尺度生长的曲线称为小波脊线(wavelet ridge)。小波脊线记录了脊线上的所有模极值点在不同尺度时的位移信息。人脸图像灰度的每一个突变点对应尺度空间中一条小波脊线, 而小波脊线上每个模极值点也对应一个灰度突变点。显然, 并不是所有小波脊线都对应我们关注的图像灰度的真正突变点, 有些脊线可能是由噪声引起的。噪声引起的模极值只出现在小尺度范围内, 而且对应的小波脊线长度较短, 随着尺度的增加会很快消失; 而灰度的弱突变点对应的 CWT 较小。另一方面, 灰度的显著突变点不仅对应较大的 CWT 模值, 而且它的小波脊线也足够长, 能够穿越多数尺度。

所以, 可以设置阈值删除那些长度较短或模值较小的小波脊线, 剩下的小波脊线对应我们感兴趣的显著突变点, 同时小波神经元个数也由剩下的小波脊线数目确定。

下面具体给出确定小波神经元个数的步骤:

- 1) 对人脸图像灰度序列进行连续小波变换。
- 2) 确定各尺度下小波系数模的局部极值点, 得到小波系数模极值图。
- 3) 从最大尺度开始, 搜索每一尺度的模极值点, 连接相邻尺度、相邻位置的模极值, 得到尺度空间中的所有小波脊线。
- 4) 设置长度阈值 L 和幅度阈值 α , 并对小波脊线图进行修理, 删去长度小于 L 或尺度为 a 时 CWT 模值小于 $\alpha * \max |C_a|$ 的小波脊线。这里 $\max |C_a|$ 表示 a 尺度下 CWT 模最大值。见图 6。

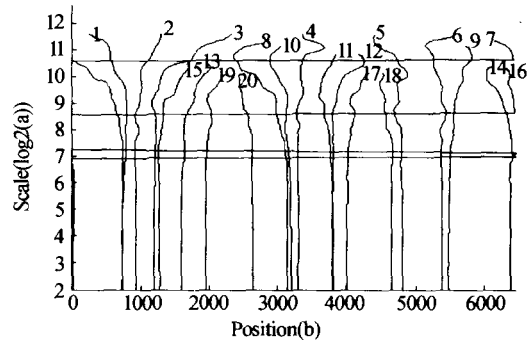


图 6 尺度空间中前 20 条小波脊线分布
Fig. 6 First 20 wavelet ridges spread in scale space

- 5) 剩下的小波脊线数目就是小波神经元的个数。

1.5 网络初始化

网络参数的初始值对网络训练有很大影响, 合理的网路初始值会大大缩短网络的训练时间。小波神经子的网路参数包括小波神经元函数尺度因子、位移因子和连接权值。连接权值的初始值可设为 $(-1, +1)$ 之间的随机数, 而尺度因子、位移因子的初始化相对比较复杂。

我们希望小波神经元能提取输入人脸图像灰度突变点的时频特征, 也就是小波模极值对应的尺度和位移参数。因此, 对信号进行 CWT 有助于我们根据时频分布信息, 更合理的确定小波神经元中尺度和位移因子的初始值。由小波神经元个数的确定过程可知, 一条小波脊线对应一个小波神经元, 小波脊线包含了相应小波神经元的尺度和位移信息。为此我们采取以下方法确定尺度和位移因子的初值。

- 1) 根据小波脊线上每点的小波系数模值随尺度因子变化的函数曲线(见图 7), 找到脊线上模幅值最大点对应的尺度值作为网络的尺度参数初值。
- 2) 小波脊线包含的尺度、位移信息, 找到该尺度对应的位移因子作为网络位移参数的初值。




