

基于最小分类误差小波特征的纺织品缺陷分类方法研究

杨学志 沈晶 殷保忠

(合肥工业大学计算机与信息学院,合肥 230009)

摘要 纺织品缺陷分类是利用计算机视觉技术检测纺织品品质的一个关键环节。提出了一种基于小波框架的纺织品缺陷分类新方法。该方法使用纺织品图像的小波框架来描述缺陷的纹理特征。在最小分类误差训练框架下,通过联合设计一个基于线性变换矩阵的特征提取器和一个分类器,来获取面向缺陷分类的小波框架特征,并最小化分类器的错误概率。该方法对包含9类纺织品缺陷的329个样本,以及328个无缺陷样本进行了分类实验评估,获得了93.1%的分类准确率,相比传统的基于小波变换的分类方法提高了27.2%。

关键词 纺织品自动检测 纺织品缺陷分类 小波框架 最小分类误差训练

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(2009)02-0309-08

Fabric Defect Classification Using Minimum-classification-error Based Wavelet Features

YANG Xue-zhi, SHEN Jing, YIN Bao-zhong

(Computer and Information Faculty Heifei University of Technology, Heifei 230009)

Abstract Fabric defect classification plays an important role in computer visionbased fabric quality inspection. In this paper, a novel defect classification method based on wavelet frames is proposed. Defects of texture properties are characterized using the wavelet frames. Minimum classification error training method is used to incorporate the design of a linear transform matrixbased feature extractor and a classifier, which yields classification-oriented wavelet features and minimizes the error rate associate with the classifier. The proposed method has been evaluated on the classification of 329 defect samples containing nine classes of fabric defects, and 328 non-defect samples. A 93.1% classification accuracy has been achieved which is 27.1% better than the traditional wavelet-based classification method.

Keywords fabric automatic detection, fabric defect classification, wavelet frame, Minimum classification error training

1 引言

现代纺织机器的进步已经极大地减少了产品中缺陷的数量,但离100%的纺织品无缺陷仍有较大距离^[1]。各种类型缺陷的存在,严重影响了纺织品的完整和美观,进而影响了企业的效益和顾客的满意度。目前,纺织品缺陷的检验主要依赖于人工肉

眼判别,其检验结果很大程度上依赖于检验员的经验、判断力和注意力。随着图像处理和计算机视觉技术的快速发展,现代纺织工业正在向纺织品自动视觉检验(FAVI)转变,以期获得对产品快速准确的评估。

目前已开发的FAVI系统能够实现纺织品缺陷检测,即判断出产品中是否存在缺陷,并且对缺陷的影响区域进行定位。然而,纺织品缺陷分类,却仍是

基金项目:国家自然科学基金项目(60672120)

收稿日期:2008-07-08;改回日期:2008-09-28

第一作者简介:杨学志(1970~),男,副教授。2003年于香港大学电机与电子工程学系获博士学位,2006年8月至2007年10月在滑铁卢大学系统设计工程系视觉与图像实验室从事博士后研究。主要研究方向为计算机视觉。E-mail:yang_xuezhi@gmail.com

一个有待研究的技术难题。织物缺陷分类的重要性在于不同种类织物缺陷的产生原因和影响(严重性)各不相同,因此,相比检测过程中获得的较为笼统的缺陷数量总和,分类过程生成的缺陷统计量能够对纺织品品质提供更为全面的评估,并且能揭示出纺织机器中存在的问题。

根据缺陷特征的不同,现有的缺陷分类方法可分为两类。第 1 类是基于缺陷形状特征的分类方法^[2-3]。Brzakovic 等人通过对织物图像进行表层投射^[2],提取了缺陷的形状特征(圆度,方向性和整体形状),并利用这些特征实现了均匀织物的缺陷分类。基于已检测到的缺陷区域,Bradshaw 计算了缺陷区域的面积以及宽度与高度的比例^[3],然后依据这些特征量对针织物中的缺陷进行分类。形状特征可以用来实现对缺陷粗略的分类,例如水平缺陷、垂直缺陷和区域缺陷,然而这类特征的鉴别力是有限的,无法将缺陷细分到各自原属的种类。第 2 类方法是基于纺织品图像纹理特征的分类方法。纺织品生产过程的固有特点造就了纺织品图像规则的周期纹理式样,而各种纺织品缺陷会局部地改变原有纹理,得到不同类型的缺陷纹理。因此,纺织品缺陷分类可以视为纹理分类问题来处理。基于这样的观点,自相关函数^[4]、局部积分^[5]以及灰度级差分方法^[6]等一系列统计方法被用来分析缺陷的纹理特征,并在此基础上进行缺陷纹理分类。纹理分析途径从纺织品图像及其缺陷的本质特性入手,为实现缺陷的准确分类提供了可能。对于这一途径,一个关键性因素是提取能够有效辨别各种缺陷纹理的特征。

