

基于改进低秩表示模型的光纤环缺陷检测

陈晓乐¹, 杨瑞峰^{1,2*}, 郭晨霞^{1,2}

¹中北大学仪器与电子学院, 山西 太原 030051;

²山西省自动化检测装备与系统工程技术研究中心, 山西 太原 030051

摘要 针对目前光纤环缺陷检测方法可靠性低、实用性差的问题,提出一种基于改进低秩表示模型的光纤环缺陷检测算法。基于低秩表示理论对缺陷检测问题进行模型构建,将无缺陷的光纤环图像建模为低秩结构,将缺陷建模为稀疏结构;同时将拉普拉斯正则化约束项施加到低秩表示模型中,以扩大缺陷区域与背景之间的差距;为了提高算法的效率,采用幂法迭代的思想来实现奇异值分解。通过实验对算法进行验证,结果表明,所提算法对不同类型的缺陷均具有良好的检测性能,且与其他算法相比,取得最优的表现。

关键词 光纤环; 缺陷检测; 低秩表示; 奇异值; 幂法迭代

中图分类号 TP391.4 **文献标志码** A

DOI: 10.3788/LOP202259.2215008

Defect Detection of Optical Fiber Coil Based on Improved Low-Rank Representation Model

Chen Xiaole¹, Yang Ruifeng^{1,2*}, Guo Chenxia^{1,2}

¹School of Instrument and Electronics, North University of China, Taiyuan 030051, Shanxi, China;

²Automated Test Equipment and System Engineering Technology Research Center of Shanxi Province, Taiyuan 030051, Shanxi, China

Abstract Aiming at the challenges of the low reliability and poor practicability of current optical fiber coil defect detection approaches, an algorithm of optical fiber coil defect detection based on an enhanced low-rank representation model is suggested in this paper. Based on the low-rank representation theory, the defect detection challenge is modeled, defect-free optical fiber coil image is modeled as a low-rank structure, and defect is modeled as a sparse structure. Meanwhile, the Laplacian regularization constraint is incorporated into the low-rank representation model to widen the gap between defect and background. To enhance the efficiency of the algorithm, the idea of power iteration is employed to achieve singular value decomposition. The algorithm is confirmed via experiments, and the findings indicate that the suggested algorithm possesses a good detection performance for various defect types. Compared with other algorithms, the suggested algorithm attains the best performance.

Key words optical fiber coil; defect detection; low-rank representation; singular value; power iteration method

1 引言

光纤陀螺仪(FOG)是一种光纤传感器设备,基于Sagnac效应^[1]测量载体相对于惯性空间的角速度。光纤环是FOG的核心部件,由光纤按照特定方式缠绕而成,可在低温、高压等极端恶劣的自然环境中工作,不受电磁干扰,具有可靠性高、功耗低、寿命长等优点^[2]。光纤环的绕制质量直接影响着FOG的测量精度^[3-4],对光

纤环进行绕制质量检测是控制产品质量的关键步骤。

对于合格的光纤环,要求光纤紧密缠绕在光纤骨架表面,这对光纤控制张力有极高的要求。由于光纤直径误差、内应力、机械设备精度不足等干扰因素^[5],光纤控制张力产生波动,造成缺陷。尽管提出了许多复杂的张力控制策略^[6-9],但缺陷仍旧不可避免。缺陷不仅影响光纤环的寿命,还会严重影响FOG的测量精度,因此对光纤环进行表面缺陷检测是控制产品质量

收稿日期: 2021-09-02; 修回日期: 2021-09-24; 录用日期: 2021-10-13

基金项目: 山西省归国留学人员科研资助项目(2020-111)

通信作者: *yangruifeng@nuc.edu.cn

的关键步骤。目前,国内主要采用人工检测的方式,该方法严重依赖于工人的主观经验,容易漏检且效率低下。因此,迫切需要一种自动缺陷检测方法来提高光纤环的自动化生产水平。近年来,机器视觉以高效、准确的优点在工业产品的质量检测中取得了突出的表现^[10-12]。迄今为止,基于机器视觉来监测光纤环质量的研究仍然较少。张万成等^[13]测量绕线滞后角作为调节排线位置的依据,但是获取高精度滞后角极其困难。Guo等^[14]通过判断相邻光纤的相对位置来识别缺陷。丁清^[15]通过寻找光纤峰值并设定阈值来定位缺陷。这些方法都存在容易误检和准确率低的问题。杨震^[16]提取图像的方向梯度直方图(HOG)特征和局部二值模式(LBP)特征,并联合支持向量机(SVM)分类器完成缺陷识别。该方法依赖于大型数据集和复杂的训练过程,通用性较差。子空间聚类方法具有轻松扩展线性模型处理非线性数据的能力,因此受到广泛关注,包括主成分分析(PCA)^[17]、稀疏表示(SR)^[18]和低秩表示(LRR)^[19]。关于该方法的变体已被用于不同的应用场景和任务,例如目标跟踪^[20]、图像恢复^[21, 22]、面部识

