DOI: 10.19650/j.cnki.cjsi.J1905194

基于局部二值差异激励模式的木材缺陷分类*

李绍丽^{1,2},苑玮琦^{1,2},杨俊友¹,李德健^{1,2}

(1. 沈阳工业大学 沈阳 110870; 2. 辽宁省机器视觉重点实验室 沈阳 110870)

摘 要:针对木板表面裂缝和矿物线的区分问题,提出一种基于局部二值差异激励模式(LB_DEP)的方法。首先经预处理分割 潜在缺陷区域,然后通过几何参数筛选呈线状的裂缝和矿物线。接着基于 LBP 与韦伯定律,建立反映图像纹理结构位置与差 异激励关联关系的 LB_DEP 直方图。最后提取 LBP 和 LB_DEP 直方图特征,并融合特征数据,形成的特征向量作为 SVM 分类 器的输入用于缺陷分类。提出的两种特征提取方法分别为"H-chi-square"法和"H-PCA"法,均在自建的数据集上进行了评估。 结果显示,在两种特征提取方法下,本文算法分别获得了 93.7% 和 95.8% 的 Recall,及 95.0% 和 96.5% 的 Precision。与相似研究 相比,Recall 和 Precision 分别至少提高了 3% 和 5%,且算法耗时均为毫秒级别,表现出方法的优势和有效性。 关键词:木材缺陷;裂缝;特征提取;局部二值差异激励模式;SVM

中图分类号: TP391.41 TH165 文献标识码: A 国家标准学科分类代码: 510.40

Wood defect classification based on local binary difference excitation pattern

Li Shaoli^{1,2}, Yuan Weiqi^{1,2}, Yang Junyou¹, Li Dejian^{1,2}

(1.Shenyang University of Technology, Shenyang 110870, China;2.Key Laboratory of Machine Vision, Liaoning Province, Shenyang 110870, China)

Abstract: Aiming at the problem of distinguishing split defects from mineral lines on the wood surface, a method based on local binary difference excitation pattern (LB_DEP) is proposed. Firstly, the potential defect regions are segmented with image pre-processing, then linear split and mineral line are screened using geometric parameters. Based on local binary pattern (LBP) and Weber's law, an LB_DEP histogram reflecting the correlation relationship between image texture structure positions and difference excitation is established. Finally, the histogram features of LBP and LB_DEP are extracted, which are fused with feature data to form the feature vector that is used as the input of the SVM classifier to classify defects. Two feature extraction methods are proposed, namely 'H-chi-square' and 'H-PCA', which are both evaluated on the self-built data set. The experiment results show that for the two feature extraction methods the recall rates of 0.937 and 0.958, as well as the precision of 0.950 and 0.965 are obtained, respectively. Compared with other similar researches, the recall rate and precision are improved by at least 3% and 5%, respectively, and the time consumption is also at the level of milliseconds, which indicates the advantages and effectiveness of the proposed method.

Keywords: wood defect; split; feature extraction; local binary difference excitation pattern; SVM

0 引 言

木材强度对于木制产品而言具有至关重要的作用, 而木材缺陷会对木材强度产生不良的影响,尤其是裂缝 缺陷。裂缝是木材表面较为严重的一种缺陷,它改变了 木材的物理结构、影响其力学性质,对木材的韧性和抗冲 击性影响较大,严重危害木制品的质量、安全性和使用寿 命,因此成为木材缺陷检测中至关重要的内容。

目前大部分的木材缺陷检测任务都是由经过训练的 人类专家完成的。然而这种识别方法将会导致观察者眼 睛疲劳,进而导致缺陷检测的低效率和低可靠性。因此, 关于木材无损检测的自动化方法研究逐渐开展起来,而 其中基于可见光的机器视觉法由于具有便捷、可重复性