本文提出了一种基于纹理分析途径的缺陷分类新方法。为解决缺陷纹理辨别性特征提取这一核心问题,该方法首先采用小波框架变换^[7]对纺织品图像进行分解,获得图像在不同尺度和不同方向上的特征表示。相比单一尺度下的纹理分析,基于小波框架的多尺度表示能够更加全面地描述图像的纹理特性,从而对不同缺陷纹理间的差异具有更强的辨别能力。其次,通过采用最小分类误差(MCE)训练方法^[8],联合设计基于线性变换矩阵的特征提取器和分类器,来获取与缺陷分类目标一致的辨别性小波框架特征。本文提出的方法进一步解决了现有缺陷分类系统中特征提取器和分类器之间联系松散、缺乏恰当相互作用的问题,使得特征提取器和分类器在最小化分类错误率的同一目标下得以优化,从

而提高了系统的整体分类性能。通过对包含 9 类纺织品缺陷的 329 个样本以及 328 个无缺陷样本进行分类测试评估,本文所提出的方法达到了 93.1% 的分类准确率,相比传统的基于小波变换的分类方法,准确率提高了 27.2%。

2 基于最小分类误差和小波框架的纺织品缺陷分类

纺织品缺陷尺寸各异,且大部分缺陷仅占据纺织品图像相对较小的一部分。为了对缺陷进行准确定位,纺织品图像被划分成尺寸为 $N \times N$ 的无重叠图像窗,然后对每个图像窗进行分类。图 1 给出了本文所提出的纺织品缺陷分类方法框图。缺陷分类过程包括特征提取和分类两部分。在特征提取单元中,首先采用小波框架变换将纺织品图像在多尺度和多方向上(统称子带)进行分解,然后在每个子带内,估计图像窗对应的小波系数的子带方差,并将所有子带方差组成一个特征向量来描述图像窗的纹理特性。在此基础上,通过一个线性变换矩阵来提取适用于缺陷分类的小波框架特征。在分类单元中,采用了一组基于欧氏距离相似性度量的判别式函数来实现特征向量的类别划分。图 1 中虚线标示部分给出了 MCE 训练方法的框架。该方法是基于一组训练样本的分类结果,通过定义一个与分类错误概率相一致的代价值来评价缺陷分类方法的性能。进一步,基于优化方法通过联合调节线性变换矩阵系数和分类器参数来最小化分类代价值,从而实现分类方法错误率最小化。

2.1 基于小波框架的纺织品纹理特征提取

与通常使用的正交小波变换相比,小波框架分解去除了输出端的临界采样过程,以分解结果的冗余性为代价,获得了具有平移不变性的信号表示,并且使小波基底的选取也有更多的自由度^[9]。这两个特点使得小波框架分解能更好地满足模式识别应用的需要。

假定 $I(x, y)$ 表示一幅纺织品图像,其中 (x, y) 为空间坐标, $H(z)$ 和 $G(z)$ 分别表示小波框架分解中低通滤波器和高通滤波器的 Z 变换。 $I(x, y)$ 在第 r 尺度上沿着对角,水平和垂直方向上的小波框架分解系数 $\{W_r^1(x, y), W_r^2(x, y), W_r^3(x, y)\}$ 以及残余 $R_r(x, y)$ 可分别通过如下的滤波器组获得:

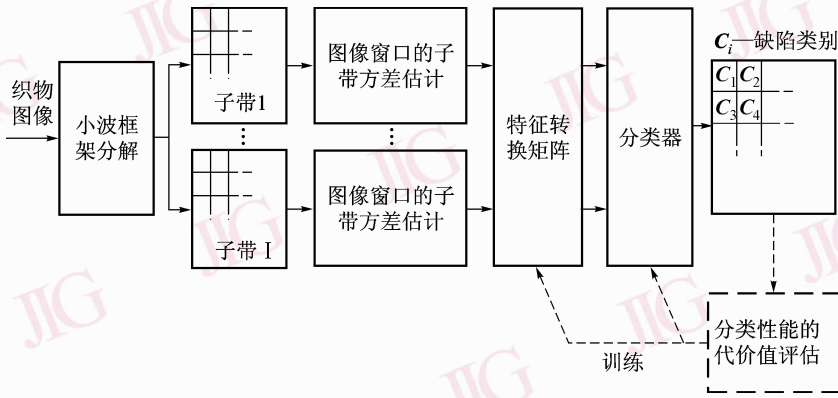


图1 本文提出的纺织品缺陷

Fig. 1 The proposed fabric defect classification method

$$\begin{aligned}
 V_r^1(z_1, z_2) &= H_r(z_1, z_2) G(z_1^{2^{r-1}}) G(z_2^{2^{r-1}}) \\
 V_r^2(z_1, z_2) &= H_r(z_1, z_2) H(z_1^{2^{r-1}}) G(z_2^{2^{r-1}}) \\
 V_r^3(z_1, z_2) &= H_r(z_1, z_2) G(z_1^{2^{r-1}}) H(z_2^{2^{r-1}}) \\
 V_r^4(z_1, z_2) &= H_r(z_1, z_2) H(z_1^{2^{r-1}}) H(z_2^{2^{r-1}}) \\
 &r = 1, \dots, K
 \end{aligned} \quad (1)$$

式中,

$$\begin{aligned}
 H_r(z_1, z_2) &= \prod_{k=0}^{r-2} H(z_1^{2^k}) H(z_2^{2^k}) \\
 &r = 2, \dots, K; H_1(z_1, z_2) = 1
 \end{aligned}$$

K 表示小波框架分解的深度。

基于小波框架的纹理图像分类研究表明^[7], 子带小波系数方差能够有效地辨别不同种类纹理之间的差异。因此, 在纺织品图像的小波框架表示基础上, 采用了图像窗对应的子带方差来描述不同种类纺织品缺陷以及无缺陷纺织品的纹理特征。对应于纺织品图像中的每个窗口, 其子带方差为窗口中小波系数的平均能量^[7], 如式(2)所示:

$$w_r^d = \text{Mean}_{(x,y) \in \text{窗口}} [W_r^d(x,y)]^2 \quad d=1,2,3, \quad (2)$$

小波框架分解结果的所有子带方差组成了一个描述图像窗纹理特性的 D 维特征向量:

$$\mathbf{F} = [w_1^1, w_1^2, w_1^3, \dots, w_k^1, w_k^2, w_k^3] \quad (3)$$

式中, 维数 D 等于 $3K$ 。

上述的图像纹理特征提取过程并未考虑到后端分类过程的特性, 导致了式(3)中所提取的特征向量 \mathbf{F} 与具体采用的分类器不匹配, 进而影响到分类方法的整体性能。为解决这一问题, 本文进一步采用了一个 $D \times D$ 大小的线性变换矩阵 $\mathbf{U} =$

$\{U_{ij}\}, 1 \leq i, j \leq D$ 来对原始小波框架特征 \mathbf{F} 进行转换, 目的在于提取面向分类过程的小波框架新特征 $\mathbf{V} = \mathbf{U}\mathbf{F}$ 。

2.2 分类算法

基于纺织品图像窗的小波框架特征向量 \mathbf{V} , 本文通过特征向量的欧氏距离来衡量其相似性, 并由此定义一组判别式函数来进行特征向量分类。判别式函数 $g_l(\mathbf{F}, \mathbf{T})$ 的定义如下:

$$\begin{aligned}
 g_l(\mathbf{F}; \mathbf{T}) &= \|\mathbf{V} - \mathbf{m}_l\|^2 = \sum_{i=1}^D (V_i - m_{li})^2 \\
 &= \sum_{i=1}^D \left(\sum_{j=1}^D U_{ij} F_j - m_{li} \right)^2 \\
 &l = 1, \dots, J
 \end{aligned} \quad (4)$$

式中, $l=1, \dots, J-1$ 代表 $J-1$ 类缺陷, $l=J$ 代表无缺陷类。 $\mathbf{A} = \{\mathbf{m}_l\}, l=1, \dots, J$ 包含了每一类别的参考向量, $\mathbf{T} = \{\mathbf{U}, \mathbf{A}\}$ 表示特征提取器和分类器中的可调节参数集。 V_i, m_{li} 和 F_j 分别表示 \mathbf{V}, \mathbf{m}_l 和 \mathbf{F} 的第 i 个和第 j 个分量。

式(4)的理论依据是根据欧氏距离来衡量特征向量间的相似性, 并以此作为类别的判别式函数, 假设一个样本对应的特征向量为 \mathbf{F} , 如果判别式函数 $g_q(\mathbf{F}; \mathbf{T})$ 在某类取得最小值, 则表明特征向量 \mathbf{F} 与该类相似度最大, 进而被划分到该类。