图7 4号小波脊线的CWT模幅值-尺度函数曲线
Fig.7 CWT altitude-scale curve of No.4 wavelet ridge

1.6 参数训练

小波神经网络中需要训练的网络参数包括小波神经元的尺度因子、位移因子和神经元连接权值。每个小波神经元的输出值是人脸图像灰度在特定尺度和位移下的CWT模值。若小波函数层中第M个小波神经元的输出值为 ϕ_m ，则

$$\phi_m = |\langle C(t), \Psi_{a_m, b_m} \rangle| = \sqrt{[\int \Psi^* (\frac{t-b_m}{a_m}) C(t) dt]^2} = |\int \Psi^* (\frac{t-b_m}{a_m}) C(t) dt| \quad (1)$$

当小波函数为实函数时，有 $\Psi^*(t) = \Psi(t)$ 。因此，对于T维输入矢量 $C(t)$ ； $t \in [0, T-1]$ ，式(1)变为 $\phi_m = |\sum_{t=0}^T \Psi(\frac{t-b_m}{a_m}) C(t)|$ 。其中，T为输入图像向量的长度。

隐含层中第p个Sigmoid神经元输出值为 O_p

$$O_p = f(\sum_{m=1}^M W_{mp} \phi_m + \theta_p) = \frac{1}{1 + \exp[-(\sum_{m=1}^M W_{mp} \phi_m + \theta_p)]} \quad (2)$$

W_{mp} 表示第m个小波神经元与第p个Sigmoid神经元的连接权值；M是小波层中小波神经元的个数； θ_p 是Sigmoid神经元阈值，一般情况下取为零，这时

$$O_p = \frac{1}{1 + \exp(-\sum_{m=1}^M W_{mp} \phi_m)} \quad (3)$$

定义网络误差函数为

$$E = \frac{1}{2} \sum_{i=1}^N \sum_{k=1}^K (d_{ik} - y_{ik})^2 \quad (4)$$

其中， $i=1, 2, \dots, N$ 表示第i个训练样本；K代表网络输出节点的个数，通常一个输出节点对应一类模式； d_{ik} 是第i个样本时第k个输出节点的期望值，当第i个样本属于第k类模式时 $d_{ik}=1$ ，否则 $d_{ik}=0$ ； y_{ik} 表示第i个样本时第k个输出节点的实际输出值。对式中定义的非线性误差函数，可采用梯度下降法，逐步修正网络参数使误差函数达到全局最小值。

假设网络节点的输入为net； W_{mp} 表示第m个小波神经元与第p个Sigmoid神经元的连接权值；

W_{pk} 表示Sigmoid层第p个节点和输出层第k个节点的连接权值。则对Sigmoid函数层第p节点 $net_p = \sum_{m=1}^M W_{mp} \phi_m$ ，对输出层第k个节点 $net_k = \sum_{p=1}^P W_{pk} O_p$ ，M，P分别为小波函数层和Sigmoid函数层的节点个数。利用BP算法可以得到误差函数E对网络参数的偏微分，进而修正网络参数。当小波神经元的小波函数为Mexican Hat小波时，即 $\Psi(t) = (1-t^2)e^{-\frac{t^2}{2}}$

$$\Psi'(t) = t(t^2 - 3)e^{-\frac{t^2}{2}} \quad (5)$$

$$\frac{\partial E}{\partial W_{pk}} = -\sum_{i=1}^N \delta_{ik} O_{ip} = -\sum_{i=1}^N (d_{ik} - y_{ik}) \cdot y_{ik} (1 - y_{ik}) O_{ip} \quad (6)$$

$$\frac{\partial E}{\partial W_{mp}} = -\sum_{i=1}^N \delta_{ip} \phi_{im} = -\sum_{i=1}^N [O_{ip} (1 - O_{ip}) \cdot \sum_{k=1}^K \delta_{ik} W_{pk}] \phi_{im} \quad (7)$$

