

DOI:10.16136/j.joel.2023.08.0538

基于F范数的二维主成分分析算法及焊缝表面缺陷识别研究

方建雄¹, 王肖锋^{1,2}, 王成林^{1,2*}

(1. 天津理工大学 机械工程学院, 天津市先进机电系统设计与智能控制重点实验室, 天津 300384; 2. 机电工程国家级实验教学示范中心, 天津理工大学, 天津 300384)

摘要: 针对传统二维主成分分析(two-dimensional principal component analysis, 2DPCA)算法应用于焊缝表面缺陷识别中存在重构性能及鲁棒性较弱等问题, 本文将最大化投影距离和最小化重构误差引入到目标函数中, 提出了一种基于F范数的非贪婪二维主成分分析算法(non-greedy 2DPCA with F-norm, NG-2DPCA-F), 该算法具有良好的鲁棒性和较低的重构误差。为了进一步提取图像的结构信息和求解出维数更小的特征矩阵, 进而提出一种基于F范数的非贪婪双向二维主成分分析算法(non-greedy bilateral 2DPCA with F-norm, NG-B2DPCA-F)。最后, 以含有不同噪声块的焊缝表面图像数据集进行实验, 结果表明, 本文所提算法在平均重构误差、重构图像与分类识别实验中均表现出良好的鲁棒性能。

关键词: 二维主成分分析(2DPCA); 焊缝表面缺陷; 特征提取; 缺陷识别

中图分类号: TG441.7 **文献标识码:** A **文章编号:** 1005-0086(2023)08-0872-10

Research on F-norm-based two-dimensional principal component analysis algorithm for weld surface defect recognition

FANG Jianxiong¹, WANG Xiaofeng^{1,2}, WANG Chenglin^{1,2*}

(1. Tianjin Key Laboratory for Advanced Mechatronic System Design and Intelligent Control, School of Mechanical Engineering, Tianjin University of Technology, Tianjin 300384, China; 2. National Demonstration Center for Experimental Mechanical and Electrical Engineering Education, Tianjin University of Technology, Tianjin 300384, China)

Abstract: Aiming at the problems of weak reconstruction performance and robustness in the traditional two-dimensional principal component analysis (2DPCA) algorithm applied to weld surface defect detection, maximizing the projection distance and minimizing the reconstruction error are introduced into the objective function as optimization objectives. And a non-greedy two-dimensional principal component analysis algorithm based on F-norm (non-greedy 2DPCA with F-norm, NG-2DPCA-F) is proposed. This algorithm has good robustness and low reconstruction error. In order to further extract the structural information of the image and obtain the feature matrix with smaller dimension, this paper proposes a bidirectional two-dimensional principal component analysis algorithm based on F-norm (non-greedy bilateral 2DPCA with F-norm, NG-B2DPCA-F). The experiments are carried out with weld surface images with different noise blocks as datasets. The results demonstrate that the proposed algorithm has good robustness in the average reconstruction error, reconstruction image and classification experiments.

Key words: two-dimensional principal component analysis (2DPCA); weld surface defect; feature extraction; defect recognition

0 引言

在焊接过程中, 由于环境条件和焊接工艺的

不同, 焊接表面缺陷是难以避免的^[1]。其在一定程度上降低了焊件的使用寿命和结构强度, 但人工检测焊缝质量通常需要工作经验和先验知识,

* E-mail: 791374074@qq.com

收稿日期: 2022-07-23 修订日期: 2022-09-12

基金项目: 国家重点研发计划 (2018AAA0103004) 和天津市科技计划重大专项 (20YFZCGX00550) 资助项目

这种方法相对缺乏客观性^[2]。而现有常用的焊缝质量无损检测方法如射线照相检测^[3]、超声波检测^[4]、涡流检测^[5]和液体渗透剂检测^[6]等都相对存在缺乏效率、检测成本高及不能有效提取焊缝缺陷特征等问题。在焊缝缺陷检测中,有效特征的提取是至关重要的一环,这将直接影响缺陷检测的准确性,而面对大量的数据样本,如何从中提取到有效的特征也尤为重要。

为了寻求一种有效提取缺陷特征的焊缝缺陷检测方法,许多学者采用图像处理技术和深度学习算法,提出了一些特征提取方法。RANJAN等^[7]提出一种用于检测焊缝表面缺陷的图像处理方法,但受限于缺陷特征,难以完成有效提取。LI等^[8]对焊接质量与焊缝缺陷图像的几何特征及纹理特征建立了模型,实现了对焊缝缺陷的检测。DUAN等^[9]提取了X射线图像中焊接缺陷的灰度特征和几何特征,提出了一种的自适应级联提升算法(adaptive cascade boosting, AdaBoost)。以上基于图像处理技术的缺陷特征提取方法都受限于缺陷外观和光照条件,且提取到的特征通常携带冗余信息。MIAO等^[10]提出一种将连续小波变换(continuous wavelet transform, CWT)与卷积神经网络(convolutional neural network, CNN)相结合的方法,提高了缺陷提取能力。ZHANG等^[11]设计了一种用于焊缝表面缺陷识别的CNN模型。谷静等^[12]提出一种基于Faster R-CNN(faster region-based convolutional neural network)^[13]的焊缝缺陷检测算法,其将膨胀卷积运算^[14]与Faster R-CNN相结合,提高了缺陷的识别能力。深度学习算法虽然能提取到焊缝图像中的表面缺陷特征,但是需要大量的训练样本与训练时间。

针对图像处理技术和深度学习算法在应用于焊缝表面缺陷时所存在的问题,一些学者基于主成分分析(principal component analysis, PCA)^[15]算法,提出了可提取焊缝图像中表面缺陷特征的方法。ZHANG等^[16]使用PCA提取了激光焊接的缺陷特征。HE等^[17]基于PCA与支持向量机(support vector machine, SVM)^[18],对铝合金的焊缝表面缺陷特征进行提取。但是PCA在提取图像的低维特征时,需要将图像张量数据转化为向量形式,破坏了图像的整体空间结构。针对这一问题,有学者提出了二维主成分分析(two-dimensional principal component analysis, 2DPCA)^[19]算法,其以矩阵的形式对图像进行低维表征,降低了整个算法的计算复杂度。对于2DPCA仅对样本数据行方向的特征进行提取,致使列方向特征信息丢失的问题,YANG等^[20]提出了行列顺序二维