别^[23]、工业检测^[24]等。

受低秩表示理论的启发,本文提出一种基于改进低秩表示模型的光纤环缺陷检测算法。通过引入拉普拉斯正则化约束,模型可以准确执行子空间聚类,分离出缺陷信息;此外采用交替最小化策略来求解所提模型,同时基于幂法迭代计算矩阵的奇异值分解,以提高算法的运行效率。与其他算法相比,所提算法对不同类型的缺陷均表现出较好的检测性能。

2 改进的LRR模型

2.1 基于LRR对缺陷检测问题建模

LRR模型基于自我表示执行子空间聚类,它可以将图像分解为对应于背景的低秩矩阵和对应于显著对象的稀疏矩阵。如图1所示,绕制缺陷主要分为两种:叠丝和间隙。无缺陷光纤环图像具有高度周期性的纹理,表现出很强的自相似性,因此是冗余的。而缺陷的出现会破坏纹理的周期性,与纹理结构相比,缺陷只占据图像一小部分,它相对于背景来说是稀疏的。因此,可以利用LRR模型处理光纤环缺陷检测任务。




图1 光纤环图像。(a)无缺陷图;(b)叠丝缺陷图像;(c)间隙缺陷图像

Fig. 1 Optical fiber coil images. (a) Defect-free image; (b) image with stack defect; (c) image with gap defect

给定光纤环图像 \mathbf{X} ,它可以分解为表示光纤环纹理的低秩矩阵 \mathbf{D} 和表示缺陷的稀疏矩阵 \mathbf{E} ,则优化问题表示为

$$\min_{\mathbf{D}, \mathbf{E}} \left[\text{rank}(\mathbf{D}), \|\mathbf{E}\|_l \right] \quad \text{s.t.} \quad \mathbf{X} = \mathbf{D} + \mathbf{E}, \quad (1)$$

式中: $\text{rank}(\cdot)$ 表示秩函数; $\|\cdot\|_l$ 是矩阵的 l 范数,代表某种正则化策略,例如 l_0 范数用于对稀疏随机噪声进行建模^[25], $l_{2,0}$ 范数用于处理区别于样本的损坏和异常值^[26], $\|\cdot\|_F^2$ 用于模拟高斯噪声^[27]。优化问题式(1)是一个难以求解的双目标优化问题,因此可以将其转换为单目标优化问题:

$$\min_{\mathbf{D}, \mathbf{E}} \text{rank}(\mathbf{D}) + \lambda \|\mathbf{E}\|_{2,0} \quad \text{s.t.} \quad \mathbf{X} = \mathbf{D} + \mathbf{E}, \quad (2)$$

式中: $\lambda(\lambda > 0)$ 是用于平衡低秩矩阵和噪声分量的参数。从式(2)中不仅可以获得样本 \mathbf{X} 的低阶表示,而且可以识别噪声信息 \mathbf{E} 。然而, $\text{rank}(\mathbf{D})$ 和 $\|\mathbf{E}\|_l$ 是非连续、非线性和非凸的组合优化函数。因此式(2)是一个NP-hard问题。

核范数 $\|\mathbf{D}\|_* = \sum_{m=1}^M \delta_m(\mathbf{D})$ 是 $\text{rank}(\mathbf{D})$ 的凸松弛,因此它可以近似替代 $\text{rank}(\mathbf{D})$,其中 $\delta_m(\mathbf{D})$ 是 \mathbf{D} 的第 m 个奇异值。在特定的几何条件下, $l_{2,1}$ 范数是 $l_{2,0}$ 范数的好松弛^[28]。因此,式(2)可以转换为凸优化问题:

$$\min_{\mathbf{D}, \mathbf{E}} \|\mathbf{D}\|_* + \lambda \|\mathbf{E}\|_{2,1} \quad \text{s.t.} \quad \mathbf{X} = \mathbf{D} + \mathbf{E}. \quad (3)$$

为了处理混合数据矩阵并且更有效地分离噪声,引入字典学习理论,以生成针对优化问题的更通用模型:

$$\min_{\mathbf{Z}, \mathbf{E}} \|\mathbf{Z}\|_* + \lambda \|\mathbf{E}\|_{2,1} \quad \text{s.t.} \quad \mathbf{X} = \mathbf{B}\mathbf{Z} + \mathbf{E}, \quad (4)$$

式中: \mathbf{B} 为线性跨越数据空间的“字典”; \mathbf{Z} 表示重构系数矩阵,代表数据 \mathbf{X} 相对于字典 \mathbf{B} 的最低秩表示。低秩矩阵 \mathbf{D} 的最优解的问题被转换为寻找系数矩阵 \mathbf{Z} 的最优解的问题。通过选择合适的字典,解决凸优化问题式(4),可以准确恢复原始数据的行空间,并分离出稀疏部分,从而得到缺陷检测结果。