收稿日期:2019-05-27 Received Date:2019-05-27

^{*}基金项目:国家自然科学基金项目(61271365)资助

高、价格低廉等优点,成为木材缺陷检测和分类领域应用 最为广泛的方法^[1-2]。目前很多学者已经基于可见光机 器视觉法对木材裂缝缺陷检测及与其他缺陷分类相关的 内容进行了大量研究,但是鲜少有方法被用来区分裂缝 和矿物线这两种缺陷,而是将大部分的注意力都集中在 裂缝的检测及与其他类间特征较为明显的缺陷(如节 子)的分类上。如文献[3]使用基于 PCA 和压缩感知的 方法对裂缝、活节和死节进行识别。其中包括几何特征、 纹理特征和不变矩特征^[4]的多维特征向量被提取出来用 于训练。文献[5]在文献[3-4]的基础上提出使用线性 判别式分析和压缩感的方法识别裂缝、活节和死节。 Chang 等首先利用凸优化法进行图像平滑,然后利用 Otsu 分割缺陷区域,进而提取几何和颜色的多维特征作 为分类器的输入,以实现裂缝与3种节子缺陷的检测和 分类^[6]。文献[7]针对板材虫眼、节子、裂缝、变色和腐 朽的识别问题提出的基于无监督聚类的方法。其首先分 别在 R、G、B 三个色彩空间下提取木材图像的一、二、三 阶矩,然后采用 K-means 方法聚类特征数据集从而识别 缺陷。然而该方法仅对节子的效果较好,对其它缺陷的 查全率仅为 57.1%^[7]。而后 2010 年又提出利用灰度共 生矩阵的 5 个典型特征代替颜色矩特征的方法^[8]。 Hittawe^[9]针对节子和裂缝的检测问题,对图像上的某一 子区域,首先进行图像对比度增强、熵最大化和中值滤波 三项预处理操作,然后提取 LBP 和 SURF 特征,最后输入 给 SVM 分类器,进而实现缺陷分类和检测。除上述文献 之外,少部分文献研究了裂缝和矿物线的分类问题,但是 并未考虑闭合紧实的呈暗色条纹状的裂缝,而是针对开 裂严重、通透的白色裂缝进行的研究。包括, Shnhnorbanun 等^[10]针对裂缝、矿物线等11种缺陷及与正 常表面分类的问题提出的一种基于 S-LVQ 网络的方法。 该方法共提取了 17 个灰度特征^[11]作为 S-LVO 分类器的 输入。但该研究中只考虑了板材上下通透的因透光而呈 亮白色的严重裂缝,而并没有对闭合的呈暗色的裂缝加 以考虑。文献[12]提出了一种前馈人工神经网络的方 法,而研究对象同样为文献[10]中的11种缺陷。

综合当前研究工作可见,其或者是只针对暗色裂缝的检测以及与节子等类间差异较大的缺陷的分类问题进行的研究,或者是对白色透亮的裂缝与矿物线分类问题进行的研究。而并没有关注暗色裂缝与矿物线的分类问题,然而将两者混淆可能会产生严重的不良后果。如图1所示,为用于制作医用压舌板而加工而成的桦木薄板,图1(a)标注的是桦木加工为薄板过程中而产生的裂缝缺陷,图1(b)标注的是桦木在树木生长过程中由于矿物质沉积而形成的矿物线缺陷。可见两者在几何形态、灰度和颜色等图像特征上的表现十分相似,均呈细长的条状、灰度相对于木板表面低,且呈近似褐色。然而对于压

舌板而言,裂缝极易造成使用者口舌的划伤,因此需要严格检测并剔除,而矿物线作为木材的天然纹理只影响美观度,是无需剔除的。因此若将裂缝误识别为矿物线,则 会导致人身伤害,而将矿物线误识别为裂缝进而剔除了 样本,则造成了资源的浪费。因此两者的区分具有至关 重要的意义。



图 1 桦木薄板表面的裂缝和矿物线



本文针对灰度图像上桦木板表面的非通透呈暗色线 条状的裂缝与矿物线的分类问题提出一种基于基于局部 二值差异激励模式(local binary difference excitation pattern,LB_DEP)的方法.首先,通过预处理操作将裂缝 和矿物线缺陷分割出来;然后在 LBP (local binary pattern)与韦伯定律的基础上提出一种反应图像上不同 纹理结构位置处差异激励分布状态的模式,称为 LB_ DEP。然后,提取目标图像区域的 LBP 和 LB_DEP 特征, 实现从纹理以及纹理与差异激励关联关系两个角度对裂 缝和矿物线内部的灰度分布状态的描述,并进行融合形 成特征向量,作为 SVM 分类器的输入用于分类裂缝和矿 物线。其中,本文提出了两种融合特征向量的获取方法: 1)将 LBP 和 LB_DEP 直方图链接起来形成组合直方图, 并通过 PCA 进行数据降维,将得到的降维后的数据作为 特征向量。将该方法记为"H-PCA"法。2)将 LBP 和 LB _DEP 直方图与卡方距离这一测度方法相结合,分别提取 两者的"直方图-卡方"特征,并链接起来形成特征向量。 将该方法记为"H-chi-square"法。实验结果表明,两种特 征向量融合方法均获得了较好的效果。

1 硬件配置与图像数据库

1.1 硬件配置

本文以由桦木加工的呈薄板状的医用压舌板作为实验对象,用于采集其表面图像的硬件装置如图 2 所示。 采用的相机为 XIME 公司 USB 口面阵黑白相机,型号为 MQ013MG-E2,最大分辨率为 1 280×1 024。镜头为 Computar 公司的 MT1214-MP2。光源选用的为 OPT 公司 高均匀条形白光光源。相机位于木板正上方 200 mm 处。 光源位于木板的左上方,光源光线入射方向与木板表面 呈 45°夹角。本文方法设置 CCD 的采集分辨率为 1 280× 256,工作方式为触发拍摄模式。



图 2 硬件装置 Fig.2 Photo of the hardware device

1.2 图像数据库

本文用于实验的图像(如图3所示)就是由图2的装置获取的。在采集图像之前,由专业技术人员对含有裂缝和矿物线的压舌板薄板进行分类拣选,得到有裂缝缺陷的样本134支,正反两个表面共标记出裂缝241处。得到有矿物线的样本177支,正反两个表面共标记出矿物线202处。然后,由图2装置对这些木板正反两个表面图像进行采集,最后得到大小为241+202=443的图库。