主成分分析(row-column two-dimensional PCA, RC2DPCA)算法,先后从行方向和列方向对数据进行特征提取,求解出了维数更小的特征矩阵。为了进一步提高算法的鲁棒性,LI等^[21]提出了基于L1范数的2DPCA算法(2DPCA with L1-norm greedy, 2DPCA-L1-G),在融合贪婪求解的基础上其目的在于在投影空间中得到基于L1范数度量下的最大投影距离,相较于2DPCA和RC2DPCA所采用的F范数平方的度量方式有着更强的鲁棒性。而对于2DPCA-L1-G算法存在投影距离最大和重构误差最小不能同时取得的情况,GAO等^[22]提出了基于F范数度量的角度二维主成分分析(Angle-2DPCA),其将重构误差与投影距离的比值作为了需要优化的目标函数。WANG等^[23]以向量2范数作为距离度量方式,提出了Cos-2DPCA算法,该算法参数可调的性质使其具优良的鲁棒性。ZHOU等^[24]又在此基础上提出了角度双向二维主成分分析(bilateral Angle 2DPCA, BA2DPCA),进一步提高了算法的特征提取能力。李进军等^[25]基于双向2DPCA结合主成分分析网络(PCANet)提出一种用于焊缝表面缺陷检测的鲁棒非贪婪双向二维PCANet(RNG-BDPCANet)算法,提高了鲁棒性,但因采用双向2DPCA作卷积核,所以网络计算复杂度高,求解时间较长。葛为民等^[26]在2DPCA的基础上提出了一种基于泛化的增量式2DPCA的特征提取算法,提高了检测的实时性。

本文在总结前人研究结果的基础上,先提出了一种基于F范数的非贪婪求解的二维主成分分析算法(non-greedy 2DPCA with F-norm, NG-2DPCA-F),提高了算法的重构性能和鲁棒性,降低噪声对焊缝表面缺陷特征提取的影响,后进一步提出一种基于F范数非贪婪求解的双向二维主成分分析算法(non-greedy bilateral 2DPCA with F-norm, NG-B2DPCA-F),增加了算法对样本数据的列方向信息的提取能力,进而获得了维数更小的投影特征矩阵。使用焊缝表面图像数据集进行缺陷特征提取、图像重构及分类实验,实验结果表明本文所提算法具有良好的图像重构性能及鲁棒性。

1 相关算法

假设存在 n 张已经过中心化处理的尺寸为 $m \times h$ 的图像样本数据 $\{\mathbf{A}_i \in \mathcal{R}^{m \times h}, i = 1, 2, \dots, n\}$, 满足 $\sum_{i=1}^n \mathbf{A}_i = \mathbf{0}$, 则存在如下关系:

$$\|\mathbf{E}_i\|_F^2 + \|\mathbf{A}_i \mathbf{W}\|_F^2 = \|\mathbf{A}_i\|_F^2, \quad (1)$$

式中, $\|\cdot\|_F$ 定义为矩阵的 Frobenius 范数, $\mathbf{W} =$

$[\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k] \in \mathcal{R}^{h \times k}$ 为由前 k 个主成分(principal components, PCs)构成的投影矩阵, $\mathbf{A}_i$ 为第 i 张样本图像数据, $\|\mathbf{A}_i \mathbf{W}\|_F$ 和 $\|\mathbf{E}_i\|_F = \|\mathbf{A}_i - \mathbf{A}_i \mathbf{W} \mathbf{W}^T\|_F$ 分别为第 i 张图像样本的投影距离的 F 范数与重构误差的 F 范数。

1.1 基于 F 范数的 Angle-2DPCA

对于 2DPCA-L1-G 算法存在不能同时满足重构误差最小和投影距离最大的问题,因此以重构误差与投影距离的比值作为目标函数的基于 F 范数的 Angle-2DPCA^[22] 被提出,当该比值最小时则可以求解出最优的投影矩阵 $\mathbf{W}$ 。该算法的目标函数为:

$$\arg \min_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{A}_i \mathbf{W}\|_F}, \quad (2)$$

式中, $\mathbf{I}_{k \times k}$ 为 $k \times k$ 阶的单位矩阵, $\|\mathbf{E}_i\|_F / \|\mathbf{A}_i \mathbf{W}\|_F$ 的值可以看作角 α_i 的正切值,如图 1 所示。图 1 是由式(1)从几何角度抽象成一个直角三角形获得。其令 $G(\mathbf{W}) = \sum_{i=1}^n \mathbf{A}_i^T \mathbf{A}_i d_i, d_i = 1 / \|\mathbf{A}_i \mathbf{W}\|_F \|\mathbf{E}_i\|_F$, 对式(2)进行转换得:

$$\begin{aligned} \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{A}_i \mathbf{W}\|_F} &= \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F^2}{\|\mathbf{A}_i \mathbf{W}\|_F^2 \|\mathbf{E}_i\|_F} = \\ \sum_{i=1}^n \frac{\|\mathbf{A}_i\|_F^2 - \|\mathbf{A}_i \mathbf{W}\|_F^2}{\|\mathbf{A}_i \mathbf{W}\|_F^2 \|\mathbf{E}_i\|_F} &= \\ \sum_{i=1}^n (tr(\mathbf{A}_i^T \mathbf{A}_i d_i) - tr(\mathbf{W}^T \mathbf{A}_i^T \mathbf{A}_i d_i \mathbf{W})) &= \\ tr(G(\mathbf{W}) - \mathbf{W}^T G(\mathbf{W}) \mathbf{W}), \end{aligned} \quad (3)$$