2.2 拉普拉斯正则化约束

正常的纹理和缺陷具有相似的外观,导致原始数据空间中样本之间的实际距离受到影响,因此很难保证缺陷检测的质量。为了解决这个问题,提出一种改进的LRR模型,算法流程如图2所示。改进的LRR模型通过引入拉普拉斯正则化作为平滑约束项,即如果两个空间相邻的子区域具有相似的几何结构,则这两个子区域的表示应该也通用于其他区域。拉普拉斯正则化定义为

$$\phi(\mathbf{Z}) = \frac{1}{2} \sum_{i,j=1}^N w_{i,j} \|\mathbf{z}_i - \mathbf{z}_j\|_2^2 = \mathbf{Z}^T \mathbf{L}_M \mathbf{Z}, \quad (5)$$

式中: \mathbf{z}_i 表示 \mathbf{Z} 的第 i 列; $w_{i,j}$ 是亲和矩阵 \mathbf{W} 的第 (i, j) 个元素,表示相邻补丁对之间特征相似度的权重; \mathbf{L}_M 是拉普拉斯矩阵。亲和矩阵 \mathbf{W} 定义为

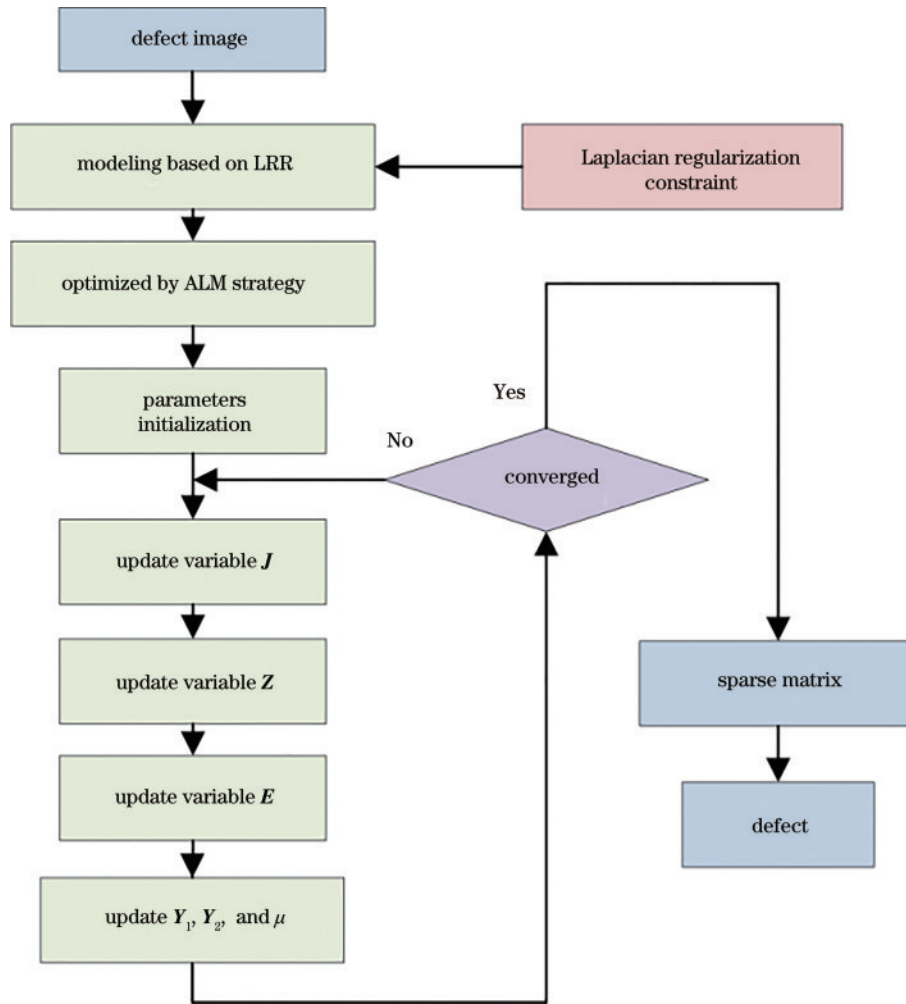


图 2 基于改进 LRR 模型的缺陷检测流程

Fig. 2 Flowchart of defect detection based on the improved LRR model

$$w_{i,j} = \begin{cases} \exp\left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|_2^2}{2\sigma^2}\right), & (P_i, P_j) \in \mathbb{N} \\ 0, & (P_i, P_j) \notin \mathbb{N} \end{cases}, \quad (6)$$

式中： \mathbf{x}_i 表示图像块 P_i 的第 i 列； σ 是调整相似度的参数； \mathbb{N} 表示相邻图像对的集合。

拉普拉斯正则化可以通过平滑系数矩阵中的向量来增加低秩空间和稀疏空间之间的差距，有效地发掘数据的分组结构，即具有相似分布的图像块共享相似或相同的表示，而不同分布的图像块具有不同的表示。将拉普拉斯正则化以加权的方式施加到 LRR 模型中，表达式为

$$\min_{Z,E} \|\mathbf{Z}\|_* + \lambda \|\mathbf{E}\|_{2,1} + \gamma \psi(\mathbf{Z}) \quad \text{s.t.} \quad \mathbf{X} = \mathbf{BZ} + \mathbf{E}, \quad (7)$$