图 3 图库中的样本图像 Fig.3 Sample images in the image database

2 方法

这部分介绍本文提出的劈裂、矿物线分类方法。该方法包括3个部分,分别为线状缺陷区域分割、基于 LBP和 LB_DEP的特征向量生成,以及使用 SVM 分类器进行缺陷分类。图4 为整体流程,具体内容在下面的章节中进行了描述。

2.1 线状缺陷区域分割

由于木板在图像中表现为明显的亮强度区域,可通 过 OTSU^[13]方法较为容易的定位。然后,采用式(1)的方 法分割缺陷区域。



$$I_{i}(x,y) = \begin{cases} 255, & I(x,y) - I(x,y) > T\\ 0, & \bar{I}(x,y) - I(x,y) \le T \end{cases}$$
(1)

式中: *I*, 是标记了分割区域后的输出图像; *I* 表示输入图像; *I* 表示采用10×10模版对*I* 进行均值滤波后的图像。 *T* 为阈值, 其大小通过对图库中的样本进行观察和统计获得的。

接着通过面积值 T_a 筛选,去除较小的噪声;并根据 裂缝和矿物线均呈细长线状这一显著共同特点,设定最 小外接矩形长宽比阈值 T_r 这一条件,对裂缝和矿物线区 域进行提取。最终得到的分割效果如图 5 所示。



图 5 缺陷分割效果 Fig.5 Segmentation effects of the defects

2.2 特征提取

这一部分,本文对分割出的线状缺陷区域的特征进 行提取,用于接下来的分类环节识别缺陷。 1)应用 LBP 进行缺陷分类

LBP 是目前比较流行的一种图像纹理特征表示方法,在木材缺陷检测和识别领域得到广泛的应用,并取得 了较好的效果^[14-15]。因此基于当前 LBP 在木材缺陷检 测相关领域成功应用的启发,本文对其在裂缝和矿物线 的分类问题上进行了研究。

木板裂缝和矿物线具有完全不同的形成原因。裂缝 是由木纤维簇沿切向撕裂而形成的,其裂口处的纹理排 布呈现一定的规律,如图 6(a)所示,类似于阶梯状。而 矿物线由矿物质沉积而成,其色素深浅的分布较为均匀, 如图 6(b)。综合图 6 可见,两者的纹理结构具有一定差 异,因此利用 LBP 这一图像纹理描述方法理论上能够得 到较好的区分效果。对此,我们进行了实验。首先求取 待测缺陷区域的 LBP 直方图,然后利用卡方距离对其与 目标纹理类标准形状的相似度进行测量。由于该部分理 论和实验方法较为成熟,因此本文不再赘述,具体可参见 文献[16-17]。





值得说明的一点是,上文所述的"目标纹理类标准形状"是根据训练数据库中各自样本的平均 LBP 直方图获得的。具体方法如式(2)。

$$H_{e/m}(LBP) = \frac{1}{n} \sum_{i=1}^{n} H(t_i)$$
 (2)

式中: $H_{e}(LBP)$ 表示裂缝纹理参考直方图; $H_{m}(LBP)$ 表示 矿物线纹理参考直方图;i表示训练数据库中样本的编 号;n表示训练数据库中裂缝或矿物线样本的总数量; $H(t_{i})$ 表示第 i 个样本 LBP 直方图横坐标为 t 时对应的 LBP 值。其中训练数据库的信息在实验部分进行了详细 的介绍。具体实验数据和实验结果如下面 4.1 节所述。

2)局部二值差异激励模式

通过 3.1 节的实验可知,利用 LBP 对裂缝和矿物线 进行分类得到的评价指标 Recall 和 Precision 的值分别为 87.8% 和 91.5%。可以说这是一个较好的效果,但是仍 然存在约 12% 的图像发生错判,尤其是矿物线,其错判的 比例约为 17%。为了能够进一步提升分类的准确性,本 文将人眼视觉感官特征引入了进来。人眼作为图像的最 终接受者,具有将十分相似的纹理准确区分开来的能力, 因此恰当利用人眼视觉特性能够有助于得到性能优良的 分类方法。人眼视觉具有对绝对感官刺激量不太敏感, 而对相对刺激量敏感的特性,这种现象正是韦伯定律所 描述的心理物理学规律^[18]。本文将韦伯定律引入进来, 与 LBP 相结合,提出一种新的图像特征描述方法,称之 为 LB_DEP。

基于韦伯定律,一种用于描述人眼对图像感知的物 理量-差异激励被定义为式(3)的形式。

$$\xi(x_c) = \arctan\left[\alpha \cdot \frac{\sum_{i=0}^{Q-1} (x_i - x_c)}{\max(I) - \min(I)}\right]$$
(3)