式中, $tr(\cdot)$ 为矩阵的迹。




图 1 第 i 张图像的重构误差与投影距离

Fig. 1 Reconstruction error and projection distance of the i -th image

由于权重系数 d_i 和投影矩阵 $\mathbf{W}$ 都是变量,因此对于 Angle-2DPCA 的目标函数式(2)的求解,文献[22]采用了贪婪迭代方式进行求解,即预先给定一个投影矩阵 $\mathbf{W}$, $\mathbf{W}$ 更新迭代可以靠对 $G(\mathbf{W})\mathbf{W}$ 进行奇异值分解(singular value decomposition, SVD),得到 $G(\mathbf{W})\mathbf{W} = \mathbf{U} \mathbf{A} \mathbf{V}^T$, 则更新后的 $\mathbf{W} = \mathbf{U} \mathbf{V}^T$, 反复更新迭代直至求得最优投影矩阵,即目标函数式(2)的解。

相较于以 L1 范数作为度量方式的 2DPCA-L1-G 算法, Angle-2DPCA 算法因采用 F 范数作为度量方式从而提高了鲁棒性。

1.2 基于 F 范数的 BA2DPCA

Angle-2DPCA 算法的目标函数中的重构误差的 F 范数与投影距离的 F 范数的比值 $\|\mathbf{E}_i\|_F / \|\mathbf{A}_i \mathbf{W}\|_F$ 是如图 1 中所示的角 α_i 的正切值。而当角 α_i 很小时,存在有 $\tan \alpha_i \approx \sin \alpha_i$, ZHOU 等^[24] 在此基础上提出了另一种基于 F 范数的角度二维主成分分析算法(Sin-2DPCA),其目标函数为:

$$\arg \min_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{A}_i\|_F}, \quad (4)$$

式中, $\|\mathbf{E}_i\|_F / \|\mathbf{A}_i\|_F$ 为重构误差的 F 范数与样本数据的 F 范数的比值,即如图 1 中所示角 α_i 的正弦值,该比值与输入图像的重构误差相关联,从而增加了算法的鲁棒性。

对式(4)进行转换,得:

$$\begin{aligned} \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F}{\|\mathbf{A}_i\|_F} &= \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F^2}{\|\mathbf{A}_i\|_F \|\mathbf{E}_i\|_F} = \\ tr(G(\mathbf{W}_t) - \mathbf{W}_t^T G(\mathbf{W}_t) \mathbf{W}_t), \end{aligned} \quad (5)$$

式中, $G(\mathbf{W}) = \sum_{i=1}^n \mathbf{A}_i^T \mathbf{A}_i / \|\mathbf{A}_i\|_F \|\mathbf{E}_i\|_F$, 在求解该目标函数时,其采用与 Angle-2DPCA 算法相似的解法,则有:

$$\mathbf{W}_{t+1} = \arg \min_{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}} tr(G(\mathbf{W}_t) - \mathbf{W}_t^T G(\mathbf{W}_t) \mathbf{W}_t). \quad (6)$$

对于预先给定的 $\mathbf{W}_t$, 对 $G(\mathbf{W}_t)\mathbf{W}_t$ 进行 SVD 求解,可得到 $G(\mathbf{W}_t)\mathbf{W}_t = \mathbf{U} \mathbf{A} \mathbf{V}^T$, 则 $\mathbf{W}_{t+1} = \mathbf{U} \mathbf{V}^T$ 。

与传统的 2DPCA 相比, Angle-2DPCA 对于异常值都具有更为优良的鲁棒性,但也仅对图像样本进行了行方向上的信息提取,而忽略了列方向上的信息,故 ZHOU 等在 Sin-2DPCA 的基础上进行了改进,提出了基于 F 范数的双向角度二维主成分分析算法(bilateral angle 2DPCA, BA2DPCA)。

BA2DPCA 的求解是在基于 Sin-2DPCA 的基础上进行的,即先对输入图像 $\mathbf{A}_i \in \mathcal{R}^{h \times k}$ 经过 Sin-2DPCA 算法求解得到一个投影矩阵 $\mathbf{W} \in \mathcal{R}^{h \times k}$, 将 $\mathbf{A}_i$ 投影到 $\mathbf{W}$ 上得到 $\mathbf{Y}_i = \mathbf{A}_i \mathbf{W} \in \mathcal{R}^{m \times k}$, 再将 $\mathbf{Y}_i^T \in \mathcal{R}^{k \times m}$ 作为新的样本图像,从而用求解第一个投影矩阵的方法求解第二的投影矩阵 $\mathbf{L} \in \mathcal{R}^{m \times r}$ 。

2 基于 F 范数的双向 2DPCA 算法

2.1 NG-2DPCA-F 算法的求解

在 PCA 领域,使用 L1 范数作为投影距离的度

量方式的算法能很好地抑制图像样本中的离群噪声对于算法鲁棒性的不利影响,但却缺乏以F范数作为度量方式的算法所具有的旋转不变性,致使重构误差没能得到有效的收束。

为了使算法具有旋转不变性,同时兼具在满足投影距离最大的情况下满足重构误差最小的性质,使其在焊缝表面缺陷检测中更具鲁棒性,故在使用F范数作为度量方式的基础上提出一种NG-2DPCA-F,其目标函数为:

$$\underset{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}}{\operatorname{argmin}} \frac{\|\mathbf{E}_i\|_F \times \|\mathbf{A}_i \mathbf{W}\|_F}{\|\mathbf{A}_i\|_F^2}, \quad (7)$$

$$\|\mathbf{E}_i\|_F < \|\mathbf{A}_i \mathbf{W}\|_F,$$

式中,目标函数的分母项 $\|\mathbf{A}_i\|_F^2$ 为第 i 张输入图像的F范数的平方,分子项为重构误差的F范数 $\|\mathbf{E}_i\|_F = \|\mathbf{A}_i - \mathbf{A}_i \mathbf{W} \mathbf{W}^T\|_F$ 与投影距离的F范数 $\|\mathbf{A}_i \mathbf{W}\|_F$ 的乘积,可以看作是如图1中所示直角三角形面积的2倍,在求解过程中需保持 $\|\mathbf{E}_i\|_F < \|\mathbf{A}_i \mathbf{W}\|_F$,即重构误差的F范数小于投影距离的F范数。

