

DOI: 10.13382/j.jemi.B2205223

结构化矩阵分解的网状织物缺陷检测方法*

刘秀平¹ 冯国栋¹ 袁皓¹ 王柯欣¹ 闫焕营²

(1. 西安工程大学电子信息学院 西安 710048; 2. 深圳罗博泰尔机器人有限公司 深圳 518109)

摘要:针对在网状织物缺陷检测过程中因纹理复杂造成误检问题,提出了一种结构化矩阵分解的网状织物缺陷检测方法。首先,通过 Retinex 算法对图像进行增强,利用所提取的底层图像特征生成特征矩阵,并将其分解为含有织物图像背景信息的低秩矩阵和含有缺陷信息的稀疏矩阵;其次,引入了高级先验矩阵和索引树两个部分,通过利用增强后图像进行获取,并对两个部分进行特征融合,实现缺陷显著性增强。通过计算稀疏矩阵的值,获得缺陷的显著性的大小;最后,通过最佳阈值分割算法分割缺陷显著图,从而得到缺陷检测结果。利用公开数据集 TILDA 和 BASLER 工业相机采集到的网状织物缺陷图像验证了算法的性能。研究表明,与其他算法相比,本文算法的识别准确率达到 94.25%,召回率达到 92.48%,分类准确率达到 90.12%。

关键词:显著性;缺陷检测;图像处理;特征融合

中图分类号: TP391.41; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 540.10

Defect detection method of agricultural mesh fabric based on structured matrix decomposition

Liu Xiuping¹ Feng Guodong¹ Yuan Hao¹ Wang Kexin¹ Yan Huanying²

(1. School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China;

2. Shenzhen Municipal Robotel Robot Technology Co., Ltd., Shenzhen 518109, China)

Abstract: Aiming at the problem of misdetection caused by complex texture during the defect detection process of mesh fabric, a structured matrix decomposition method for mesh fabric defect detection is proposed. First, the image is enhanced by the Retinex algorithm, the feature matrix is generated using the extracted underlying image features, and it is decomposed into a low-rank matrix containing fabric image background information and a sparse matrix containing defect information. Secondly, the enhanced image is used to obtain Advanced priori matrix and index tree to achieve significant enhancement of defects. By calculating the value of the sparse matrix, the saliency of the defect is obtained. Finally, the defect saliency map is segmented by the optimal threshold segmentation algorithm to obtain the defect detection result. The performance of the algorithm is verified by using the defect images of the mesh fabric collected by the public data set TILDA and the CCD industrial camera. The results show that compared with other algorithms, the recognition accuracy of this algorithm reaches 94.25%, the recall rate reaches 92.48%, and the classification accuracy rate reaches 90.12%.

Keywords: significance; defect detection; image processing; feature fusion

0 引言

近年来,机器视觉是人工智能研究的热点之一。在纺织制造业中,机器视觉已经成为检测识别的重要的技

术手段,尤其纹理复杂,同质化严重的网状织物中应用前景广泛。将机器视觉与智能算法的结合来实现网状织物缺陷的快速检测是研究的主流方向^[1]。现有的网状织物缺陷检测方法有基于低秩分解(low-rank decomposition, LRD)、基于方向梯度直方图(histogram of directional

gradients, HOG)、基于稀疏理论等。基于低秩分解的方法是提取网状织物纹理特征构建低秩稀疏分解模型,该方法对网状织物纹理不规则或背景复杂情况下并不适用^[2]。基于方向梯度直方图是将缺陷图像分解为多个单元,并提取 LBP 和 HOG 特征用来训练支持向量机,利用分类器判别缺陷。由于该方法需大量图像特征,致使算法存在计算量大,花费时间长的问题^[3]。基于稀疏表示法是将缺陷图像分割为缺陷前景和纹理背景两个部分,去除纹理背景,则凸显出了缺陷图像。该方法并不适用于无周期性的图像纹理检测^[4]。本文提出了基于以人眼注意力机制为原型缺陷显著性的检测算法,该方法对织物缺陷检测有一定的普适性。

通过以上分析可知,网状织物缺陷检测取得了良好的性能,但也存在一定的不足之处,如对织物图像纹理性、周期性要求较高、计算量大、花费时间长等问题,在一定程度上很难在实际的工业检测中发挥作用,因此本文提出了一种以显著性为基础的织物缺陷检测方法,这种方法降低了织物的特征性要求,一定程度增加了算法的鲁棒性,更加适合运用与工业实际生产的环境中。

迄今为止,已经提出了许多计算显著性的模型。显著性检测模型按人类视觉注意力机制划分为以任务驱动的自上向下的方法(top-down models, TDM)和以数据驱动的自下向上方法(bottom-up models, BUM)^[5]。TDM 由人的“认知因素”决定,如主观对目标的认知,是通过图像的特定特征来计算目标的显著性。BUM 由低级特征决定,如边缘、纹理、位置特征等。BUM 的方法就是利用这些低级特征计算目标的显著性。