基于上述判别式函数的分类判决准则为 $\mathbf{F} \in \mathbf{C}_q$, 当

$$q = \arg \min_l g_l(\mathbf{F}; \mathbf{T}) \quad (5)$$

时, 即如果判别式函数 $g_q(\mathbf{F}; \mathbf{T})$ 在所有类中取得最小值, 则特征向量 \mathbf{F} 对应的图像窗被分到第 q

类 C_q 。

2.3 基于 MCE 训练方法的特征提取器和分类器的设计

MCE 训练方法是由 Juang 等人提出的一种基于判别训练的分类器设计方法^[10]。该方法定义了一个与分类器判决准则相一致的目标函数,并采用梯度下降算法调节分类器的参数来最小化目标函数,实现最小错误率的分类器设计。为了使分类系统的特征提取器和分类器获得恰当的相互作用, Biem 等人和 Watanabe 等人从分类系统的整体设计出发,将 MCE 训练方法从后端分类器延伸到前端特征提取器^[11-12],为面向分类性能的特征提取器设计提供了新途径。相比传统途径, MCE 方法在语音识别^[11,13]和字符识别^[14-15]等模式分类应用中获得了更高的分类准确率。

本文采用了 MCE 训练方法来联合设计基于小波框架的特征提取器和基于判别式函数的分类器,达到纺织品缺陷分类错误率最小化的目的。在图 1 所示的缺陷分类中,特征提取器中,可调节的参数为线性变换矩阵 U ,基于欧氏距离的判别式函数分类器中,可调节的参数为参考向量集 A 。缺陷分类系统的总体可调整参数集为 $T = \{U, A\}$,其 MCE 训练的实现过程如下^[8,13]。

假定有 N 个训练样本 $F = \{F^{(n)}\}, n = 1, \dots, N$,且每个样本的所属类别已标注。根据本文采用的分类器及判决准则,对每个训练样本 $F^{(n)}$ 定义如下:

分类误差度量:

$$d_n = 1 - \frac{\left[\frac{1}{J-1} \sum_{p \neq q} (g_p(F^{(n)}; T))^{-\eta} \right]^{-1/\eta}}{g_q(F^{(n)}; T)} \quad (6)$$

$F^{(n)} \in C_q$

式中, $\eta > 0$,用来控制当前训练样本所属类 C_q 之外其他类别在分类误差度量中所占比重。分类误差度量 d_n 是根据 Bayes 理论的最小分类错误概率,并结合基于判别式函数的分类方法提出的^[10]。相比现有其他分类误差度量,如最小均方误差, d_n 的定义与分类准则更加一致,从而式(5)及式(6)能更准确地度量相应的分类误差。

当 η 趋向于 $+\infty$ 时,分类误差度量简化为

$$d_n = 1 - \frac{g_{p_min}(F^{(n)}; T)}{g_q(F^{(n)}; T)} \quad (7)$$

式中,

$$p_min = \arg \min_{p, p \neq q} g_p(F^{(n)}; T) \quad (8)$$

由式(5)中的分类判决准则可知,当正确分类时, $g_{p_min}(F^{(n)}; T) \geq g_q(F^{(n)}; T)$,所以 $d_n \leq 0$ 表明一个正确的分类,而当错误分类时, $g_{p_min}(F^{(n)}; T) < g_q(F^{(n)}; T)$,所以 $d_n > 0$ 则表明了一个错误的分类,当某参数集 T 使得 $g_{p_min}(F^{(n)}; T)$ 为 0 或充分接近 0 时, $d_n \approx 1$,达到其最大值,表明对当前样本被错误分类的可能性极大。通过采用与分类决策准则相一致的描述方式, d_n 衡量了样本 $F^{(n)}$ 被错误分类的可能性。