$$\frac{\partial E}{\partial b_m} = -\sum_{i=1}^N \sum_{k=1}^K \delta_{ik} \sum_{p=1}^P \frac{\partial net_k}{\partial net_p} W_{mp} \left[\frac{-1}{a_m |\phi_{im}|} \cdot \sum_{t=0}^{T-1} \Psi'(t') C(t) \right] = -\sum_{i=1}^N \sum_{k=1}^K \delta_{ik} (d_{ik} - y_{ik}) y_{ik} (1 - y_{ik}) \cdot \sum_{p=1}^P W_{pk} O_{ip} (1 - O_{ip}) W_{mp} \left[\frac{-1}{a_m |\phi_{im}|} \sum_{t=0}^{T-1} \Psi'(t') C(t) \right] = -\sum_{i=1}^N \frac{[\sum_{t=0}^{T-1} t'(t^2 - 3)e^{-\frac{t'^2}{2}} C(t)]}{a_m |\phi_{im}|} \sum_{k=1}^K (d_{ik} - y_{ik}) y_{ik} (1 - y_{ik}) \sum_{p=1}^P W_{pk} O_{ip} (1 - O_{ip}) W_{mp} \quad (8)$$

$$\frac{\partial E}{\partial a_m} = -\sum_{i=1}^N \sum_{k=1}^K \delta_{ik} \sum_{p=1}^P \frac{\partial net_k}{\partial net_p} W_{mp} \left[\frac{-1}{a_m |\phi_{im}|} \cdot \sum_{t=0}^{T-1} \Psi'(t') C(t) t' \right] = -\sum_{i=1}^N \frac{[\sum_{t=0}^{T-1} t'(t^2 - 3)e^{-\frac{t'^2}{2}} C(t) t']}{a_m |\phi_{im}|} \cdot \sum_{k=1}^K (d_{ik} - y_{ik}) y_{ik} (1 - y_{ik}) \sum_{p=1}^P W_{pk} O_{ip} (1 - O_{ip}) W_{mp} \quad (9)$$

其中， $t' = \frac{t-b_m}{a_m}$ ，其中 $\delta_{ik} = -\frac{\partial E_i}{\partial net_k}$ ，

$$\delta_{ip} = -\frac{\partial E_i}{\partial net_k} \frac{\partial net_k}{\partial net_p}, t' = \frac{t-b_m}{a_m}$$

为了加快网络训练速度，分别对权值W，尺度因子a和位移因子b引入不同的学习步长 $\lambda_w, \lambda_a, \lambda_b$ ($\lambda_w = 0.01, \lambda_a = \lambda_b = 0.05$)。在第j次迭代结束后，按照下式修正网络参数，直到网络误差函数E小于 ϵ 时，整个训练停止。

$$W^{j+1} = W^j - \lambda_w \frac{\partial E}{\partial W}, a^{j+1} = a^j - \lambda_a \frac{\partial E}{\partial a}, b^{j+1} = b^j - \lambda_b \frac{\partial E}{\partial b} \quad (10)$$

2 实验结果

在本次实验中，我们对FERET人脸库、ORL人脸库和我们实验室自己建立的人脸库SEU进行

识别率测试. 其中每个库选取 40 人的 人脸图像, 每人 5 幅作为训练样本, 每人 5 幅用来测试识别率, 训练样本和测试样本没有交集, 每幅图像处于不同的光照, 不同表情, 不同姿态中. 实验的软件编译的环境是 Visual C++ 6.0.

具体仿真中, 例如对图 2 中第一人的小波神经网络进行设计的时候, 设定小波脊线的长度阈值 $L=1024$, 幅度阈值 $\alpha=0.75$. 这样, 确定下来的小波神经元个数为 16, 且每个小波神经元对应一条小波脊线, 提取其不同位移不同尺度下最显著的时频特征. 例如, 4 号小波脊线(如图 7)CWT 模的幅值-尺度函数分析可得: 当尺度 $a=53.82(b=3215)$ 时, 该小波脊线上 CWT 模取的最大值 14.17. 所以, 该小波脊线对应小波神经元的尺度因子和位移因子的初值分别为 $a=53.82, b=3215$.

对其子网进行训练时, 将 5 幅训练样本输入网络训练一次称为一个训练周期, 针对图 2 中第一人的神经网络训练时误差随着迭代次数的变化如图 8. 将每个人脸模式对应的小波神经网络整合在一起, 添加 Sigmoid 函数比较层, 就形成了基于紧致型小波神经网络的人脸识别系统.