式中： λ 和 γ 均代表模型的正平衡参数。拉普拉斯正则化器强制在原始空间中接近的样本具有相似的表示。通过这样做，聚类性能显著提高，低秩恢复得到增强。

2.3 解决模型优化问题

所提优化问题能够利用增广拉格朗日函数法 (ALM)^[29] 得到解决，它具有较少的迭代次数、较高的

精度和良好的收敛性。选择观察矩阵 \mathbf{X} 作为字典矩阵，得到优化问题^[28]：

$$\min_{Z,E} \|\mathbf{Z}\|_* + \lambda \|\mathbf{E}\|_{2,1} + \gamma \psi(\mathbf{Z}, \mathbf{E}) \quad \text{s.t.} \quad \mathbf{X} = \mathbf{XZ} + \mathbf{E}. \quad (8)$$

为了方便地找到最佳解，引入变量 \mathbf{J} 将式 (8) 转换为等价优化问题：

$$\min_{Z,E} \|\mathbf{J}\|_* + \lambda \|\mathbf{E}\|_{2,1} + \gamma \mathbf{Z}^T \mathbf{L}_M \mathbf{Z} \quad \text{s.t.} \quad \mathbf{X} = \mathbf{XZ} + \mathbf{E}, \mathbf{Z} = \mathbf{J}. \quad (9)$$

于是构造的增广拉格朗日函数为

$$L(\mathbf{J}, \mathbf{Z}, \mathbf{E}, \mathbf{Y}_1, \mathbf{Y}_2, \mu) = \|\mathbf{J}\|_* + \lambda \|\mathbf{E}\|_{2,1} + \gamma \mathbf{Z}^T \mathbf{L}_M \mathbf{Z} + \langle \mathbf{Y}_1, \mathbf{X} - \mathbf{XZ} - \mathbf{E} \rangle + \langle \mathbf{Y}_2, \mathbf{Z} - \mathbf{J} \rangle + \frac{\mu}{2} (\|\mathbf{X} - \mathbf{XZ} - \mathbf{E}\|_F^2 + \|\mathbf{Z} - \mathbf{J}\|_F^2), \quad (10)$$

式中： $\mu > 0$ 为惩罚因子； \mathbf{Y} 为拉格朗日乘子； $\langle \cdot, \cdot \rangle$ 代表内积。对于每次迭代，通过最小化增广拉格朗日函数来找到 \mathbf{X}_k ，然后根据 \mathbf{X}_k 和 μ 求向量 \mathbf{Y}_{k+1} ，重复执行这两个步骤，直到满足某些条件为止，此时 \mathbf{X}_k 收敛到最优解。

交替最小化方案通过最小化拉格朗日函数来更新变量，于是将 L 的最小化问题分解为对 $\mathbf{J}, \mathbf{Z}, \mathbf{E}$ 最小化

的 3 个子问题。算法 1 总结了优化过程的伪代码,具体流程如图 3 所示,优化过程如下。

1) 固定其他变量,优化 J :

$$J = \arg \min \frac{1}{\mu} \|J\|_* + \frac{1}{2} \left\| J - \left(Z + \frac{Y_2}{\mu} \right) \right\|_F^2. \quad (11)$$

通过文献[30]中的定理 1,可以通过奇异值阈值方法(SVT)对式(11)进行优化,可得到

$$J = D_\tau \left(Z + \frac{Y_2}{\mu} \right) = UD_\tau(\Sigma)V^T, \quad (12)$$

式中: $D_\tau(\Sigma) = \text{diag}(\{\sigma_i - \tau\}_+)$ 为软阈值操作, $+$ 表示使奇异值 σ_i 趋向于 0。因此,可以通过对矩阵 $Z + \frac{Y_2}{\mu}$ 进行奇异值分解,将较小的奇异值设置为 0,进行迭代来求解 J 。

Algorithm 1: solve objective function Equ.(10) via ALM

Input: data matrix X , Laplacian matrix L_M , and regularization parameters λ, γ ;
Output: Z^*, S^* ;
Initialization: $Z=S=J=Y_1=Y_2=0, \rho>1, \mu>0$;
While not converged, do
Update J via Equ. (11);
Update Z via Equ.(13);
Update E via Equ.(15);
Update Y_1, Y_2 , and μ ;
End

图 3 算法 1 的流程

Fig. 3 Flowchart of algorithm 1

2) 固定其他变量,优化 Z :

$$Z = \arg \min \frac{1}{2} \left\| X - XZ + \frac{Y_1}{\mu} \right\|_F^2 + \frac{1}{2} \left\| Z - J + \frac{Y_2}{\mu} \right\|_F^2 + \gamma Z^T L_M Z, \quad (13)$$