1 Retinex 图像增强

图像增强^[6]是突出图像中的一些重要信息的方法。在图像采集过程中,因光照不均、不充足导致图像的很多细节信息被忽略,增加了检测算法的难度,影响了检测效果和检测效率^[7]。因此,为了降低外界环境因素对本文算法的影响,对采集到的图像通过 Retinex 进行预处理,对检测结果有了很大的改善。Retinex 理论^[8]最早是在 1963 年提出的计算图像亮度的模型,是建立在科学实验和科学分析基础上图像增强的方法。它主要研究了色彩的恒常性的问题,完成低光增强的任务^[9]。

设织图像 U 是由入射光 L 和反射率 R 的乘积得到:

$$U(x, y) = R(x, y) \times L(x, y) \quad (1)$$

式中: U 为织物图像, L 为光照强度, R 为反射率,其中反射率 R 的值由图像 U 决定。

从式(1)中可以看出,Retinex 增强是从织物图像 U 中估计光照强度,分解出反射率 R ,用来解决光照不均匀的问题,达到图像增强效果^[10]。在图像处理中,通常把

它放在对数域进行计算,可表示为:

$$u = \log U, l = \log L, r = \log R \quad (2)$$

因此,式(1)可简化为:

$$u = r + l \quad (3)$$

从式(3)中可以看出,Retinex 算法本质是在图像 U 中估测 L 分量的值,并将其去除,得到 R 。

2 结构化矩阵分解模型

结构化矩阵分解模型主要包括 3 部分:1) 织物图像底层特征提取,主要包括提取织物图像的 HOG 特征、边缘特征、纹理特征用来构建特征矩阵;2) 高层先验矩阵与索引树构建,主要融合了 3 种类型先验即位置先验、颜色先验、背景先验,通过 3 个矩阵相乘形成高级先验矩阵,在与索引树共同指导矩阵分解并增强缺陷显著性;3) 特征矩阵分解并计算缺陷显著性,通过计算矩阵分解得到稀疏矩阵的值来确定织物图像缺陷的显著性,再采用大津阈值分割算法(otsu threshold segmentation algorithm, OTSU)分割显著图得到织物缺陷检测结果。如图 1 所示,为结构化矩阵分解模型的整体框架图。

2.1 织物图像底层特征提取

织物缺陷检测问题就是设计一个有效的算法模型,通过提取织物图像的特征来进行检测。通过线性迭代聚类算法(linear iterative clustering algorithm, SLIC)^[11]将输入带有缺陷的织物图像 I 划分为 a 个不重叠层 $P = \{P_1, P_2, P_3, \dots, P_a\}$,对于每层 P_i 提取一个 M 维的特征向量,包括 HOG 特征、边缘特征^[12]、纹理特征^[13],表示为 $f_i \subset R^M$,形成输入图像 I 的特征矩阵 F ,即 $F = [f_1, f_2, f_3, \dots, f_a]$ 。将特征矩阵 F 分解为一个低秩矩阵 L 和一个稀疏矩阵 S ,因此,本文提出的 SMD 模型可表示为:

$$\min_{L, S} \varphi(L) + \alpha \delta(S) + \beta \theta(L, S) \quad (4)$$

式中:约束条件为 $F = L + S$ 。 $\varphi(\cdot)$ 为低秩约束条件,用来约束低秩矩阵中的特征空间^[14]; $\delta(\cdot)$ 为稀疏矩阵的正则化,用来约束稀疏矩阵 S 中的空间和特征关系^[15]; $\theta(\cdot, \cdot)$ 为低秩矩阵 L 和稀疏矩阵 S 的交互式正则化,用来扩大 L 和 S 绘制的子空间距离^[16]; α, β 是权衡参数,其中 $\alpha = 0.25, \beta = 1.2$ 。

2.2 高层先验矩阵与索引树的构建

为了增强织物缺陷的显著性,规范矩阵分解,提出通过整合 3 种类型的先验即位置先验^[17]、颜色先验^[18]、背景先验^[19]生成一个高层次先验图的方法。位置先验是由高斯分布生成,计算每个像素到图像中心的距离。颜色先验通过计算颜色的亮度和色度信息生成。背景先验是通过计算每个像素到图像边界的距离生成。将产生的 3 个先验矩阵相乘,生成先验矩阵,如图 1 所示。