式中: x_e 为当前像素点的灰度值; x_i 为邻域像素点的灰度 值。Q 的取值为 8, 图 7 中"Q = 8"模式图为 x_e 和 x_i 的位 置关系 分 布。 其 它 参 数 的 具 体 意 义 可 参 见 文 献 [19-20]。然而,当前的研究只考虑了"Q = 8"模式这一 种情况,为了探索人眼观察目标时的感知方式,本文又另 外定义了6种计算差异激励时 x_e 和 x_i 的位置关系,即6种 新的 Q 模式,分别为"Q = 4 +"、"Q = 4X"、"Q = 2 -"、 "Q = 2 -"、"Q = 2/"和"Q = 2、",如图 8 所示。在实验 部分,本文对图 7 中 7 种 Q 模式的效果进行了实验比较和 分析。



基于 LBP 和差异激励,本文提出一种用来描述图像 不同纹理结构处差异激励的强度以及各纹理结构之间差 异激励强度分布关系的描述方法,即 LB-DIP 直方图。其 基本生成原理示意如图 8 所示。首先对目标图像块的 LBP 图谱进行式(4)的定值阈值分割操作得到二值图像 I_b 。然后将 I_b 映射到目标图像的差异激励图谱 $\xi \perp$,并 统计 $I_b(x,y) = 0$ 的像素位置(x,y)处对应的差异激励值 $\xi(x,y)$ 。然后根据式(5)得到差异激励特征值 F(t)。 在 t 依次取 0 到($2^p - 1$)的过程中,可得到 $2^p \land F(t)$ 。 则以 t 为横坐标、F(t) 为纵坐标而形成的分布曲线唯一 的表征了目标图像块纹理结构和差异激励的关联关系, 称为 LB-DIP 模式直方图。

$$I_{\rm b}(x,y) = \begin{cases} 0, & I_{\rm LBP}(x,y) = t \\ 1, & \pm \ell \ell \end{cases}$$
(4)

式中: I_{LBP} 表示输入的 LBP 图谱; $I_{LBP}(x, y)$ 表示 LBP 图谱

(5)

上点(x, y)处的灰度值(LBP fi):t为阈值, 且 $0 \le t \le 2^{p}$ - $1(P 表示 LBP 采样点数量); I_k 表示输出的二值图像。$

式中: $\xi_i(x,y)$ 表示 $I_i(x,y)$ 为0的像素位置(x,y)处对应 的差异激励值; R 表示满足 $I_{k}(x, y)$ 为 0 的像素位置构成 的坐标集合。



图 8 LBP 特征图与差异激励图的映射 Fig.8 Mapping of LBP feature graph and difference excitation graph

3)特征向量的生成

本文采用了两种特征向量生成策略:

(1)H-PCA 方法

该方法中本文将 LBP 和 LB_DEP 模式直方图连接 起来,形成组合直方图特征向量,然后通过 PCA 进行主 成分分析,去掉冗余信息后的信息作为特征向量作为 SVM 分类器的输入。

将图像的 LBP 直方图记为 H(LBP)=[h(0),h(1), ..., h(i), ..., h(n)], LB_DEP 模式直方图记为 H^d(LB_ DEP)= $[h^{d}(1), h^{d}(2), \dots, h^{d}(i), \dots, h^{d}(n)]$.其中 *i* 表示 直方图的横坐标,h(i)和 $h^{d}(i)$ 分别表示待测图像中LBP 值和 LB_DEP 值为 i 的像素点数量。n 表示直方图的尺 度,其大小如式(6)。

$$n = \sum_{i=0}^{P-1} 2^i$$
 (6)

式中:P为LBP的采样点数。

将 H(LBP)和 H^d(LB_DEP)连接起来,形成 2n 维的 特征向量 H_{coneat},然后利用 PCA 进行降维,作为下一步 SVM 分类器的输入。

$$H_{\text{concat}} = [H(\text{LBP}), H^{d}(\text{LB} - \text{DIP})] = [h(0), h(1), \cdots, h(i), \cdots, h(n), hd(1), hd(2), \cdots, hd(i), \cdots, hd(n)]$$
(7)
(2) H-chi-square 方法

定义直方图-卡方特征,并将 LBP 和 LB_DEP 的直方 图-卡方特征连接起来,形成组合卡方特征向量。

基于 LBP 直方图及其利用卡方距离进行纹理分类 的原理,本文定义了 LBP 直方图-卡方特征向量 $F_{\rm hx}$,如 式(8)。

$$F_{\rm hx} = \left[\chi^2(H, H_{\rm c}) \, \chi^2(H, H_{\rm m})\right] \tag{8}$$

式中:H表示待测试样本的LBP模式直方图,H。和Hm 分别表示裂缝和矿物线参考 LBP 直方图。类似的, LB_ DEP 的直方图-卡方特征向量定义如式(9)。

$$\boldsymbol{F}_{hx}^{d} = \left[\boldsymbol{\chi}^{2}(\boldsymbol{H}^{d},\boldsymbol{H}_{c}^{d}) \; \boldsymbol{\chi}^{2}(\boldsymbol{H}^{d},\boldsymbol{H}_{m}^{d})\right]$$
(9)