图 8 网络误差函数随迭代次数变化情况

Fig. 8 Changing curve of E by iterative times

我们记录下来的每个小波神经网络的平均训练时间为 $4'46''$, 每个子网从人脸向量输入到输出层输出结果的平均时间为 0.005 s, 组合而成的人脸识别系统平均一幅人脸的识别时间为 0.228 s. 识别率的实验结果如表 1, 可以看出小波神经网络的识别性能明显优于用特征脸方法对相同人脸库进行的识别.

表 1 最近邻分类器和小波神经网络分类器的识别率比较

数据库	特征脸方法	小波神经网络	提高率
FERET	64.9%	80.9%	24.7%
ORL	90.1%	99.8%	10.8%
SEU	71.3%	87.2%	22.3%

3 结论

本文研究了基于连续小波变换的神经网络进行人脸识别的方法, 详细讨论了连续小波变换中小波基函数的选取, 根据连续小波变换的性质所决定的网络神经元个数的确定方法以及神经网络的初始化和参数训练方法. 通过对输入人脸灰度的连续小波分析, 神经网络能准确提取灰度奇异点处的时频特征; 通过自组织自学习的训练, 将连接权值和所有小波神经元的尺度、位移参数调整到最佳状态, 从而完成人脸识别的任务. 实验结果也验证了小波神经网络的识别性能明显优于用特征脸方法对相同人脸库进行的识别. 因此, 我们可以得出紧致型小波神经网络在人脸识别领域颇具应用潜力的结论.

参考文献

- Mallat S, Hwang W L. Singularity detection and processing with wavelets. *IEEE Trans Information Theory*, 1992, **38**(2): 617~643
- Grossmann A. Wavelet transform and edge detection. in stochastic processes in physics and engineering, Dordrecht: Reidel, 1986
- 何俊发, 赵选科, 王红霞, 等. 基于光学小波微分预处理联合变换相关目标识别. *光子学报*, 2002, **31**(12): 1538~1541
He J F, Zhao X K, Wang H X, et al. *Acta Photonica Sinica*, 2002, **31**(12): 1538~1541
- Mallat S, Zhong S. Wavelet transform maxima and multiscale edges. *Wavelets and their Applications*, Boston: Jones and Bartlett Publication, 1992
- 过润秋, 李大鹏, 林晓春, 等. 红外点目标检测的小波变换方法研究. *光子学报*, 2004, **33**(4): 464~468
Guo R Q, Li D P, Lin X C, et al. *Acta Photonica Sinica*, 2004, **33**(4): 464~468
- 刘卫光, 周利华. 基于小波概率估计的图像融合方法的研究. *光子学报*, 2004, **33**(2): 203~208
Liu W G, Zhou L H. *Acta Photonica Sinica*, 2004, **33**(2): 203~208

Face Recognition Using Neural Network Based on Continuous Wavelet Transform

Zhao Jing, Xia Liangzheng

Department of Automatic Control Engineering, Southeast University, Nanjing 210096

Received date: 2004-06-14

Abstract A face recognition method using neural network is proposed based on continuous wavelet transform. The theory of wavelet analysis is introduced. The method of selecting mother wavelet function is detailed according wavelet transform norm, and the number of wavelet knot and the initialization are decided by wavelet ridge. The training method of parameters is also introduced. Through continuous wavelet analysis and self-organizing and self-training of neural networks, the connection weights and the parameters of scales and positions are adapted to complete the task of face recognition. The test results shows that this method obtains much better performance in face recognition compared with the classical eigenface method.

Keywords Continuous wavelet transform; Face recognition; Module maxima; Wavelet ridge



Zhao Jing was born in 1978. She received her B. S. degree in Automatic Control Department of Southeast University in 2000. Now she is a doctoral candidate in Pattern Recognition & Intelligence System in Southeast University. Her research work focuses on neural network and computer vision techniques.