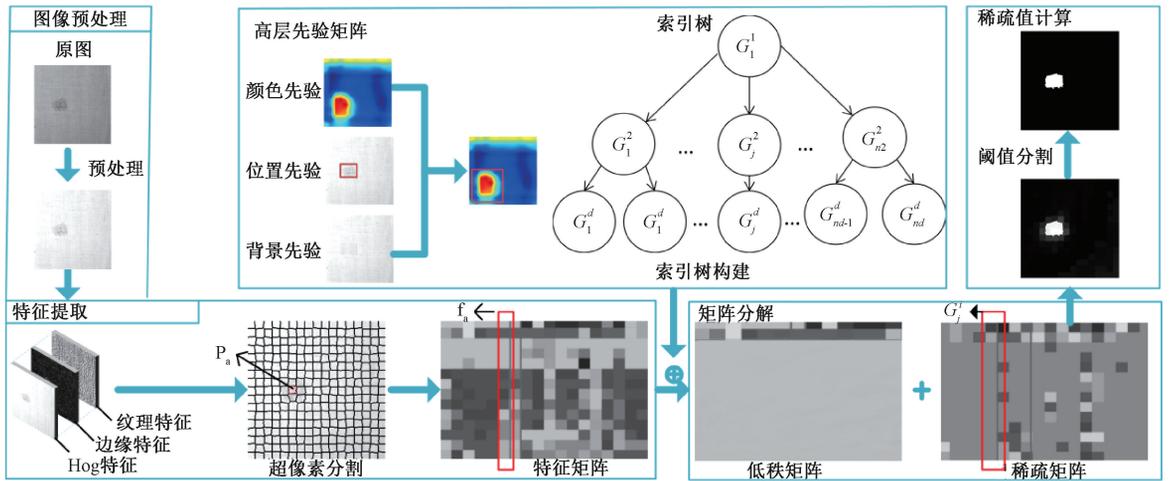


图 1 结构化矩阵分解模整体框架图

Fig. 1 Overall framework diagram of structured matrix factorization model

对于每一层 $P_i \subset P$ 中,在高级先验中 $\pi_i \in [0,1]$ 表示基于 P_i 为织物图像缺陷的可能性,通过对稀疏矩阵 S 中的每列元素进行不同的加权求,通过最小二乘估计函数 v_j^i ,如式(5)所示。

$$v_j^i = 1 - \max(\{ \pi_k; k \in G_j^i \}) \quad (5)$$

式中: G_j^i 为第 i 层的第 j 个节点,并与下面的索引树相作用,将高级先验与本文所提出的 SMD 模型融合,在 v_j^i 处提高了织物图像缺陷的显著性,增强了缺陷的可能性大小。

为了将织物图像的缺陷部分在高级先验图中凸显出,将先验矩阵与 SMD 模型进行融合,如式 6 所示。

$$(L^*, S^*) = \operatorname{argmin}_{L,S} (\|L\|_* + \lambda \|S\|_1) \quad (6)$$

式中:约束条件为 $FQ = L + S$, Q 为织物缺陷显著值的对角矩阵,表示为 $Q = \operatorname{diag}(q_1, q_2, \dots, q_n)$ 。

通过将高级先验矩阵与所提出的 SMD 进行融合,主要有如下两个方面的作用:1) 在对角矩阵 Q 中,大部分 q_n 值是较小的,当与特征矩阵 F 进行融合时,被视为低秩矩阵中的异常值,并且有可能包含在稀疏矩阵 S 中,因此在 q_n 较大的织物图像区域产生更高的显著性;2) 将高级先验矩阵与本文的模型融合,使本文算法具有更好的鲁棒性,并且考虑到织物图像相似度较高一些背景区域也会误检,但因为在这些区域处的特征向量仍与其他背景区域高度相关,因此,不会被标记为噪声,也不会被标记为显著区域。

通过将高级先验矩阵与索引树结合,共同指导矩阵的分解,是增强织物缺陷显著性的关键一步。

索引树的原理是通过将织物图像进行分割,再计算每一层图像的相似性将图像进行合并。在每一层 P 的基础之上,来构建一个索引树 T 。索引树^[20] 的形状类似结

构树。如图 2 所示,给出了从织物图像的分层分割中提取的 $N = 8$ 的引树。图 2 中 G_1^1 分解为 G_1^2, G_2^2, G_3^2 , 其中 G_1^2 索引 1,2,3,4 层, G_2^2 索引 5,6 层, G_3^2 索引 7,8 层。同一层节点相交为空集,同一层所有节点的并集组成了上一层的父节点。因此,引入树形稀疏正则化式,如式(7)所示。

$$\Omega(S) = \sum_{i=1}^d \sum_{j=1}^{n_i} v_j^i \|S_{G_j^i}\|_p \quad (7)$$

式中: v 是对应于节点 G_j^i 的权重, $S_{G_j^i}$ 是节点 G_j^i 对应于稀疏矩阵的子矩阵, d 是树的深度即层次。因此整个索引树构建过程如下:首先,通过分层分割对图像结构信息进行编码;其次,通过亲和矩阵计算每一层 P_a 的相似性。最后,根据图像的分割算法^[21] 计算出对每一层个 P_a 进行合并,达到增强织物图像缺陷显著性的目的。