为使梯度优化算法适用于分类错误率的最小化过程, MCE 在分类误差度量的基础上进一步定义了一个代价函数来评价分类方法在训练样本 $F^{(n)}$ 上的分类性能。该代价函数通常采用 sigmoid 函数将分类误差度量 d_n 转换为在 $[0, 1]$ 区间连续可微形式:

$$l_n = \frac{1}{1 + e^{-\alpha d_n}} \quad (9)$$

式中, $\alpha > 0$ 。对于整个训练样本集 F ,其对应的平均代价值为

$$L = \frac{1}{N} \sum_{n=1}^N l_n \quad (10)$$

最后,通过调节参数集 $T = \{U, A\}$ 来最小化式(10)中定义的平均代价值,从而完成了特征转换矩阵的设计及分类器的训练,实现了缺陷分类错误率最小化。在 MCE 训练中,一般使用最陡梯度下降梯度法来最小化平均代价值。为加速优化过程,本文采用了 Quasi-Newton 优化方法^[16]。该优化方法需要计算平均代价值 L 相对于参数集 $T = \{U, A\}$ 的梯度,具体的推导如下:

$$\frac{\partial L}{\partial U_{ij}} = \frac{1}{N} \sum_{n=1}^N \frac{\partial l_n}{\partial U_{ij}} = \frac{1}{N} \frac{\alpha e^{-\alpha d}}{[1 + e^{-\alpha d}]^2} \sum_{n=1}^N \frac{\partial d_n}{\partial U_{ij}} \quad (11)$$

$$\frac{\partial L}{\partial m_l} = \frac{1}{N} \frac{\alpha e^{-\alpha d}}{[1 + e^{-\alpha d}]^2} \sum_{n=1}^N \frac{\partial d_n}{\partial m_l} \quad (12)$$

式中,

$$\frac{\partial d_n}{\partial U_{ij}} = \frac{2 \left[\frac{1}{J-1} \sum_{p \neq q} g_p(F^{(n)}; T)^{-\eta} \right]^{-1/\eta}}{g_q(F^{(n)}; T)} \times$$

$$\left[\frac{(V_i^{(n)} - m_{qi})}{g_q(\mathbf{F}^{(n)}; \mathbf{T})} - \frac{\sum_{p \neq q}^J g_p(\mathbf{F}^{(n)}; \mathbf{T})^{-\eta-1} (V_i^{(n)} - m_{pi})}{\sum_{p \neq q}^J g_p(\mathbf{F}^{(n)}; \mathbf{T})^{-\eta}} \right] \cdot F_j^{(n)} \quad (13)$$

$$\frac{\partial d_n}{\partial m_l} = \begin{cases} 2 \left\{ \frac{1}{J-1} \sum_{p, p \neq q} g_p^{-\eta} \right\}^{-1/\eta} \frac{(m_l - V^{(n)})}{g_q^2} & l = q \\ \frac{2}{1-J} \frac{\left\{ \frac{1}{J-1} \sum_{p, p \neq q} g_p^{-\eta} \right\}^{-1/\eta-1} g_p^{-\eta-1}}{g_q} (m_l - V^{(n)}) & l \neq q \end{cases} \quad (14)$$

式中, V 表示经过线性矩阵转换的小波框架特征。 n 是样本的索引, 表示第 n 个样本。

3 实验评价

3.1 数据采集

本文采用了普通斜纹织物中存在的 9 种典型纺织品缺陷(如图 2 所示)对所提出的缺陷分类方法进行实验, 其中没有缺陷的纺织品被划分到无缺陷类。实验中共采集了含有 9 种缺陷的 83 幅的纺织品图像, 每幅图像尺寸为 256×256 , 被划分为 32×32 的无重叠图像窗。42 幅纺织品图像被用于训练, 其中有缺陷图像窗样本数和无缺陷图像窗样本数均为 336; 另外的 41 幅纺织品图像被用于测试, 其中有缺陷图像窗样本数为 329, 无缺陷图像窗样本数为 328。