式中: H^{d} 表示待测试样本的 LB_DEP 模式直方图. H^{d}_{e} 和 H_m^d 分别表示裂缝和矿物线参考 LB_DEP 直方图。

然后将 $F_{\rm hx}$ 和 $F_{\rm hx}^{d}$ 连接起来,形成4维特征向量 $F_{\rm concat}$ 作为下一步 SVM 分类器的输入。

$$F_{\text{concat}} = [F_{\text{hx}}, F_{\text{hx}}^d] =$$

 $\left[\chi^{2}(H,H_{c})\chi^{2}(H,H_{m})\chi^{2}(H^{d},H_{c}^{d})\chi^{2}(H^{d},H_{m}^{d})\right] \quad (10)$

2.3 基于 SVM 分类器的缺陷分类识别

2.2 节中采用 H-PCA 和 H-chi-square 两种方法分别 得到了特征向量 H_{concat} 和 F_{concat} 。这一部分将 H_{concat} 和 F_{concat}分别作为 SVM 分类器的输入用于 SVM 网络的训 练,以及缺陷的分类识别。

本文中采用 RBF 作为 SVM 的核函数,具体形式如

式(11)所示。

$$K(x,z) = e^{-\gamma \|x-z\|^2}$$
(11)

式中:*z* 是核函数的中心;γ 是核函数的宽度参数。γ 的 直观含义是支持向量对其周围环境的影响程度。对于γ 的确定,本文选用一种典型的策略,即选择一个小的γ-N_u 对,并随着识别率的增加逐渐增大他们的值。其中 N_u 表示正则化系数。

3 实 验

这一部分,对本文所提出的木材缺陷分类方法的效 果进行评估。用于实验评估的图像数据集为本文在第2 部分建立的数据集。

Recall, Precision,和 False negative rate(FNR)是三个 常用于评价缺陷检测效果的测量指标,其具体定义如式 (12)~(14)。Recall 给出了实际缺陷被正确识别的比 率, Precision 给出了被识别为缺陷的对象其实际为缺陷 的比例。FNR 表示实际为缺陷但是没有被检测出来的比 例。

$$Recall = \frac{TP}{TP + FN}$$
(12)

$$Precision = \frac{TP}{TP + FP}$$
(13)

$$FNR = \frac{FN}{TP + FN} \tag{14}$$

式中:TP 表示实际为裂缝缺陷被识别为裂缝的样本数 量;FP 表示实际是裂缝而被识别为矿物线的样本数量; FN 表示实际为矿物线被识别为裂缝的数量。

为了执行实验评估,首先从第2部分采集的图像中创 建了一个训练数据集,包括100个裂缝和100个矿物线图 像区域。这些训练图像被用来创建2.2中1)和3)所述的 LBP和LB_DEP参考直方图。图库中其余的未被用来训 练的图像形成测试样本集,用于测试。测试集包含141个 裂缝缺陷图像区域和102个矿物线图像区域。

此外,通过对图库中样本的观察和统计,确定式(1) 中阈值 T 取 15;面积值 T_a为 20,长宽比阈值 T_r为 5。下 面的实验均是在上述预处理部分阈值取值情况的基础上 进行的。

3.1 LBP 分类实验

这一部分对 2.2 中 1) 节的内容进行实验。本文测试 了 LBP 参数 *P*、*R* 分别为[8,1] 和[16,2] 的两种情况。从 训练数据集中得到的 LBP 参考直方图如图 9 所示。表 1 给出了算法在测试数据集上的结果。在参数为[8,1] 时, Recall, precision 和 FNR 分别为 87.8%, 91.5% 和 11.2%。 在参数为[16,2] 时, Recall, Precision 和 FNR 分别为 73.6%, 75.2% 和 26.4%。可见参数[8,1] 给出了比参数 [16,2]更好的表现效果,但是仍然存在约[(141-129)(102-84)]/(141+102)≈12.3%的图像发生错判,尤其是 矿物线,其错判的比例约为(102-84)/102≈17.6%。





3.2 LB_DEP 分类实验

与 3.1 节的实验过程相同,本文同样利用卡方距离 对 LB_DEP 的分类效果进行了测试。其中裂缝和矿物线 的参考 LB_DEP 直方图求取方法已经在前面介绍了。测 试了图 8 中 7 种 Q 模式下 LB_DEP 的分类效果。

表 1 分类结果 Table 1 Classification results

参数	正确分类数量		Recall/	precision/	FNR/
	裂缝	矿物线	%	%	%
LBP8,1	129	84	87.8	91.5	11.2
LBP16,2	106	64	73.6	75.2	26.4