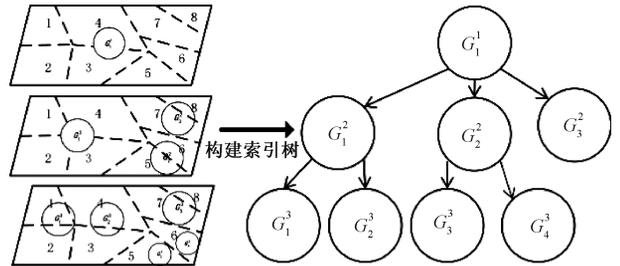


图 2 $N = 8$ 的索引树示意图

Fig. 2 Schematic diagram of index tree with $N = 8$

2.3 特征矩阵分解与显著性计算

当得到特征矩阵 F 和结构树 T 后,需要对特征矩阵进行分解。为了更好地将织物缺陷部分从图像中分离出来,需要扩大低秩矩阵 L 和稀疏矩阵 S 的空间距离,因此引入了拉普拉斯正则化,如式(8)所示。

$$\psi(L, S) = \frac{1}{2} \sum_{i,j}^N \|s_i - s_j\|_2^2 w_{i,j} = \text{Tr}(SM_F S^T) \quad (8)$$

式中: s_i 表示 S 的第 i 列, $w_{i,j}$ 是亲和矩阵 W 的第 (i,j) 项, 表示缺陷特征的相似性, $\text{Tr}(\cdot)$ 表示矩阵的迹, M_F 表示拉普拉斯矩阵。本质上, 拉普拉斯正则化就是通过特征矩阵 F 的局部不变来平滑稀疏矩阵 S 中的向量, 达到增加特征空间距离、规范矩阵分解的目的。

当特征矩阵 F 分解为低秩矩阵 L 和稀疏矩阵 S 后, 再将分解后得到的结果从特征域转到空间域进行缺陷的显著性计算。在稀疏矩阵 S 中, 缺陷显著性函数定义为 $\text{Sal}(\cdot)$, 如式(9)所示。

$$\text{Sal}(P) = \|s_i\|_1 \quad (9)$$

式中: s_i 代表稀疏矩阵 S 的第 i 列。当 $\text{Sal}(P)$ 的值越大, 表示网状织物图像缺陷的显著性越大, 缺陷的概率越大。

最后, 通过 OTSU 算法对得到的显著图进行分割, 得到织物缺陷的最终检测结果。

3 实验结果与分析

本文算法是在 Windows10 操作系统下, Intel Core i7 处理器, 安装内存为 8 GB, CPU 频率为 2.2 GHz, 并结合 MATLAB 2016b、Visual Studio 2015 实现。首先, 实验采用了公开数据集 TILDA 织物纹理库, 共 1 400 张图片来对本文算法进行了验证, 数据集中图片大小为 768×512 , 将缺陷部分裁剪为 256×256 。其次, 还采集了 3 种最常见织物缺陷, 分别为打结、破洞、裂缝, 来进一步对本文算法进行验证。织物图像大小统一为 256×256 。本实验织物图像样本含打结 1 000 幅、破洞 2 200 幅、裂缝 1 500 幅。

首先, 在 TILDA 数据集下进行测试, 如图 3 所示。图 3 中检测到缺陷形状与原图中缺陷基本保持一致, 并且缺陷周围检测误点很少。但由于在公开数据集中的图像缺陷周围存在与缺陷相似度较高的部分, 在检测过程中容易造成干扰, 是导致一些图像中检测效果不理想的主要原因。

其次, 为了进一步验证本文提出算法模型有效性, 将本文的算法与其他织物缺陷检测算法进行比较, 包括低秩矩阵恢复算法 (low rank matrix recovery algorithm, ULR)^[22]、小波变换算法 (wavelet transform algorithm, WT)^[23]、最小二乘回归算法 (least squares regression algorithm, PGLSR)^[24], 实验结果如图 4 所示。

图 4 中第 1 行为织物图像原图, 第 2 行为不同检测算法的显著图, 第 3 行为阈值分割图, 图中为便于观察, 分别对 ULR、WT、PGLSR 算法产生的显著图进行一次阈值分割。从图 4 中可以看出, 在 ULR 算法下因图像的相似度高, 低秩矩阵中出现了过多的相似值导致的检测