对式(7)进行变换,得:

$$\begin{aligned} \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F \times \|\mathbf{A}_i \mathbf{W}\|_F}{\|\mathbf{A}_i\|_F^2} &= \\ \sum_{i=1}^n \frac{\|\mathbf{E}_i\|_F^2 \times \|\mathbf{A}_i \mathbf{W}\|_F}{\|\mathbf{A}_i\|_F^2 \|\mathbf{E}_i\|_F} &= \\ \sum_{i=1}^n \frac{\|\mathbf{A}_i - \mathbf{A}_i \mathbf{W} \mathbf{W}^T\|_F^2 \times \|\mathbf{A}_i \mathbf{W}\|_F}{\|\mathbf{A}_i\|_F^2 \|\mathbf{A}_i - \mathbf{A}_i \mathbf{W} \mathbf{W}^T\|_F} &= \\ \sum_{i=1}^n \operatorname{tr}(\mathbf{A}_i^T \mathbf{A}_i d_i) - \operatorname{tr}(\mathbf{W}^T \mathbf{A}_i^T \mathbf{A}_i d_i \mathbf{W}) &= \\ \operatorname{tr}(G(\mathbf{W})) - \operatorname{tr}(\mathbf{W}^T G(\mathbf{W}) \mathbf{W}), \end{aligned} \quad (8)$$

式中,加权协方差矩阵 $G(\mathbf{W})$ 和权系数 d_i 分别为:

$$G(\mathbf{W}) = \sum_{i=1}^n \mathbf{A}_i^T \mathbf{A}_i d_i, \quad (9)$$

$$d_i = \frac{\|\mathbf{A}_i \mathbf{W}\|_F}{\|\mathbf{A}_i\|_F^2 \|\mathbf{A}_i - \mathbf{A}_i \mathbf{W} \mathbf{W}^T\|_F}. \quad (10)$$

则目标函数可转换为:

$$\underset{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}}{\operatorname{argmin}} [\operatorname{tr}(G(\mathbf{W})) - \operatorname{tr}(\mathbf{W}^T G(\mathbf{W}) \mathbf{W})]. \quad (11)$$

在对目标函数式(11)求解时,因无法同时求解两个相互关联的未知变量 $\mathbf{W}$ 和 d_i ,故本文采用非贪婪的迭代法来求解这两个变量,即先固定 $\mathbf{W}$ 来更新 d_i ,然后固定 d_i 来更新 $\mathbf{W}$ 。即预先初始化一个满足 $\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}$ 的 $\mathbf{W}$,此时目标函数中的第一项 $\operatorname{tr}(G(\mathbf{W}))$ 将为定值,令投影矩阵 $\mathbf{H} = G(\mathbf{W}) \mathbf{W} (\mathbf{H} \in \mathbb{R}^{m \times h})$,则目标函数将转化为:

$$\underset{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}}{\operatorname{argmax}} r(\mathbf{W}^T \mathbf{H}). \quad (12)$$

对矩阵 $\mathbf{H}$ 进行SVD,可得:

$$\mathbf{H} = \mathbf{U} \mathbf{A} \mathbf{V}^T, \quad (13)$$

式中, $\mathbf{U}^T \mathbf{U} = \mathbf{V}^T \mathbf{V} = \mathbf{I}_k$, $\mathbf{A} \in \mathbb{R}^{k \times k}$ 是一个非奇异对角矩阵, $\mathbf{A}$ 的对角元素 λ_i 是矩阵 $\mathbf{H}$ 的奇异值,且 $k = \operatorname{rank}(\mathbf{H})$ 。则有:

$$\begin{aligned} \operatorname{tr}(\mathbf{W}^T \mathbf{H}) &= \operatorname{tr}(\mathbf{W}^T \mathbf{U} \mathbf{A} \mathbf{V}^T) = \\ \operatorname{tr}(\mathbf{U} \mathbf{A}^{\frac{1}{2}} \mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T). \end{aligned} \quad (14)$$

根据矩阵迹的定义有:

$$\operatorname{tr}(\mathbf{W}^T \mathbf{H}) = (\operatorname{vec}(\mathbf{U} \mathbf{A}^{\frac{1}{2}}))^T \operatorname{vec}(\mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T). \quad (15)$$

根据Cauchy-Schwarz不等式将式(15)转换得:

$$\begin{aligned} \operatorname{tr}(\mathbf{W}^T \mathbf{H}) &= (\operatorname{vec}(\mathbf{U} \mathbf{A}^{\frac{1}{2}}))^T \operatorname{vec}(\mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T) \leq \\ \|\operatorname{vec}(\mathbf{U} \mathbf{A}^{\frac{1}{2}})\|_2 \|\operatorname{vec}(\mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T)\|_2 &= \\ \|\mathbf{U} \mathbf{A}^{\frac{1}{2}}\|_F \|\mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T\|_F &= \\ \|\mathbf{A}^{\frac{1}{2}}\|_F \|\mathbf{A}^{\frac{1}{2}}\|_F. \end{aligned} \quad (16)$$

当且仅当 $\mathbf{A}^{\frac{1}{2}} \mathbf{U}^T = \mathbf{A}^{\frac{1}{2}} \mathbf{V}^T \mathbf{W}^T$ 时等号成立,即满足 $\mathbf{W} = \mathbf{U} \mathbf{V}^T$ 时等号成立。

具体迭代求解步骤如下:

第一步:存在一个 $\mathbf{W}^{(t)} \in \mathbb{R}^{h \times k}$ ($k = 1, 2, \dots, h$), 满足 $(\mathbf{W}^{(t)})^T \mathbf{W}^{(t)} = \mathbf{I}_{k \times k}$, 则 $d_i^{(t)}$ 可由下式求得:

$$d_i^{(t)} = \frac{\|\mathbf{A}_i \mathbf{W}^{(t)}\|_F}{\|\mathbf{A}_i\|_F^2 \|\mathbf{A}_i - \mathbf{A}_i \mathbf{W}^{(t)} (\mathbf{W}^{(t)})^T\|_F}. \quad (17)$$

第二步:此时目标函数中的第一项 $\operatorname{tr}(G(\mathbf{W}^{(t)}))$ 将为定值,则目标函数将变为:

$$\underset{\mathbf{W}^T \mathbf{W} = \mathbf{I}_{k \times k}}{\operatorname{argmax}} r((\mathbf{W}^{(t)})^T \mathbf{H}^{(t)}), \quad (18)$$

式中, $\mathbf{W}^{(t)}$ 为第 t 次迭代的 $\mathbf{W}$, $d_i^{(t)}$ 为第 t 次迭代的 d_i , 且有:

$$\mathbf{H}^{(t)} = G(\mathbf{W}^{(t)}) \mathbf{W}^{(t)}, \quad (19)$$

$$G(\mathbf{W}^{(t)}) = \sum_{i=1}^n \mathbf{A}_i^T \mathbf{A}_i d_i^{(t)}. \quad (20)$$

对 $\mathbf{H}^{(t)}$ 进行SVD得:

$$\mathbf{H}^{(t)} = \mathbf{U}^{(t)} \mathbf{A}^{(t)} (\mathbf{V}^{(t)})^T. \quad (21)$$

则目标函数的最优解为:

$$\mathbf{W}^{(t+1)} = \mathbf{U}^{(t)} (\mathbf{V}^{(t)})^T. \quad (22)$$

最佳投影矩阵 $\mathbf{W}$ 通过反复迭代求解式(17)~(22)直至满足收敛要求来获得。

如果图像中存在离群噪声,那么分母项会对整个分式的值进行收束,降低离群噪声对算法识别性能的影响,提高算法的鲁棒性,当目标函数最小时,即可取得最优投影矩阵 $\mathbf{W}$ 。给出如表1的伪代码。

表1 NG-2DPCA-F 算法伪代码

Tab.1 Algorithm procedure of NG-2DPCA-F

Input: Sequence of images $\{A_i \in \mathcal{R}^{m \times h}, i = 1, 2, \dots, n\}$;
 Output: $W = [w_1, w_2, \dots, w_k] \in \mathcal{R}^{h \times k} (k = 1, 2, \dots, h)$;

Initialize: $W^{(1)} \in \mathcal{R}^{h \times k}$, $(W^{(1)})^T W^{(1)} = I_{k \times k}$, $t = 1$;
 for $t = 1, 2, \dots$;
 do
 Calculate $d_i^{(t)}$ by Eq. (17) for each image matrix A_i ;
 Calculate $G(W^{(t)})$ by Eq. (20), and $H^{(t)}$ by Eq. (19) ;
 Calculate SVD of matrix $H^{(t)}$: $H^{(t)} = U^{(t)} \Lambda^{(t)} (V^t)^T$;
 Update $W^{(t+1)}$ according to Eq. (22) ;
 Update $t: t \leftarrow t + 1$;
 while converge
 Output: Optimal projection matrix $W^{(t)} \in \mathcal{R}^{h \times k}$;

2.2 NG-B2DPCA-F 算法的求解

如 2.1 节所述, NG-2DPCA-F 算法主要是对样本图像在方向上进行了信息提取, 忽略了列方向的信息, 本文受到 RC2DPCA 算法^[20]的启发, 引入双向信息提取的思想, 提出了 NG-B2DPCA-F 算法, 提高了算法的鲁棒性及样本信息的提取能力, 且本算法比 RNG-BDPCANet 算法^[25]的计算复杂度更低、求解时间更短, 同时能求解出维数更小的特征矩阵。

NG-B2DPCA-F 算法的求解是在 NG-2DPCA-F 算法的基础上实现的, 将输入的样本图像 $A_i \in \mathcal{R}^{m \times h} (i = 1, 2, \dots, n)$ 经过 NG-2DPCA-F 算法求解得到第一个最优投影矩阵 $W \in \mathcal{R}^{h \times k} (k = 1, 2, \dots, h)$, 将样本图像 A_i 投影到 W 上得到第一个特征矩阵 $Y_i = A_i W \in \mathcal{R}^{m \times k} (i = 1, 2, \dots, n)$, 再将 $Y_i^T \in \mathcal{R}^{k \times m}$ 作为新的样本图像, 再次通过 NG-2DPCA-F 算法求解, 从而得到第二最优投影矩阵 $L \in \mathcal{R}^{m \times r} (r = 1, 2, \dots, m)$, 则最终的特征矩阵为 $X_i = L^T A_i W \in \mathcal{R}^{r \times k}$, 其特征矩阵的大小比输入图像的大小更小。具体求解方式如下:

由于样本图像 A_i 已经过中心化处理, 满足 $\sum_{i=1}^n A_i = 0$, 故存在 $\sum_{i=1}^n Y_i^T = 0 (i = 1, 2, \dots, n)$, 则目标函数转换为:

$$\arg \min_{L^T L = I_{k \times k}} \frac{\|E_i\|_F \times \|Y_i^T L\|_F}{\|Y_i^T\|_F^2},$$

$$\|E_i\|_F < \|Y_i^T L\|_F, \quad (23)$$

式中, 重构误差的 F 范数为 $\|E_i\|_F = \|Y_i^T - Y_i^T L L^T\|_F$, 参考式(8)对式(23)进行转换, 得:

$$\sum_{i=1}^n \frac{\|E_i\|_F \times \|Y_i^T L\|_F}{\|Y_i^T\|_F^2} =$$

$$\sum_{i=1}^n \frac{\|E_i\|_F \times \|Y_i^T L\|_F}{\|Y_i^T\|_F^2 \|E_i\|_F}$$

$$\sum_{i=1}^n [tr(Y_i Y_i^T d_i) - tr(L^T Y_i Y_i^T d_i L)] =$$

$$tr(G(L)) - tr(L^T G(L) L), \quad (24)$$

式中, 加权协方差矩阵 $G(L)$ 和权系数 d_i 分别变为:

$$G(L) = \sum_{i=1}^n Y_i Y_i^T d_i, \quad (25)$$

$$d_i = \frac{\|Y_i^T L\|_F}{\|Y_i^T\|_F^2 \|Y_i^T - Y_i^T L L^T\|_F}. \quad (26)$$