Z 有闭式解:

$$Z = \left(X^T X + I + \gamma L_M \right)^{-1} \left[X^T (X - E) + J + \frac{X^T Y_1 - Y_2}{\mu} \right]. \quad (14)$$

3) 固定其他变量,优化 E :

$$E = \arg \min \lambda \frac{\|E\|_{2,1}}{\mu} + \frac{1}{2} \left\| E - \left(X - XZ + \frac{Y_1}{\mu} \right) \right\|_F^2. \quad (15)$$

根据文献[31]中的引理,求解 E 的公式为

$$E = \max \left\{ \left\| X - XZ + \frac{Y_1}{\mu} \right\|_2 - \lambda, 0 \right\} \times \frac{X - XZ + \frac{Y_1}{\mu}}{\left\| X - XZ + \frac{Y_1}{\mu} \right\|_2}. \quad (16)$$

4) 更新 Y_1, Y_2 :

$$Y_1 = Y_1 + \mu(X - XZ - E), \quad (17)$$

$$Y_2 = Y_2 + \mu(Z - J). \quad (18)$$

5) 更新 μ :

$$\mu = \min(\mu_{\max}, \rho\mu), \quad (19)$$

式中: $\mu > 0$ 是一个常数。

2.4 基于幂法的 SVD

在上述算法中,矩阵奇异值分解(SVD)是其中一个重要步骤。由于计算量大和收敛速度慢,SVD将消耗大量的时间和硬件资源。所提算法基于幂迭代法来求解 SVD,相比于原先的 SVD,这种方法更有效,因为不需要计算矩阵的所有奇异值,只需求解前 s 个最大奇异值及其对应的奇异向量,因此效率更高。

对于一个实矩阵 $A \in \mathbf{R}^{m \times n}$,存在正交实矩阵 $U \in \mathbf{R}^{m \times m}$ 、 $V \in \mathbf{R}^{n \times n}$ 和一个正对角矩阵 $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r, 0, \dots) \in \mathbf{R}^{n \times m}$,使得 $A = U\Sigma V^T$ 。令 $U = [u_1, \dots, u_m]$, $V = [v_1, \dots, v_n]$,得到 $A = \sum_{k=1}^r \sigma_k u_k v_k^T$, $Av_k = \sigma_k u_k$ 和 $A^T u_k = \sigma_k v_k$ 。直接使用幂方法只能获取到最大的奇异值及其奇异向量。通过构造一个初始向量序列 $V^0 \in \mathbf{R}^{n \times s}$ 和两个向量序列 $U^k \in \mathbf{R}^{m \times s}$ 和 $V^k \in \mathbf{R}^{n \times s}$,利用幂法迭代, U^k 和 V^k 可分别收敛于对应于奇异值 $\sigma_1 \geq \dots \geq \sigma_s$ 的左右奇异向量。算法 2 具体过程的伪代码如图 4 所示。

Algorithm 2: solve SVD based on power method

Input: matrix $A \in \mathbf{R}^{m \times n}$, vector sequence $V^0 \in \mathbf{R}^{n \times s}$, tolerance t ;
Output: orthogonal matrix $U = [u_1, \dots, u_m]$, $V = [v_1, \dots, v_n]$, diagonal array $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_s)$;
Initialization: $V^0 = \text{eye}(n, s)$, $\text{eye}(\cdot)$ is Matlab function;
While $e > t$, do
 $AV = QR$ (QR decomposition), $U \leftarrow Q(:, 1:s)$;
 $A^T U = QR$, $V \leftarrow Q(:, 1:s)$, $\Sigma \leftarrow R(1:s, 1:s)$;
 $e = \|AV - U\Sigma\|$;
End

图 4 算法 2 的流程

Fig. 4 Flowchart of algorithm 2

3 实验与分析

根据缺陷特征,缺陷可分为两种类型:叠丝,即光纤匝落到上一匝;间隙,即光纤从当前落点过渡到下一个落点。为了评估所提缺陷检测方法的可靠性,采集包含不同类别缺陷的图像组成数据集用于实验,其中包含叠丝区域 300 个,间隙区域 300 个,另外选取同样数量的无缺陷区域用于比较。图像采集设备为大恒水星系列 CMOS 工业相机,像素精度为 8 bit。

在低秩恢复中,根据经验,将模型参数 λ 和 γ 分别设置为 0.09 和 0.1,在正则化约束中, σ^2 设置为 0.05。对输出结果图进行手动判断,以此作为性能评估的标准。如果所提方法检测出的缺陷位置与手动检测结果一致,则认为所提方法得出的检测结果是正确的,相反,则认为错误的检测。