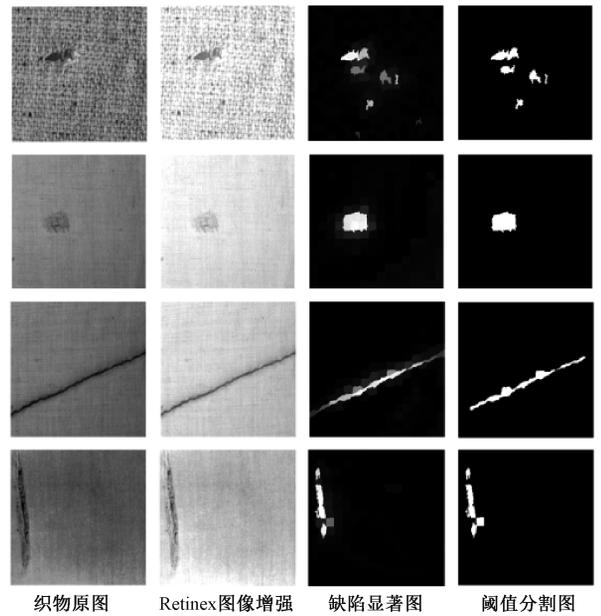


图 3 TILDA 数据集缺陷检测结果

Fig. 3 TILDA data set defect detection result graph

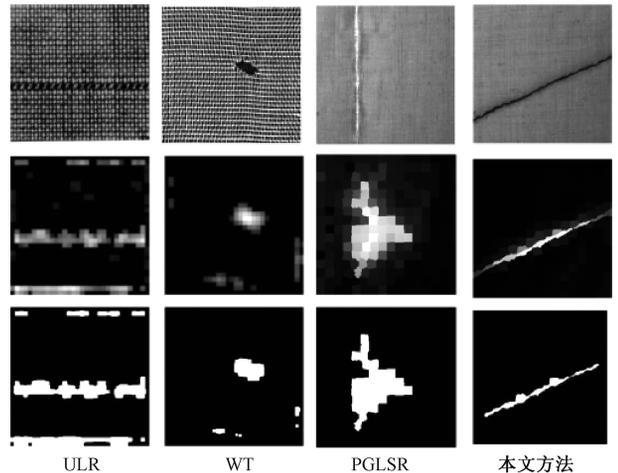


图 4 不同算法下的织物缺陷检测结果

Fig. 4 Fabric defect detection results under different algorithms

结果出现较多的检测误点。同样在 WT 和 PGLSR 算法中检测效果欠佳, 检测误点明显增多。相反本文算法因对织物图像的纹理、周期性依赖较低, 取得良好的检测效果, 具有较高的鲁棒性。

为了更好地评估本文所提出的算法, 采用了准确率 (precision, PR)、召回率 (recall, RE)、平均绝对误差 (mean absolute error, MAE)、分类总正确率 (percentage correct classification, PCC) 4 种指标来对本文算法进行评价, 其中 PR、RE、PCC 值越高算法指标越好, MAE 值越低

算法模型效果越好。具体评价指标定义式如式(10)所示。

$$PR = \frac{P_{rf}}{P_{rf} + P_{wf}}, RE = \frac{P_{rf}}{P_{rf} + P_{wb}} \quad (10)$$

式中: P_{rf} 为正确匹配的前景像素数目, P_{wf} 为非正确匹配的前景的像素数目, P_{rb} 为正确匹配的背景像素数目, P_{wb} 非正确匹配的背景像素数目。

如表 1 所示, 为本文算法和 ULR、WT、PGLSR 算法在织物缺陷检测中的各项指标评价对比。

表 1 本文算法和其他算法的检测数据

Table 1 Detection data of the algorithm in this paper and other algorithms (%)

	PR	PE	MAE	PCC
ULR	84.25	86.12	11.25	72.84
WT	75.47	75.32	25.14	78.26
PGLSR	61.48	70.45	15.19	86.46
本文算法	94.25	92.48	8.79	90.12

从表 1 中可以看出, 本文算法的评价指标 PR、RE、PCC 都达到了 90% 以上, 相对于其他算法, 取得了较好的检测效果, 同时本文算法的 MAE 是 4 种算法的最小值, 也表明了本文算法的模型具有较高的鲁棒性, 更加适合在用于纺织制造业的缺陷检测中。

为了更好地体现本文算法的有效性, 通过使用不同算法对相同的图像进行处理, 如图 5 所示。

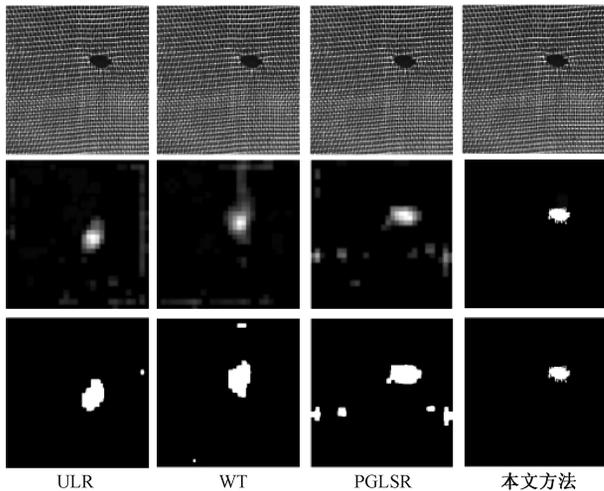


图 5 同一图像在不同算法下的检测结果

Fig. 5 Detection results of the same image under different algorithms

从图 5 中可以看出, ULR、WT、PGLSR 这 3 种算法的检测结果形状与原图均有差异, 本文算法检测结果与原图基本一致, 可见本文算法相比于其他算法取得了较好