则目标函数转化为:

$$\arg \min_{L^T L = I_{k \times k}} [tr(G(L)) - tr(L^T G(L) L)], \quad (27)$$

第二个投影矩阵 L 的求解方式与第一个投影矩阵 W 相同, 具体迭代求解步骤如下:

第一步: 存在一个 $L^{(t)} \in \mathcal{R}^{m \times r} (r = 1, 2, \dots, m)$, 满足 $(L^{(t)})^T L^{(t)} = I_{k \times k}$, 则 $d_i^{(t)}$ 可由下式求得:

$$d_i^{(t)} = \frac{\|Y_i^T L^{(t)}\|_F}{\|Y_i^T\|_F^2 \|Y_i^T - Y_i^T L^{(t)} (L^{(t)})^T\|_F}. \quad (28)$$

第二步: 此时目标函数式(27)中的第一项 $tr(G(L^{(t)}))$ 将为定值, 则目标函数将变为:

$$\arg \max_{L^T L = I_{k \times k}} r((L^{(t)})^T R^{(t)}), \quad (29)$$

式中, $L^{(t)}$ 为第 t 次迭代的 L , $d_i^{(t)}$ 为第 t 次迭代的 d_i , 且有:

$$R^{(t)} = G(L^{(t)}) L^{(t)}, \quad (30)$$

$$G(L^{(t)}) = \sum_{i=1}^n Y_i Y_i^T d_i^{(t)}. \quad (31)$$

对 $H^{(t)}$ 进行 SVD 得:

$$R^{(t)} = D^{(t)} \Lambda^{(t)} (Z^{(t)})^T. \quad (32)$$

则目标函数式(18)的最优解为:

$$L^{(t+1)} = D^{(t)} (Z^{(t)})^T. \quad (33)$$

最佳投影矩阵 L 通过反复迭代求解式(28)——(33)直至满足收敛要求来获得。为了更直观地理解 NG-B2DPCA-F 算法的非贪婪求解过程, 给出如表 2 的伪代码。

表2 NG-B2DPCA-F 算法伪代码

Tab.2 Algorithm procedure of NG-B2DPCA-F

Input: Sequence of images
 $\{Y_i^T \in \mathcal{R}^{k \times m}, i = 1, 2, \dots, n\}$ with $Y_i = A_i W \in \mathcal{R}^{m \times k} (i = 1, 2, \dots, n)$;
 Output: $L = [l_1, l_2, \dots, l_k] \in \mathcal{R}^{m \times r}$;

Initialize: $L^{(1)} \in \mathcal{R}^{m \times r}$, $(L^{(1)})^T L^{(1)} = I_{k \times k}$, $t = 1$;
 for $t = 1, 2, \dots$;
 do
 Calculate $d_i^{(t)}$ by Eq. (28) for each image matrix Y_i^T ;
 Calculate $R^{(t)}$ by Eq. (30), and $G(L^{(t)})$ by Eq. (31) ;
 Calculate SVD of matrix $R^{(t)}$: $R^{(t)} = D^{(t)} \Lambda^{(t)} (Z^{(t)})^T$;
 Update $L^{(t+1)}$ according to Eq. (33) ;
 Update $t: t \leftarrow t + 1$;
 while converge
 Output: Optimal projection matrix $L^{(t)} \in \mathcal{R}^{m \times r}$;

3 实验与分析

算法性能测试实验的软件环境为 Windows 10 操作系统、Python 3.7 和 OpenCV 2.4.10, 采用 Intel Core i7-7700HQ 处理器、8 G 内存的硬件环境。

3.1 实验数据的获取

实验平台由一套视频采集系统和一套机器人焊接系统构成, 如图 2 所示。视频采集系统由一个分辨率为 640×480 的工业灰度 CMOS 相机、LED 光源和一台由 SINAMICS V90 伺服驱动器控制的三自由度笛卡尔机械手构成。焊接机器人系统由一台型号为 ABB-IRB2600 的六轴机器人、一台型号为 ABB-RC5 的控制柜、一台型号为 Kemppi-SYN300 的焊机、一台型号为 Kemppi-DT400 的焊丝送丝机以及一把型号为 Kemppi-TIG 的焊枪构成。采用纯度为 80% 以上的氦气作为保护气体, 对牌号为 Q235 的低碳钢工件进行自动焊接。




图 2 实验平台

Fig. 2 Experiment platform

3.2 实验数据的处理

视频采集过程与焊接过程同步完成, 由视频采集系统对机器人焊接系统实时跟随, 因为摄像机所拍摄的区域中存在部分非焊接区域, 故本文在视频采集后, 对其进行了分割处理, 分割为 120×80 分辨率的局部图像块作为数据集, 如图 3 所示。受制于焊接工艺与焊件材料, 不可避免地会出现诸如表面气腔、缺焊、填充不足缺陷、焊接飞溅、焊瘤等焊缝表面缺陷, 该数据集由这 5 类有代表性的焊缝表面缺陷和焊接合格的焊缝图像构成。每个类别分别有 300 张分辨率为 120×80 的图像, 即该焊缝表面数据集一共 1800 张图像。为了验证本文所提出算法的鲁棒性, 本文对上述数据集中随机 20%、40%、60% 的图像样本进行人为地位置随机地加入像素大小为 20×20 、 40×40 和 60×60 的高斯噪声块, 如图 4 所示。并使用上文提到的 2DPCA、RC2DPCA、2DPCA-L1、Angle-2DPCA、BA2DPCA 与本文所提出的两个算法进行性能测试实验与对比分析。