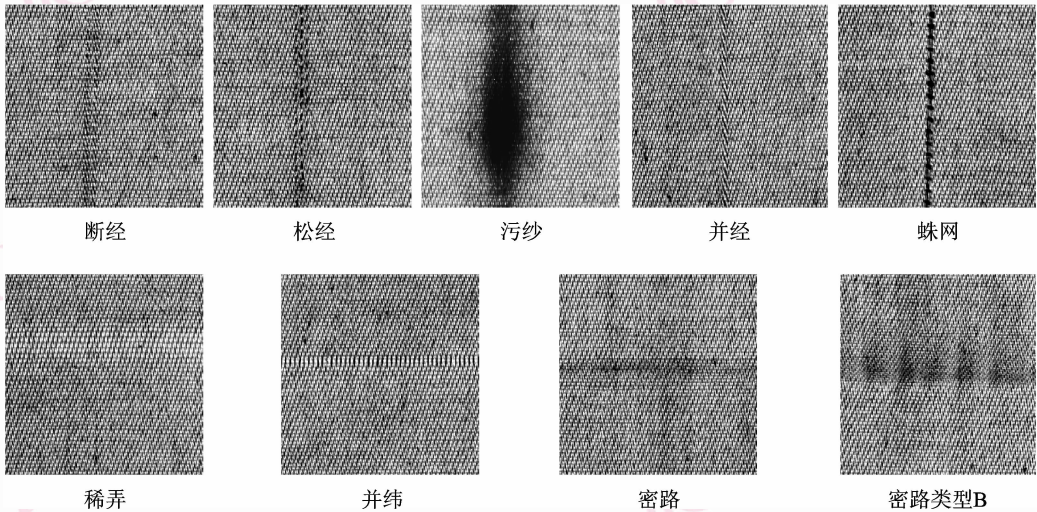


图 2 包含缺陷的纺织品图像
Fig. 2 Fabric images containing defects

3.2 评价条件

(1) 小波基的选择

在小波框架分解中, 小波基的选择决定了小波滤波器 $H(z)$ 和 $G(z)$ 。在实验评价中选取了 Haar 小波基。该小波具有良好的空间局部化特性, 在纹理分类的研究中显现出优于其他常用小波基的纹理辨别能力^[7]。

(2) 小波框架的分解深度

随着小波框架分解深度的增加, 特征向量 F 将包含更多的图像子带特征。在评价中, 分解深度设定为 3 级, 即图像在 3 个尺度和 3 个方向上共 9 个小波框架子带特征被用于缺陷分类。

(3) MCE 训练中 η 和 α 的选择

在分类误差度量 d_n 的定义中, 参数 η 被用来控制当前类之外其他类所占权重。在代价函数 l_n 的定义中, 参数 α 用来调节训练样本分类结果对应的代价值。为了评价 η 和 α 对分类方法性能的影响, 实验中采用了不同的 η 值和 α 值进行 MCE 训练, 其相应的分类性能如图 3 所示。从图 3 可以看出, 在 η 值固定的情况下, α 值为 5 时其对应的分类准确率要优于其他 α 值。当 α 值取 5, η 值取 10 时获得了最好的分类性能。

(4) 不同窗口尺寸的影响

小波框架特征是从纺织品图像的每个无重叠的

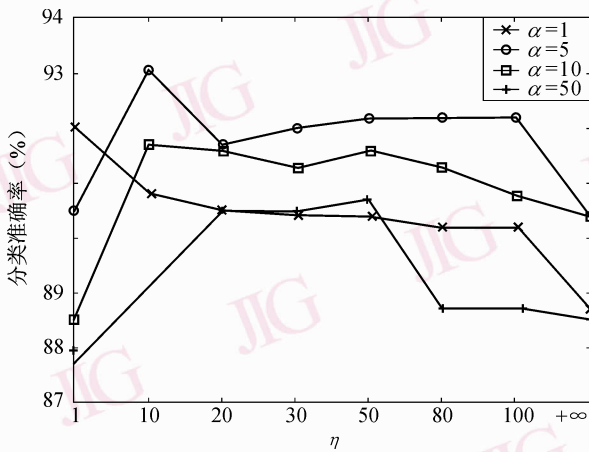


图 3 基于 MCE 训练方法的 η 和 α 对缺陷分类性能的影响

Fig. 3 The effect of η and α on the performance of the defect classification using the MCE training method

图像窗提取的,因此,窗口尺寸的选择影响到缺陷分类中小波框架的辨别力。一个合适的窗口尺寸应该能很好地保持纺织品图像中缺陷及无缺陷区域的纹理特性。实验中分别对尺寸为 16×16 , 32×32 和 64×64 的图像窗采用本文提出的方法进行分类,相应的测试样本的分类准确率如表 1 所示。从表 1 中的结果可知, 32×32 的窗口尺寸为最佳选择。

表 1 图像窗口尺寸对缺陷分类性能的影响

Tab. 1 The effect of window size on the performance of defect classification 单位:%

窗口尺寸	分类结果
16×16	90.9
32×32	93.1
64×64	87.7

(5) MCE 训练中参数的初始化

MCE 训练过程采用了梯度下降优化方法,需要对参数集 $T = \{U, A\}$ 进行初始化。对于线性变换矩阵 U ,实验中初始化为单位矩阵。在此基础上,先通过最大似然估计(使用了同类样本的平均向量)计算参考向量 A ,并进一步采用 MCE 方法训练分类器,获得与初始转换矩阵 U 相对应的初始参考向量 A 。