的检测结果。主要原因是本文算法对图像信息的丰富度有了较低的要求, 提升了算法整体的鲁棒性, 更加符合生产中工业实际要求。

为了验证外界环境因素对检测结果的影响, 采用了不同分辨率下的 TILDA 数据集中的图像进行验证。如图 6 所示, 图 6(a)、(b) 是在分辨率 100×100 、 150×150 的检测结果。可以看出, 在分辨率为 100×100 的检测结果中, 检测误点增多, 检测的缺陷形状变形严重。而 150×150 的分辨率下, 检测到的缺陷形状与织物图像中的缺陷基本保持一致。通过图 6(a)、(b) 对比, 可以看到不同的分辨率对检测结果有着至关重要的作用。

为了更接近纺织业中织物缺陷检测的实际情况, 采集了破洞、打结、裂缝 3 种常见的网状织物缺陷进行实验, 对比了 Retinex 增强和未经过 Retinex 增强的织物图像的检测效果, 如图 7 所示。通过对比发现在未经过 Retinex 处理的图像中, 在 3 种不同类型的缺陷中, 检测误点增多, 检测到的缺陷形状与原图缺陷形状误差较大。这是因为在采集到的图像在未经过 Retinex 处理时, 会造成本文算法对图像的特征提取能力较弱。另外, 织物材质稍硬, 在裁剪时容易造成织物变形, 对检测效果也会造成一定影响。

同时, 利用 PR、RE、MAE、PCC 这 4 种指标对在工业实际采集的数据集中进行了评价, 进行比较, 实验结果如表 2 所示。

表 2 本文检测算法在不同织物缺陷检测中的评价指标

Table 2 The evaluation index of the detection algorithm in the detection of different fabric defects (%)

	PR	RE	MAE	PCC
破洞	97.26	96.92	9.21	94.36
裂缝	94.38	82.94	10.56	97.68
打结	95.75	94.81	8.35	92.23

表 2 中可以看出, 本文算法的 PR 值在各类缺陷中都达到了 94% 以上, RE 和 PCC 值达到了 91% 以上, 其中 MAE 最低值达到了 8.35%。总的来说, 本文算法首先对输入的织物图像有了较低要求, 例如纹理性、周期性等。其次, 在实验过程中发现每张图像检测的时间有了明显改善, 平均每副图像的检测时间为 2.57 s 左右, 对计算效率有了很大提升。最后, 虽然本文算法取得了比较满意的结果, 但其中 MAE 值过高, 还需要进一步的优化。