图 3 分割图像

Fig. 3 Segmentation of images




图 4 不同比例噪声的焊缝表面图像

Fig. 4 Weld surface images with different scale of noise

3.3 平均重构误差实验

本实验以平均重构误差 (average reconstruction error, ARCE) 为性能指标进行实验, ARCE 定义为式 (34) 所示。在主成分个数 (number of principle components, NPC) 相同的情况下, 若算法的 ARCE

越小, 则其的鲁棒性越好。

$$\bar{E} = \frac{1}{n} \sum_{i=1}^n \|E_i\|_F = \frac{1}{n} \sum_{i=1}^n \|A_i - A_i W W^T\|_F. \quad (34)$$

在不同噪声情况下各算法的 $ARCE$ 如图 5—7 所示。从中可得如下结论:1) 随着 NPC 的增加,各算法的 $ARCE$ 逐渐下降直至趋于平稳,这是因为所提取到的主成分信息越多,投影空间中包含的数据信息越多,故其 $ARCE$ 越小;2) 单向提取图像样本信息的 2DPCA 比双向提取的算法在 $ARCE$ 的表现上更具优势,其原因在于,双向提取的算法虽然能获得行、列两个方向的信息同时获得维数更小的特征矩阵,但是也造成了提取后在特征图像列方向上的结构信息的损失;3) 本文所提 NG-2DPCA-F 算法相较于 2DPCA、2DPCA-L1 和 Angle-2DPCA 等单向算法对高比例噪声块遮盖更具有鲁棒性,随着噪声比例的增加,这一优势也进一步扩大。同时本文所提 NG-B2DPCA-F 算法与 RC2DPCA 和 BA2DPCA 等双向算法相比在 $ARCE$ 上的表现也更加优良,且能降维得到维数更小的特征矩阵。




图 5 加入 20% 比例的噪声块

Fig. 5 Noise block with 20%




图 6 加入 40% 比例的噪声块

Fig. 6 Noise block with 40%




图 7 加入 60% 比例的噪声块

Fig. 7 Noise block with 60%

3.4 重构图像实验

为了进一步验证各算法鲁棒性的优劣,本文采取重构图像实验的方式来更直观展示这一概念。从图可以看出,当 NPC 为 30 时,各算法的 $ARCE$ 的下降速率都趋于平稳,说明此时所获取到的特征已经囊括了图像样本中的大部分特征信息。故本文取前 30 个主成分进行图像重构实验。如图 8 所示为在 60% 图像样本含有 60×60 噪声块的情况下的图像重构效果。

分析图 8 可得:1) 随着主成分数 NPC 的增加,各算法的重构图像的清晰度也增加;2) 在前 10 个 NPC 的实验结果中相较于单向的 2DPCA 算法,双向的 2DPCA 算法的重构图像清晰度更差,图像的畸变也更严重,这是由于双向提取特征信息的 2DPCA 算法所获得的特征矩阵虽然在大小上较之于单向的 2DPCA 算法更小,但也为之损失了更多的信息,这与重构误差实验中的结果曲线相互印证;3) 随着 NPC 的增加,本文所提出的 NG-2DPCA-F 算法对图像样本的细节还原度明显优于其他算法。同时本文所提 NG-B2DPCA-F 算法,在双向提取特征信息以获取维数更小的特征矩阵的基础上,虽然牺牲一定量的图像信息,但是其在图像还原度上也优于其他双向 2DPCA 算法。

3.5 平均分类率实验

为了进一步验证本文所提算法的性能,进行了平均分类率实验。将焊缝表面数据集中每类随机抽取 150 张图像,一共 900 张图像构成训练集样本,剩余的 900 张构成测试集样本。在训练集样本中随机选取 20%、40% 和 60% 的样本分别在随机位置加入像素大小为 20×20 、 40×40 和 60×60 的遮盖噪声

块。鉴于噪声块位置的随机性,为了消除其对算法性能的干扰,本文采用了上述方法随机生成了 3 个不同的训练集,用重复 3 次实验取平均值的方式获取最终的分类率。本文采用 KNN 算法作为分类器,对各算法所提取的特征信息进行分类,分类率越高代表该算法所提取到的特征信息越接近真实特征信息,即反映了该算法提取特征的能力越强。本实验固定主成分数 $NPC=50$,以加入的噪声块所占比例作为自变量进行实验,各算法的平均分类率实验结

果如表 3 所示。

通过分析实验结果可得:1) 随着噪声块占比的增加,各算法在平均分类率上均有所下降,即遮盖性噪声的存在对算法的分类性能存在很大影响;2) 在 40% 的噪声块占比的情况下,本文所提 NG-2DPCA-F 算法具与其他单向 2DPCA 算法相近的分类性能,在 20% 及 60% 噪声块占比的情况下,则本文所提算法具有更高的分类性能。且本文所提 NG-B2DPCA-F 算法与同类的双向 2DPCA 算法相比也具有优良




图 8 60%噪声下的重构图像

Fig. 8 Reconstruction images under 60% noise

表 3 含有不同比例的噪声块的平均分类率

Tab. 3 Average classification rate with different noise scale

Noise	2DPCA	2DPCA-L1	Angle-2DPCA	RC2DPCA	BA2DPCA	NG-2DPCA-F	NG-B2DPCA-F
Original	89.56	89.45	89.56	90.33	90.33	89.56	90.33
20%	89.04	89.04	89.04	89.85	89.93	89.04	89.93
40%	87.19	87.15	87.07	88.63	88.22	87.15	88.54
60%	85.78	85.56	85.52	86.26	86.44	85.85	86.52

的分类性能,即鲁棒性更强。

4 结 论

本文提出 NG-2DPCA-F,又在其基础上进一步提出了 NG-B2DPCA-F,并将上述两个所提算法应用于焊缝表面缺陷的检测,与现有部分 PCA 对比以验证所提算法的鲁棒性和重构性能。