3.3 评价结果

实验中特征提取器和分类器的 MCE 训练过程被分为 3 个步骤,在每一步给出了其分类性能的评价结果。

(1)用单位矩阵对转换矩阵 U 进行初始化,并通过最大似然估计计算分类器的参考向量 A ,即同类样本的平均向量。

(2)对分类器参考向量 A 进行 MCE 训练。

(3)对整体参数集 $T = \{U, A\}$ 进行 MCE 训练。

MCE 训练过程的学习曲线如图 4 所示,对应于上述过程的每一步,表 2 给出了相应的训练样本和测试样本的分类准确率。如表中所示,步骤(1)使用同类样本平均向量作为分类器参考向量导致了较差的分类性能,表明这一常用的分类器参数估计方法会引起了较大的分类判决偏差。在步骤(2),由于使用了 MCE 训练,分类器参考向量引起的判决偏差得到了纠正,使得测试样本的分类准确率提高了 19.1%。在步骤(3),MCE 训练方法在最小化分类错误率的目标下对特征转换矩阵和分类器进行了联合设计。该设计方法进一步提取了面向分类的小波框架特征,并且使特征提取器和分类器之间达到恰当的相互作用,从而使测试样本的分类准确率进一步提高了 8.1%。

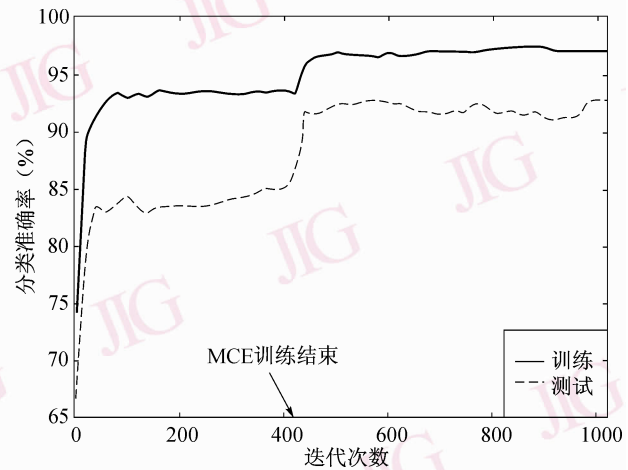


图 4 MCE 训练的学习曲线

Fig. 4 Learning curves of MCE training

表 2 基于 MCE 训练的缺陷分类结果

Tab. 2 Classification performance in the MCE training 单位:%

MCE 训练步骤	分类结果	
	训练样本	测试样本
步骤(1)	73.3	65.9
步骤(2)	93.6	85.0
步骤(3)	97.1	93.1

对应于 93.1% 的总体分类准确率,表 3 中给出了对每一缺陷类及无缺陷类的详细分类准确率。从表 3 中数据可知,对“并经”类缺陷的分类性能是不理想的,这是因为该类缺陷对 Haar 小波的响应较弱。对此,可以通过专门对“并经”类缺陷设计一种小波基^[17]来提高分类的性能。同样,小波包结构^[18]也可来进行特征提取,提高对“并经”类缺陷

的分类性能。使用本文中设计的特征提取器和分类器,图 5 描述了图 2 中所示的纺织品图像的分类结果。在图 5 中,黑色区域表示被正确分类的图像窗,灰色区域表示被错误划分到有缺陷类的图像窗,白色区域表示被分到无缺陷类的图像窗。在密路类型 B 缺陷的分类中,该缺陷区域的边缘被划分到密路类型中,这是由这两类缺陷的相似性而导致的。

表 3 每一类缺陷的分类结果

Tab. 3 Classification performance of each class

单位:%

缺陷类	断经	松经	污纱	并经	蛛网	稀弄	并纬	密路	密路类型 B	无缺陷	总体
分类结果	100	100	88.8	46.8	75.0	100	100	78.5	100	96.0	93.1




图 5 图 2 所示纺织品图像的分类结果

Fig. 5 Classification results of the fabric images shown in Fig. 2

同其他缺陷分类研究工作的结果相比,Brzakovic 等人对均匀织物的分类准确率为 85%^[2],Bradshaw 等人对 4 种缺陷(分别为垂直、水平、局部、粗纺线)进行的分类中得到了相同的分类准确率^[3]。Tolba 等人尽管在分类实验中得到了 100% 的准确率^[4],但这个结果只是针对 3 种类型(垂直、水平和区域缺陷)进行的,并且只使用了 22 个测试样本。Karayiannis 等对于 8 类缺陷(亮色垂直、黑色垂直、亮色水平、黑色水平、亮色区域、黑色区域、皱纹和无缺陷)的分类达到了 85% 的准确率^[6],但是没有提到测试样本的数量。