4 结 论

本文针对网状织物缺陷误检、漏检问题提出了结

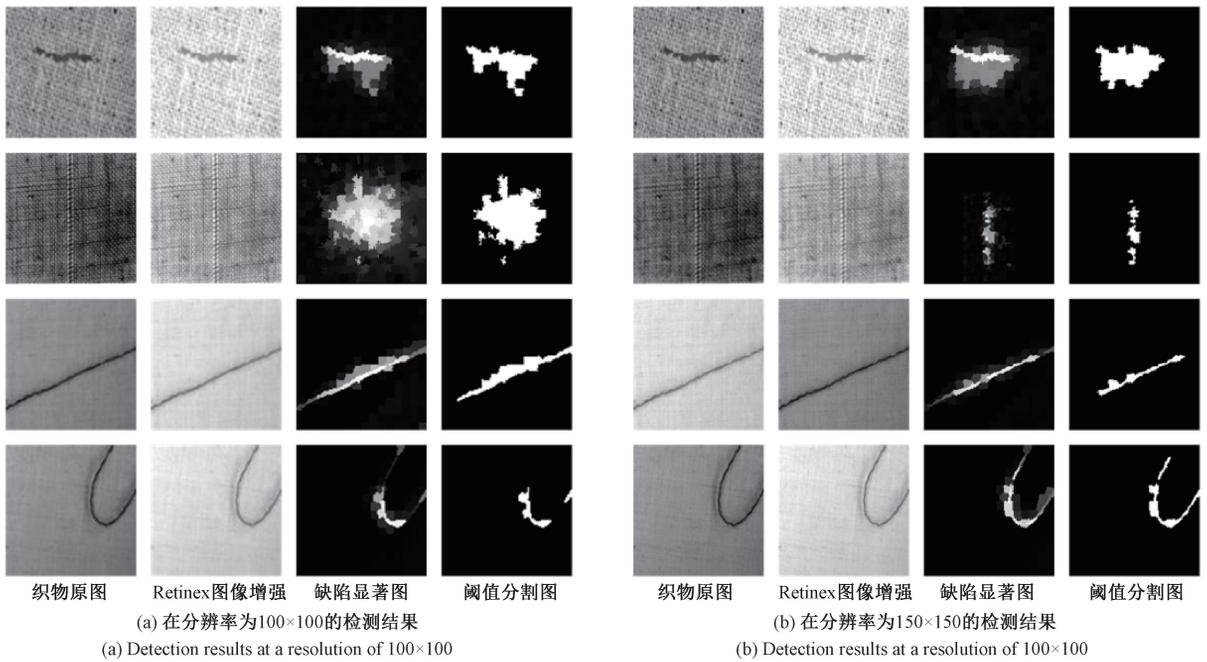


图 6 本文算法在不同分辨率的检测结果

Fig. 6 The detection results of the algorithm in this paper at different resolutions

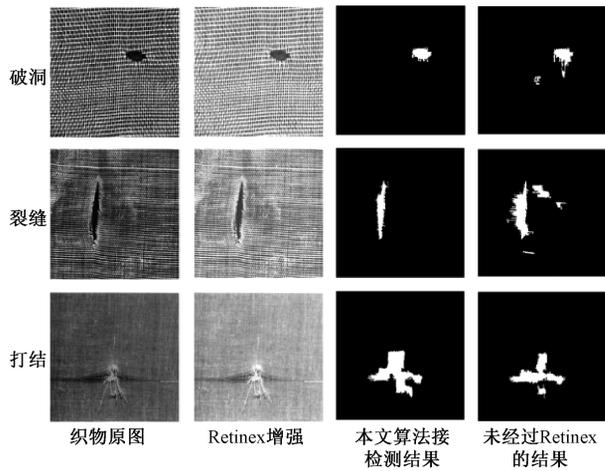


图 7 3 种常见的缺陷检测结果

Fig. 7 Three common defect detection results

构化矩阵分解模型的网状织物缺陷检测算法。首先,通过 Retinex 算法进行图像增强构建图像的特征矩阵,再将分解特征矩阵后得到稀疏矩阵,同时加入高级先验矩阵和索引树两个部分对缺陷的显著性进行增强;其次,通过计算稀疏矩阵的值来确定织物图像显著性;最后用 OTSU 算法对显著图进行分割得到检测结果。通过在公开数据集 TILDA 测试表明,该方法能有效的检测出各类缺陷。

本文算法在织物缺陷相似度较高的图像中,存在准确率低和误判的情况,在后面的工作中侧重在算法优化

和新算法开发方面进行研究提高特征提取质量,根据特征差异更好地扩大低秩矩阵和稀疏矩阵之间的距离,提升高相似度图像的准确率和误判问题。

参考文献

[1] 杨传礼,张修庆. 基于机器视觉和深度学习的材料缺陷检测应用综述[J]. 材料导报, 2022, (16):1-19.
 YANG CH L, ZHANG X Q. Review of material defect detection based on machine vision and deep learning [J]. Materials Review, 2022 (16):1-19.

[2] 杨恩君,廖义辉,刘安东,等. 基于低秩分解的织物疵点检测[J]. 纺织学报,2020,41(5):72-78.
 YANG EN J, LIAO Y H, LIU AN D, et al. Fabric defect detection based on low-rank decomposition [J]. Journal of Textile Science and Technology, 2020, 41(5):72-78.

[3] LI C, GAO G, LIU Z. Defect detection for patterned fabric images based on GHOG and low-rank decomposition [J]. IEEE Access, 2019, 41(2):83962-83973.

[4] 李清勇,梁正平,黄雅平. 缺陷检测的稀疏表示模型及应用[J]. 计算机研究与发展, 2014, 51(9):1929-1935.
 LI Q Y, LIANG ZH P, HANG Y P. Sparse representation model for defect detection and its application [J]. Computer Research and Development,