表2总结了不同Q模式下LB_DEP在测试集上的效 果。其中前7种Q模式为本文在图8中定义的形式。可 以看到,在Q=8模式下,获得最大的 Recall 和最小的 FNR,分别为86.3%和13.7%。当Q为'21'模式时获得 最高的 Precision,为 94.3%。而 Q 为'2-'模式时,3 个参 数均给出了与其他模型相比最差的结果,其 Recall, Precision 和 FNR 分别为 59.1%, 46.1%, 40.9%。说明裂 缝和矿物线在水平方向的纹理和差异激励的分布形式非 常相似。然而,由图8可见,Q=8模式中参与计算的图 像范围是包含了 Q=2-模式的计算范围的,因此设想将 Q=8 模式中的 Q=2-模式图像部分去除会得到更好的效 果。根据这个设想,本文建立了新的Q模式,如图10 (a),称之为Q=6模式。然后按照与其他Q模式同样的 方法在测试数据上对其效果进行了测试。图 10(b)、(c) 分别为在训练数据库上获得的 Q=6 模式下 LBP 和 LB_ DEP 的参考直方图。测试的结果如表 2 中最后一行所 示。可以看到,Q=6模式时算法的 Recall, Precision 和 FNR 分别为 88.2%,90.1% 和 11.8%,其中指标 Recall 是 所有 Q模式中最高的,FNR 是所有 Q模式中最低的。表 明其相对于其它 Q模式具有更好的效果。

表 2 不同 Q 模式下的分类效果 Table 2 Classification effects under different Q modes

Q模式	正确分类数量		Recall/	precision/	FNR/
	裂缝	矿物线	%	%	%
8	126	82	86.3	89.4	13.7
4+	114	69	77.6	80.9	22.4
4 *	127	65	77.4	90.1	22.6
21	133	71	81.1	94.3	18.9
2-	65	57	59.1	46.1	40.9
2/	123	74	81.5	87.2	18.5
2\	107	72	78.1	75.9	21.9
6	128	85	88.2	90. 8	11.7



Fig.10 The state and reference shape for mode Q=6

3.3 LBP 与 LB_DEP 融合分类实验

3.1和3.2节中分别对 LBP 和 LB_DEP 在不同参数下进行了实验。这部分本文将 LBP 和 LB_DEP 方法进行融合,且选取其单独使用时获得最佳效果的参数。即 LBP 参数 P、R 分别选取[8,1];LB_DEP 参数 Q 取 6。 需要说明的是 3.2节中最高的 Recall 和 Precision 分属于两个组,由于 Recall 反应的是算法的综合性能,因此我们以其为衡量标准,选择 Q=6模式进行融合实验。

融合的方法有两种。以 H-chi-square 方法方式进行融合时,特征向量的维度是 4,本文直接将该特征向量输入到 SVM 分类器中。以 H-PCA 方法进行融合时,特征数据的 维度为 2n,为了降低数据的冗余信息,首先利用 PCA 对其进行降维处理,然后再输入到 SVM 分类器用于缺陷识别。本文使用训练数据集中的 100 个裂缝和矿物线图像区域的 H_{concat}序列作为样本进行了主成分分析。图 11 给出的 是将得到的主成分按照贡献率降序排列后的分布状态,以 及相应的累计贡献率分布状态。可见,前 99 个主成分值 的累计贡献率达到了 98%。因此本文选择前 99 个主成分

作为特征用于 SVM 分类器的训练和识别。





表3给出了两种融合方法的结果。可见,以H-PCA 方式融合的 Recall, Precision 和 FNR 分别为 95.8%, 96.5%和4.2%,获得了比 H-chi-square 方式融合更好的 表现效果。分析其原因为,将直方图序列直接融合进而 通过 PCA 降维得到的特征对直方图形状的细节描述更 加丰富,信息的维度也更多,因此得到了更好的效果。而 H-chi-square 方法是将目标对象与两个类别的平均形状 的卡方距离值作为特征的,是对直方图整体相似性的综 合评估,相对而言对目标形状细节的描绘能力就较弱。

表 3 融合分类结果 Table 3 Fusion classification results

方法	正确分类数量		Recall/	precision/	FNR/
	裂缝	矿物线	%	%	%
H-chi-square	134	93	93.7	95.0	6.3
H-PCA	136	95	95.8	96.5	4.2

图 12 为使用两种融合方法与融合前分别使用 LBP 和 LB_DEP 在测试集上效果的对比。可见两种融合方法 均获得了比使用任何单独特征都更好的表现效果。因此 本文将 LBP 和 LB_DEP 特征相结合,为正确检测木材缺 陷提供了健壮的描述符。



before and after fusion

对在测试集上获得最佳效果的 H-PCA 方法错判的 样本进行了观察,典型的代表如图 13 所示。错判的裂缝 如图 13(a)所示,为一种间断而不连续的裂缝。可见对 于分割出的条状裂缝区域,左、右两侧裂纹较明显,而中 间呈现出一个间断,因此将其整体作为目标来提取特征 时,左右两侧"裂缝属性"的程度被中间拉低,导致其整 体平均 LBP 和 LB_DEP 特征反而与矿物线更接近。图 13(b)是被识别为裂缝的矿物线,通过观察,这些矿物线 的纹理分布及灰度的对比度均与裂缝极其相似。这主要 是由于矿物线的色素沉积具有一定的随机性而引起的。



图 13 测试集中错判的样本代表 Fig.13 The misjudged representative samples in the test set

3.4 对比实验

本文与近些年同样利用 LBP 特征进行木材表面缺 陷检测研究的方法进行了比较,包括文献[13]和[22]。

文献[13]将 LBP 与 SIFT 相结合。文献[21]将 LBP 与 GLCM 相结合。表 4 给出了本文方法与其方法结果的 对比。可见,本文的两种特征提取方法的效果均优于对 比方法。因此将 LB_DEP 特征,而不是 SIFT 和 GLCM,与 LBP 方法配合用于对桦木表面裂缝和矿物线的分类能够 起到更好的效果。