本文方法与传统方法相比,其运算复杂度上的差异主要在于训练过程。由于本文采用了基于 Quasi-Newton 的快速优化方法,使得 MCE 训练方法相比传统的最大似然估计训练方法运算复杂度上的

增加相当有限。而当训练过程结束后,实际分类测试时运算复杂度的增加很小,可以忽略。

4 结 论

纺织品缺陷分类是纺织品自动视觉检验的关键环节也是目前的难点所在。本文对此提出了一种新的解决方法。该方法基于小波框架变换和最小分类误差训练框架,通过联合设计一个基于线性变换矩阵的特征提取器和一个分类器,来获取面向缺陷分类的小波框架特征,并使特征提取器和分类器之间达到恰当的相互作用,从而达到最小化分类错误率的目标。实验评价结果表明,本文提出的分类方法相比现有方法在分类准确率上有较大的提高。

参考文献 (References)

- 1 Srinivasan K, Dastor P H, Radhakrishnaihan P, *et al.* FDAS: A knowledge-based frame detection work for analysis of defects in woven textile structures [J]. *Journal of Textile Institute*, 1992, **83**(3): 431-447.
- 2 Brzakovic D, Vujovic N. Designing a defect classification system: a case study [J]. *Pattern Recognition*, 1996, **29**(8): 1401-1419.
- 3 Bradshaw M. The application of machine vision to the automated inspection of knitted fabrics [J]. *Mechatronics*, 1995, **29**(8): 233-243.
- 4 Tolba A S, Abu-Rezeq A N. A self-organizing feature map for automated visual inspection of textile products [J]. *Computers in Industry*, 1997, **32**(3): 319-333.
- 5 Rohrmus D. Invariant web defect detection and classification system [A]. In: *Proceedings of IEEE International Conference on CVPR* [C], Hilton Head, SC, USA, 2000: 794-795.
- 6 Karayiannis Y A. Defect detection and classification on web textile fabric using multiresolution decomposition and neural networks[A]. In: *Proceedings of IEEE International Conference on Electronics, Circuits and Systems* [C], Blacksburg, Virginia, USA, 1999: 765-768.
- 7 Unser M. Texture classification and segmentation using wavelet frames[J]. *IEEE Transactions on Image Processing*, 1995, **4**(11): 1549-1560.
- 8 Katagiri S, Juang B H, Lee C H. Pattern recognition using a family of design algorithms based upon the generalized probabilistic descent method[J]. *Proceedings of the IEEE*, 1998, **86**(11): 2345-2373.
- 9 Cvetkovic Z, Vetterli M. Oversampled filter banks [J]. *IEEE Transactions on Signal Processing*, 1998, **45**(5): 1245-1255.
- 10 Juang B H, Katagiri S. Discriminant learning for minimum error classification[J]. *IEEE Transactions on Signal Processing*, 1992, **40**(12): 3043-3054.
- 11 Biem A, Katagiri S, Juang B H. Pattern recognition based on discriminative feature extraction [J]. *IEEE Transactions on Signal Processing*, 1997, **45**(2): 500-504.
- 12 Watanabe H, Yamaguchi T, Katagiri S. Discriminant metric design for robust pattern recognition [J]. *IEEE Transactions on Signal Processing*, 1997, **45**(11): 2655-2662.
- 13 Paliwal K K, Bacchiani M, Sagisaka Y. Simultaneous design of feature extractor and pattern classifier using the minimum classification error training algorithm[A]. In: *Proceedings of IEEE Workshop on Neural Networks for Signal Processing* [C], Cambridge, MA, USA, 1995: 67-76.
- 14 Tasy K M, Shyu H K, Chang H P. Feature transformation with generalized learning vector quantization for handwritten Chinese character recognition [J]. *IEICE Transactions on Information and Systems*, 1999, **E82-D**(3): 687-692.
- 15 Huo Q, Ge Y, Feng Z. High performance chinese OCR based on Gabor features, discriminative feature extraction and model training [A]. In: *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing* [C], Salt Lake City, Utah, USA, 2001: 1517-1520.
- 16 Fletcher R. *Practical Methods of Optimization*[M]. New York, USA: Wiley, 1987:35-40.
- 17 Yang X, Pang G, Yung N. Discriminative fabric defect detection using adaptive wavelet [J]. *Optical Engineering*, 2002, **41**(12): 3116-3126.
- 18 Laine A, Fan J. Frame representations for texture segmentation[J]. *IEEE Transactions on Image Processing*, 1996, **5**(5): 771-780.