- 2014, 51(9):1929-1935.
- [5] 李世镇, 钱俊, 余映. 基于凸包计算和颜色特征的显著性检测算法[J]. 云南大学学报(自然科学版), 2021, 43(2):254-262.
- LI SH ZH, QIAN J, YU Y. Saliency detection algorithm based on convex hull computation and color feature [J]. Journal of Yunnan University (Natural Science Edition), 2021, 43(2):254-262.
- [6] 吴振中. 基于 Retinex 理论的图像增强算法的研究[J]. 现代计算机(专业版), 2016, 35(26):67-69.
- WU ZH ZH. Research on image enhancement algorithm based on retinex theory [J]. Modern Computer (Professional Edition), 2016, 35(26):67-69.
- [7] LAN E H, MCANN J J. Lightness and retinex theory[J]. Journal of the Optical Society of America, 1971, 61(1):1-11.
- [8] Land E H. The retinex[J]. American Scientist, 1964, 52(2):247-264.
- [9] WANG P, WANG Z, LV D, et al. Low illumination color image enhancement based on Gabor filtering and Retinex theory[J]. Multimedia Tools and Applications, 2021, 80(12):17705-17719.
- [10] LIU S, LONG W, HE L, et al. Retinex-based fast algorithm for low-light image enhancement[J]. Entropy, 2021, 23(6):746.
- [11] ACHANTA R, SHAJI A. Super-pixel segmentation of remote sensing image based on improved simple linear iterative clustering algorithm [J]. Laser & Optoelectronics Progress, 2019, 50(1):2274-2282.
- [12] 高佳月, 许宏丽. 基于局部边缘特征描述子的自适应边缘检测算法[J]. 中国激光, 2020, 47(6):156-163.
- GAO J Y, XU H L. Adaptive edge detection algorithm based on local edge feature descriptors [J]. Chinese Journal of Lasers, 2020, 47(6):156-163.
- [13] 刘秀平, 冯奇, 袁皓. LBP 与低秩分解的网状织物纹理缺陷检测方法[J]. 电子测量与仪器学报, 2021, 35(1):135-141.
- LIU X P, FENG Q, YUAN H. Texture defect detection method of mesh fabric based on LBP and low-rank decomposition [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1):135-141.
- [14] 张涛, 唐振民, 吕建勇. 一种基于低秩表示的子空间聚类改进算法[J]. 电子与信息学报, 2016, 38(11):2811-2818.
- ZHANG T, TANG ZH M, LYU J Y. An improved subspace clustering algorithm based on low-rank representation [J]. Journal of Electronics and Information Technology, 2016, 38(11):2811-2818.
- [15] SHI B, LIANG J, DI L. Fabric defect detection via low-rank decomposition with gradient information[J]. IEEE Access, 2019, 7(1):130423-130437.
- [16] DONG Y, WANG J, LI C. Fusing multilevel deep features for fabric defect detection based NTV-RPCA [J]. IEEE Access, 2020, 8(1):1872-1883.
- [17] 庞彦伟, 尚楚博, 何宇清. 基于尺度不变特征和位置先验的行人检测算法[J]. 天津大学学报(自然科学与工程技术版), 2017, 50(9):946-952.
- PANG Y W, SHANG CH B, HE Y Q. Pedestrian detection algorithm based on scale-invariant feature and location prior[J]. Journal of Tianjin University (Natural Science and Engineering Technology Edition), 2017, 50(9):946-952.
- [18] 李黎, 王惠刚, 刘星. 基于改进暗原色先验和颜色校正的水下图像增强[J]. 光学学报, 2017, 37(12):176-184.
- LI L, WANG H G, LIU X. Underwater image enhancement based on improved dark channel prior and color correction [J]. Acta Optica Sinica, 2017, 37(12):176-184.
- [19] 崔丽群, 杨振忠, 段天龙. 基于复合先验知识的显著性目标检测方法[J]. 激光与光电子学进展, 2020, 57(10):196-203.
- CUI L Q, YANG ZH ZH, DUAN T L. Salient object detection method based on composite prior knowledge [J]. Laser & Optoelectronics Progress, 2020, 57(10):196-203.
- [20] QIAO Z. Tree structure-aware graph representation learning via integrated hierarchical aggregation and relational metric learning [J]. ICDM, 2020, 41(2):432-441.
- [21] 黄小童, 程虹, 罗颖. 基于类间蚂蚁竞争模型的显著图像分割算法[J]. 计算机技术与发展, 2021, 31(1):98-102.
- HUANG X T, CHENG H, LUO Y. Saliency image segmentation algorithm based on ant competition model between classes [J]. Computer Technology and Development, 2021, 31(1):98-102.
- [22] ZHOU F, WU Y, DAI P. Graph-regularized laplace

approximation for detecting small infrared target against complex backgrounds[J]. IEEE Access, 2019, 7(1): 85354-85371.

- [23] SHEN X, YING W. A unified approach to salient object detection via low rank matrix recovery [C]. IEEE Conference on Computer Vision & Pattern Recognition, IEEE, 2012.
- [24] IMAMOGLU N, LIN W, FANG Y. A saliency detection model using low-level features based on wavelet transform[J]. IEEE Transactions on Multimedia, 2012, 10(1): 96-105.

作者简介



刘秀平, 2006 年于长治学院获得学士学位, 2009 年于西安建筑科技大学获得硕士学位, 2013 年于西安电子科技大学获得博士学位, 现为西安工程大学副教授, 主要研究方向为机器视觉目标检测、目标跟踪。
E-mail: liuxiuping8@126.com

Liu Xiuping received his B. Sc. degree in 2006 from Changzhi University, received his M. Sc. degree in 2009 from Xi'an University of Architecture and Technology and received his Ph. D. degree in 2013 from Xidian University. Now he is an associate professor in Xi'an Polytechnic University. His main research interests include machine vision target detection and target tracking.