表 4 本文方法与其他方法效果对比 Table 4 Effect comparison between the proposed method and other methods

方法	Recall/%	Precision/%	FNR/%	运行时间/s
H-PCA	95.8	96. 5	4.2	0.098 5
H-chi-square	93.7	95.0	6.3	0.1087
LBP+SIFT ^[13]	91.5	91.5	8.5	0.184 0
LBP+GLCM ^[21]	92.8	90. 8	7.2	0.092 2

此外,从表4中可以观察到,相对于其他方法本文方 法并没有消耗更多的运行时间。为本文算法各步骤耗时 的具体情况如表5所示。表5中,"*"标记的算法过程 为本文两种特征融合方式均需要运行的步骤,"+"标记 的算法过程为只有 H-chi-square 需要运行的步骤,"#"标 记的算法过程为只 H-PCA 方法需要运行的步骤。可见, H-PCA 方法的耗时主要体现在离线部分,而这不影响在 线的检测。

	表 5	算法耗时
Table 5	Time consu	imption of the algorithms

在线算法过程	耗时	离线算法过程	耗时
LBP 直方图生成 *	0.042 3	SVM 卡方训练+	0.007 7
LB_DEP 直方图生成 *	0.054 9	SVM 直方图训练#	2.236 4
卡方特征提取及分类+	0.010 5	PCA#	2.223 4
SVM 卡方分类+	0.001 0	-	-
SVM 直方图分类#	0.001 3	-	-

4 结 论

本文针对木板表面矿物线和裂缝由于在几何形 态、灰度分布等诸多图像特征上的表现均十分相似而 极易混淆的问题,提出一种基于 LB_DEP 和 SVM 的木 材缺陷分类方法。该方法基于 LBP 和一种在本文中提 出的反应图像上不同纹理结构位置与差异激励关联关 系的 LB_DEP 方法,然后使用 SVM 分用于分类。实验 使用了自建的桦木板图像数据集,包含裂缝和矿物线 这两种缺陷。实验结果显示,LBP 和 LB_DEP 的融合 使用(无论是以 H-chi-square 方式还是 H-PCA 方式), 均表现出比单独使用其中任意一种特征描述符更好的 效果。且以 H-PCA 方式融合时效果更佳。在测试数据 集上,本文方法获得的 Recall, Precision 和 FNR 分别为 95.8%,96.5%和4.2%。与其他相似的研究相比 Recall 和 Precision 至少提高了 3% 和 5%, FNR 至少降 低了3%。此外,本文算法在测试数据集上的平均消耗 时间为0.0985s,与对比方法相比均属于毫秒级别。 未来工作计划将本文方法用于其他的数据集,以及其 他的缺陷类型,比如节子和污染。

参考文献

- LIN L Y, HE SH, FU F, et al. Detection of wood failure by image processing method: influence of algorithm, adhesive and wood species [J]. European Journal of Wood and Wood Products, 2015, 73(4):485-491.
- [2] KE ZH N, ZHAO Q J, HUANG CH H, et al. Detection of wood surface defects based on particle swarm-genetic hybrid algorithm [C]. 2016 International Conference on Audio, Language and Image Processing. IEEE, 2016:

375-379.

- [3] ZHANG Y, XU C, LI C, et al. Wood defect detection method with PCA feature fusion and compressed sensing[J].Journal of Forestry Research, 2015, 26(3): 745-751.
- 【4】 张怡卓,许雷,丁亮,等.基于图像融合分割的实木地板表面缺陷检测方法[J]. 电机 与控制学报,2014, 18(7):113-118.

ZHANG Y ZH, XU L, DING L, et al. Defects segmentation for wood floor based on image fusion method[J]. Electric Machines and Control, 2014, 18(7):113-118.

- [5] CHAO L, ZHANG Y ZH, TU W J, et al. Soft measurement of wood defects based on LDA feature fusion and compressed sensor images [J]. Journal of Forestry Research, 2017, 28(6):1274-1281.
- [6] CHANG Z, CAO J, ZHANG Y. A novel image segmentation approach for wood plate surface defect classification through convex optimization [J]. Journal of Forestry Research, 2018(6):1789-1795.
- [7] 吴东洋,业宁,沈丽容,等.基于颜色矩的木材缺陷聚类 识别[J].江南大学学报(自然科学版),2009,8(5): 520-524.

WU D Y, YE N, SHEN L R, et al. Clustering method for automatic timber defects detection based on the color moment [J]. Journal of Jiangnan University (Natural Science Edition), 2009, 8(5):520-524.

 [8] 吴东洋,业宁,苏小青.基于灰度共生矩阵和聚类方法的木材缺陷识别[J].计算机与数字工程,2010, 38(11):38-41.

> WU D Y, YE N, SU X Q. Wood defect recognition based on GLCM and clustering algorithm [J]. Computer & Digital Engineering, 2010, 38(11):38-41.