为了评估所提方法检测的准确性,以数据集的每个缺陷区域为基本度量单位,计算几种定量评价指标:精度(P_r)、召回率(R_c)、特异度(S_p)和准确率(A_c)。将缺陷定义为阳性 P,将正常定义为阴性 N, TP(true

positive)表示真阳性, TN(true negative)表示真阴性, FP(false positive)表示假阳性, FN(false negative)表示假阴性。则上述指标可以表示为 $P_r = N_{TP} / (N_{TP} + N_{FP})$, $R_c = N_{TP} / (N_{TP} + N_{FN})$, $S_p = N_{TN} / (N_{TN} + N_{FP})$, $A_c = (N_{TP} + N_{TN}) / (N_{TP} + N_{FP} + N_{FN} + N_{TN})$ 。另外, 误检率(FAR)和漏检率(MAR)也被采用来衡量算法的性能, 计算公式分别为 $R_{FA} = N_{FP} / (N_{FP} + N_{TN})$, $R_{MA} = N_{FN} / (N_{TP} + N_{FN})$ 。

3.1 模型分析和讨论

为了证明提出的拉普拉斯正则化约束的有效性,




图 5 正则化约束项对模型的影响。(a)原图;(b)原始 LRR 模型结果;(c)正则化约束后的模型结果
Fig. 5 Influence of regularization constraint on the model. (a) Original image; (b) result of original LRR model; (c) result of regularized constrained model

3.2 缺陷检测结果

对所提方法在数据集上进行实验, 定量检测结果如表 1 所示。对于叠丝缺陷, 所提方法的检测成功率为 97.8%, 误检率为 2.7%, 漏检率为 0; 对于间隙缺陷, 所提方法仍然具有高达 97.2% 的检测成功率, 误检率为 1.7%, 漏检率为 1.3%。这表明所提缺陷检测算法对光纤环绕制过程中出现的错误具有可靠的性能, 且对不同的缺陷类型是鲁棒的, 在实际应用中可以满足光纤环缺陷检测的准确性要求。

表 1 所提方法的实验结果统计

Table 1 Statistics of experimental results of the proposed method

| Defect | method | | | | | |
|--------|--------|-------|-------|-------|-----|-----|
| | P_r | R_c | S_p | A_c | FAR | MAR |
| Stack | 97.4 | 100 | | 97.8 | 2.7 | 0 |
| Gap | 98.3 | 98.7 | | 97.2 | 1.7 | 1.3 |
| Normal | | | 95.7 | 98.1 | 4.3 | 0 |

3.3 与现有算法的对比

为了验证所提算法的优越性, 将其与现有算法在相同数据集上进行对比实验。表 2 为所提算法与其他几种算法之间的比较结果, 可以看出, 相比而言, 所提算法实现了最高的准确率、最低的误检率和漏检率。结果说明了所提算法在检测准确率方面的优势, 体现出所提 LRR 模型用于光纤环缺陷检测的有效性、可靠性和实用性。

为了直观比较, 图 6 和图 7 显示了所提方法及其他光纤环缺陷检测方法的结果。可以观察到: 所提方法

图 5 为添加约束项前后的缺陷检测可视化结果。可以直观地看出: 不添加约束项的模型检测效果较差; 通过集成拉普拉斯正则化约束项, 可以充分检测缺陷信息, 同时有效地抑制了不突出的背景干扰, 证明拉普拉斯正则化约束对提高缺陷检测性能是有效的。另外, 图 5 也说明了建立的低秩表示模型对检测两种缺陷都是有效的, 说明所提模型具有较强的通用性, 可以用统一的模型来描述不同类型的缺陷图像。因此对于任意的光纤环缺陷, 都可以采用所提模型, 检测方法一致。

表 2 不同算法之间的性能比较

Table 2 Performance comparison between different algorithms

| Algorithm | unit: % | | | | | |
|------------------------|-------------|------|------|-----------|-----|------|
| | Fiber-stack | | | Fiber-gap | | |
| | P_r | FAR | MAR | P_r | FAR | MAR |
| Algorithm in Ref. [14] | 71.3 | 36.7 | 28.7 | 73.7 | 6.4 | 26.2 |
| Algorithm in Ref. [15] | 81.7 | 7.1 | 18.3 | 85.3 | 2.1 | 14.7 |
| LBP+SVM | 90.7 | 4.6 | 9.3 | 91.7 | 5.9 | 8.3 |
| Proposed algorithm | 97.4 | 2.7 | 0 | 98.3 | 1.7 | 1.3 |

可以精确地提取出整个缺陷对象, 轮廓清晰, 缺陷完整度高, 且与正常的光纤环纹理具有很好的分离性; 而其他方法采用边框定位缺陷区域, 容易将部分背景视为缺陷, 具有较低的检测准确率。结果进一步说明了所提方法对光纤环缺陷检测的有效性和优越性。