- [9] HITTAWE M M, MUDDAMSETTY S M, SIDIBE D, et al. Multiple features extraction for timber defects detection and classification using SVM [C]. IEEE International Conference on Image Processing. IEEE, 2015:427-431.
- [10] SHNHNORBANUN S, HUDA S N, HASLINA A, et al. A computational biological network for wood defect classification [J]. Lecture Notes in Engineering and Computer science, 2010, 2186(1):559-563.
- [11] DRAKE D, PACKIANATHER M S. A decision tree of

neural networks for classifying images of wood veneer [J]. International Journal of Advanced Manufacturing Technology, 1998, 14(4):280-285.

- [12] BARIS Y, ERNESTO M, MICHAEL S P, et al. Neural network design and feature selection using principal component analysis and Taguchi method for identifying wood veneer defects [J]. Production and Manufacturing Research: An Open Access Journal, 2014, 2 (1): 291-308.
- [13] FAN H, XIE F, LI Y, et al. Automatic segmentation of dermoscopy images using saliency combined with Otsu threshold [J]. Computers in Biology & Medicine, 2017, 85:75-85.
- [14] KAYOKO K, SUNG H, TAKAYUKI O, et al. Nondestructive method for wood identification using conventional X-ray computed tomography data, Journal of Cultural Heritage, 2019, 38:88-93.
- [15] KUANG H, DING Y, LI R, et al. Defect detection of bamboo strips based on LBP and GLCM features by using SVM classifier [C]. The 30th Chinese Control and Decision Conference, 2018;574-578.
- [16] LI L, FIEGUTH P, GUO Y, et al. Local binary features for texture classification: taxonomy and experimental study [J]. Pattern Recognition, 2017, 62:135-160.
- [17] 储怡宁,汪源源,朱建伟,等.改进LBP 描述符法提取 胰腺内镜超声图像特征[J].仪器仪表学报,2014, 35(S2):182-185.
 CHUYN, WANGYY, ZHUJW, et al. Improved LBP descriptor in pancreas endoscopic ultrasound image feature extraction [J]. Chinese Journal of Scientific Instrument, 2014, 35(S2):182-185.
- [18] PAULO A, THIERRY G, FERNANDO P. An ant navigation model based on Weber's law [J]. Journal of Mathematical Biology, 2019, 78(4):943-984.
- [19] LEE S, KIM J. Vessel pattern enhancement based on Weber's law for sclera recognition [C].2018 International Conference on Electronics, Information, and Communication (ICEIC), 2018:1-2.
- [20] 陈勇,吴明明,房昊,等.基于差异激励的无参考图像质量评价[J]. 自动化学报, 2019, 3:1-11.
 CHEN Y, WU M M, FANG H, et al. No-reference image quality assessment based on differential

excitation[J]. Acta Automatica Sinica, 2019, 3:1-11.

[21] ZHANG L, BOVIK A C. A Feature-Enriched Completely Blind Image Quality Evaluator[J]. IEEE Transactions on Image Processing, 2015, 24(8): 2579-2591.

作者简介



李绍丽,分别于 2013、2018 年于沈阳工 业大学获得学士、博士学位。现为沈阳工业 大学电气工程学科博士后,主要研究方向为 机器视觉检测和图像处理。

E-mail: 707816215@ qq.com

Li Shaoli received B. Sc. and Ph. D. degrees both from Shenyang University of Technology in 2013 and 2018, respectively. Now, she is a postdoctor fellow in electrical engineering, Shenyang University of Technology. Her main research interest includes machine vision and image processing.



苑玮琦,1982年于湖南大学获得学士学 位,分别于1988、1997年在东北大学获得硕 士、博士学位,现为沈阳工业大学教授、博士 生导师,主要研究方向为机器视觉检测和生 物特征识别。

E-mail: yuan60@126.com

Yuan Weiqi received B. Sc. degree from Hunan University in 1982, received M.Sc and Ph.D degrees both from Northeastern University in 1988 and 1997, respectively. Now, he is a professor and doctoral supervisor in Shenyang University of Technology. His main research interest includes machine vision detection and biometric identification.



杨俊友,1993年于哈尔滨工业大学获得 博士学位,现为沈阳工业大学教授、博士生 导师,主要研究方向为康复机器人与特种电 机及其控制。

E-mail: junyouyang@ sut.edu.con

Yang Junyou received his Ph. D. degree from Harbin Institute of Technology in1993. Now, he is a professor and Ph. D. supervisor in Shenyang University of Technology. His main research interest includes rehabilitation robot, special motor and its control.



李德健(通信作者),分别于2013、2018 年于沈阳工业大学获得学士、博士学位。现 为沈阳工业大学电气工程学科博士后,主要 研究方向为机器视觉检测和图像处理。 E-mail: 540785944@qq.com

Li Dejian (corresponding author) received B. Sc. and Ph. D. degrees both from Shenyang University of Technology in 2013 and 2018, respectively. Now, he is a postdoctor fellow in electrical engineering, Shenyang University of Technology. His main research interest includes machine vision and image processing.