3.4 计算复杂度分析

基于 LRR 的算法使用幂法迭代的思想代替 SVD, 将减小算法的计算量。假设 X 的大小为 $m \times n$ ($m > n$)。SVD 是需要计算 $n \times n$ 矩阵的。 Z 的行数不会超过 r_x (X 的秩), 因此 SVD 的计算复杂度为 $O(mnr_x + nr_x^2 + r_x^3)$ 。利用幂法迭代, 计算复杂度缩减为 $O(2ns^2)$ 。另外在所提算法中数据矩阵 X 被用作字典矩阵, 计算复杂度最大为 $O(mn^2 + n^3)$ 。考虑到正交化的成本和收敛所需的迭代次数, 最终所提算法的复杂度为 $O(mn^2) + O(2n_s ns^2)$, 其中 n_s 是迭代次数。 n_s 的值取决于 ρ 的大小。 ρ 越大, n_s 越小, 反之亦然。尽管选择较大的 ρ 值能够产生更高的效率, 但同时也




图 6 叠丝缺陷的原始图像及对应的缺陷检测结果。(a)原图;(b)所提方法;(c)文献[14]中的方法;(d)文献[15]中的方法;(e)LBP+SVM

Fig. 6 Original images of the stack defect and their detection results. (a) Original images; (b) proposed method; (c) method in Ref. [14]; (d) method in Ref. [15]; (e) LBP+SVM




图 7 间隙缺陷的原始图像及对应的缺陷检测结果。(a)原图;(b)所提方法;(c)文献[14]中的方法;(d)文献[15]中的方法;(e)LBP+SVM

Fig. 7 Original images of the gap defect and their detection results. (a) Original images; (b) proposed method; (c) method in Ref. [14]; (d) method in Ref. [15]; (e) LBP+SVM

面临错过最优解的风险。在本文中,设置 $\rho=1.1$ 。所有实验的硬件环境为 Intel(R) Core(TM) i5-2450M CPU 2.50 GHz, 8GB RAM。为了比较改进 SVD 前后的运行效率,计算 100 张图片的平均运行时间。使用 SVD 求解的算法平均运行时间为 10.58 s,使用幂法改进后的平均运行时间为 4.35 s,比先前快了 2 倍,从而降低了时间和硬件成本。

4 结 论

提出一种基于改进低秩表示模型的光纤环缺陷检测新方法。通过引入拉普拉斯正则化约束,实现了高

质量的缺陷分离,同时利用幂法替代原始的 SVD,节省了昂贵的硬件资源。所提方法简单易行,无需训练图像即可实现。理论和实验结果都表明,所提方法对光纤环缺陷检测是有效的,并且有较高的准确率,且始终优于其他方法。然而,所提算法仍然存在问题,字典的选择特定于 $B=X$ 的情况。在未来的工作中,将进一步探索所提方法是否可以扩展到除 X 之外的一般字典矩阵。

参 考 文 献

- [1] Barrett B, Geiger R, Dutta I, et al. The Sagnac effect:

- 20 years of development in matter-wave interferometry [J]. *Comptes Rendus Physique*, 2014, 15(10): 875-883.
- [2] Jia M, Yang G L. Research of optical fiber coil winding model based on large-deformation theory of elasticity and its application[J]. *Chinese Journal of Aeronautics*, 2011, 24(5): 640-647.
- [3] Shen C, Chen X Y. Analysis and modeling for fiber-optic gyroscope scale factor based on environment temperature [J]. *Applied Optics*, 2012, 51(14): 2541-2547.
- [4] 丁振扬. 陀螺用光纤环全面质量检测研究[D]. 天津: 天津大学, 2010.
- Ding Z Y. Study of complete quality measurement for FOG fiber coils[D]. Tianjin: Tianjin University, 2010.
- [5] Webber M, Willig R, Rackowski H, et al. Modeling of rate error in interferometric fiber-optic gyroscopes due to stress induced by moisture diffusion[J]. *Journal of Lightwave Technology*, 2012, 30(14): 2356-2362.
- [6] Ge S C, Yang R F, Guo C X. Constant small tension control for fiber optic coil variable-velocity winding[J]. *IEEE Access*, 2019, 7: 172012-172020.
- [7] Duong V T, Doan P T, Min J H, et al. Active real-time tension control for coil winding machine of BLDC motors [C]//2014 International Conference on Advances in Computing, Communications and Informatics (ICACCI), September 24-27, 2014, Delhi, India. New York: IEEE Press, 2014: 765-770.
- [8] Ren S L, Lai Y N, Wang Y Z, et al. Fiber winding precision tension fuzzy control system[J]. *Advanced Materials Research*, 2010, 129/130/131: 370-375.
- [9] Lu J S, Chen H R, Cheng M Y, et al. Tension control improvement in automatic stator in-slot winding machines using iterative learning control[C]//2014 International Conference on Information Science, Electronics and Electrical Engineering, April 26-28, 2014, Sapporo, Japan. New York: IEEE Press, 2014: 1643-1647.
- [10] Ming W Y, Shen F, Li X K, et al. A comprehensive review of defect detection in 3C glass components[J]. *Measurement*, 2020, 158: 107722.
- [11] Huang Y Q, Jing J F, Wang Z. Fabric defect segmentation method based on deep learning[J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70: 5005715.
- [12] Saufi S R, Ahmad Z A B, Leong M S, et al. Gearbox fault diagnosis using a deep learning model with limited data sample[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(10): 6263-6271.
- [13] 张万成, 叶泽群. 一种用于光纤精密绕线的视觉识别技术[J]. *电子工艺技术*, 2015, 36(3): 172-174, 178.
- Zhang W C, Ye Z Q. A design of visual identify cation technology for accurate winding of optical fiber[J]. *Electronics Process Technology*, 2015, 36(3): 172-174, 178.
- [14] Guo C X, Yang R F. The improved defects detection method of optical fiber winding[J]. *Optik*, 2014, 125(2): 675-678.
- [15] 丁清. 基于机器视觉的光纤环绕制缺陷检测系统研究[D]. 太原: 中北大学, 2017.
- Ding Q. Research on detection system of optical fiber winding defects based on machine vision[D]. Taiyuan: North University of China, 2017.
- [16] 杨震. 基于机器视觉的光纤环绕制监测技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2019.
- Yang Z. Research for fiber optic ring winding monitoring technology based on machine vision[D]. Harbin: Harbin Engineering University, 2019.
- [17] 潘文慧, 陈秉灵, 张建国, 等. 基于噪声校正主成分分析的压缩感知 STORM 超分辨率图像重构[J]. *中国激光*, 2020, 47(2): 0207024.
- Pan W H, Chen B L, Zhang J G, et al. Compressed sensing STORM super-resolution image reconstruction based on noise correction-principal component analysis preprocessing algorithm[J]. *Chinese Journal of Lasers*, 2020, 47(2): 0207024.
- [18] 张俊超, 陈澍来, 罗海波, 等. 基于张量非负稀疏分解的偏振图像插值算法[J]. *光学学报*, 2021, 41(14): 1411001.
- Zhang J C, Chen J L, Luo H B, et al. Polarization image interpolation algorithm via tensor non-negative sparse factorization[J]. *Acta Optica Sinica*, 2021, 41(14): 1411001.
- [19] 王佳好, 许金鑫, 李庆武. 基于分层模型和低秩近似的 X 射线图像重建[J]. *激光与光电子学进展*, 2021, 58(6): 0610004.
- Wang J Y, Xu J X, Li Q W. X-ray image reconstruction based on hierarchical model and low-rank approximation [J]. *Laser & Optoelectronics Progress*, 2021, 58(6): 0610004.
- [20] Zhang T Z, Liu S, Xu C S, et al. Structural sparse tracking[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA, USA. New York: IEEE Press, 2015: 150-158.
- [21] 谢骏, 侯国家, 王国栋, 等. 基于红通道稀疏先验的水下图像盲复原[J]. *激光与光电子学进展*, 2021, 58(16): 1610014.
- Xie J, Hou G J, Wang G D, et al. Blind restoration for underwater image based on sparse prior of red channel[J]. *Laser & Optoelectronics Progress*, 2021, 58(16): 1610014.
- [22] Zha Z Y, Yuan X, Wen B H, et al. From rank estimation to rank approximation: rank residual constraint for image restoration[J]. *IEEE Transactions on Image Processing*, 2019, 29: 3254-3269.
- [23] 刘伟, 葛洪伟. 一种基于稀疏表示的快速人脸识别方法[J]. *激光与光电子学进展*, 2020, 57(18): 181024.
- Liu W, Ge H W. Fast face recognition method based on sparse representation[J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181024.
- [24] Ahmed J, Gao B, Woo W L. Sparse low-rank tensor decomposition for metal defect detection using thermographic imaging diagnostics[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 1810-1820.
- [25] Candès E J, Li X D, Ma Y, et al. Robust principal component analysis[J]. *Journal of the ACM*, 2011, 58(3): 1-37.
- [26] Liu G C, Lin Z C, Yu Y. Robust subspace segmentation by low-rank representation[C]//Proceedings of the 27th International Conference on Machine Learning, June 21-

- 24, 2010, Haifa, Israel. New York: International Machine Learning Society, 2010: 663-670.
- [27] Candes E J, Plan Y. Matrix completion with noise[J]. Proceedings of the IEEE, 2010, 98(6): 925-936.
- [28] Liu G C, Lin Z C, Yan S C, et al. Robust recovery of subspace structures by low-rank representation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(1): 171-184.
- [29] 张贤达. 矩阵分析与应用[M]. 2 版. 北京: 清华大学出版社, 2013.
- Zhang X D. Matrix analysis and applications[M]. 2nd ed. Beijing: Tsinghua University Press, 2013.
- [30] Lei Y W, Zhou D X. Analysis of singular value thresholding algorithm for matrix completion[J]. Journal of Fourier Analysis and Applications, 2019, 25(6): 2957-2972.
- [31] Yang J F, Yin W T, Zhang Y, et al. A fast algorithm for edge-preserving variational multichannel image restoration [J]. SIAM Journal on Imaging Sciences, 2009, 2(2): 569-592.