本文所提算法将重构误差与投影距离的乘积整合进目标函数,在寻求投影距离最大的同时满足重构误差最小,以提升算法的特征提取能力和图像重构能力。且所提出的双向 2DPCA 在牺牲一定图像

重构性能的基础上提取到了更多图像信息,同时获得了维数更小的特征矩阵。在以焊缝表面图像集作为实验数据进行算法性能验证,与 2DPCA 算法、Angle-2DPCA 算法、2DPCA-L1 算法、RC2DPCA 算法及 BA2DPCA 算法进行了对比分析。结果表明,本文所提的算法在 ARCE、图像重构和平均分类率等方面表现优良,即相较于其他算法,本文所提算法在焊缝表面图像中所提取的焊缝表面缺陷特征更接近真实缺陷特征,鲁棒性更强,有着更强的重构性能,能由降维后得到的特征矩阵重构出更接近原始状态的图像。

参考文献:

- [1] HOU W, ZHANG D, WEI Y, et al. Review on computer aided weld defect detection from radiography images[J]. Applied Sciences, 2020, 10(5): 1878.
- [2] WANG F, ZHU J J. Application of machine vision in welding defect detection in complex environment[J]. Welding Technology, 2017, 46(5): 127-133.
王飞, 朱建江. 机器视觉在复杂环境下焊接缺陷检测的应用研究[J]. 焊接技术, 2017, 46(5): 127-133.
- [3] FIORAVANTI C C B, CENTENO T M, de BIASE DA SILVA DELGADO M R. A deep artificial immune system to detect weld defects in DWDI radiographic images of petroleum pipes[J]. IEEE Access, 2019, 7: 180947-180964.
- [4] SILVA L C, FILHO E, ALBUQUERQUE M, et al. Segmented analysis of time-of-flight diffraction ultrasound for flaw detection in welded steel plates using extreme learning machines[J]. Ultrasonics, 2019, 102(11): 106057.
- [5] WU J, ZHU J, XIA H, et al. DC-biased magnetization based eddy current thermography for subsurface defect detection [J]. IEEE Transactions on Industrial Informatics, 2019, 15(12): 6252-6259.
- [6] ZOLFAGHARI A, KOLAHAN F. Reliability and sensitivity of visible liquid penetrant NDT for inspection of welded components[J]. Materials Testing, 2017, 59(3): 290-294.
- [7] RANJAN R, KHAN A R, PARIKH C, et al. Classification and identification of surface defects in friction stir welding: an image processing approach[J]. Journal of Manufacturing Processes, 2016, 22: 237-253.
- [8] LI L, XIAO L, LIAO H, et al. Welding quality monitoring of high frequency straight seam pipe based on image feature [J]. Journal of Materials Processing Technology, 2017, 246: 285-290.
- [9] DUAN F, YIN S, SONG P, et al. Automatic welding defect detection of X-ray images by using cascade AdaBoost with penalty term [J]. IEEE Access, 2019, 7: 125929-125938.
- [10] MIAO R, GAO Y, GE L, et al. Online defect recognition of narrow overlap weld based on two-stage recognition model combining continuous wavelet transform and convolutional neural network[J]. Computers in Industry, 2019, 112: 103115.
- [11] ZHANG Z, WEN G, CHEN S. Weld image deep learning-based on-line defects detection using convolutional neural networks for al alloy in robotic arc welding[J]. Journal of Manufacturing Processes, 2019, 45: 208-216.
- [12] GU J, WU Y N, MENG X H. Weld defect detection based on expansion convolution multi-scale fusion[J]. Journal of Optoelectronics · Laser, 2022, 33(1): 61-66.
谷静, 吴怡宁, 孟鑫昊. 基于膨胀卷积的多尺度焊缝缺陷检测算法[J]. 光电子·激光, 2022, 33(1): 61-66.
- [13] GIRSHICK R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE, 2016: 15801732.
- [14] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[C/OL]// International Conference on Learning Representations, May 2-4, 2016, San Juan, Puerto Rico. (2016-04-30) [2022-07-03]. <https://arxiv.org/abs/1511.07122v3>.
- [15] WU S X, WAI H T, LIN L, et al. A review of distributed algorithms for principal component analysis[J]. Proceedings of the IEEE, 2018, 106(8): 1321-1340.
- [16] ZHANG Y, GAO X, KATAYAMA S. Weld appearance prediction with BP neural network improved by genetic algorithm during disk laser welding[J]. Journal of Manufacturing Systems, 2015, 34: 53-59.
- [17] HE K, LI X. Time-frequency feature extraction of acoustic emission signals in aluminum alloy MIG welding process based on SST and PCA [J]. IEEE Access, 2019, 7: 113988-113998.
- [18] SHAO J, HAN S, DONG D, et al. Automatic weld defect detection in real-time X-ray images based on support vector machine[C]//2011 4th International Congress on Image and Signal Processing, October 15-17, 2011, Shanghai, China. New York: IEEE, 2011: 12439462.
- [19] JIAN Y, DAVID Z, FRANGI A F, et al. Two-dimensional PCA: a new approach to appearance-based face representation and recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(1): 131-137.
- [20] YANG W, SUN C, RICANEK K. Sequential row-column 2DPCA for face recognition[J]. Neural Computing and Applications, 2012, 21(7): 1729-1735.
- [21] LI X, PANG Y, YUAN Y. L1-norm-based 2DPCA[J]. IEEE Transactions on Systems, Man, and Cybernetics. Part B, (Cybernetics), 2010, 40(4): 1170-1175.
- [22] GAO Q, LAN M, YANG L, et al. Angle 2DPCA: a new formulation for 2DPCA[J]. IEEE Transactions on Cybernet-

ics, 2018, 48(5):1672-1678.

- [23] WANG X F, SHI L Y, LIU J, et al. Cosine 2DPCA with weighted projection maximization[J/OL]. IEEE Transactions on Neural Networks and Learning Systems, (2022-04-07) [2022-07-03]. <https://ieeexplore.ieee.org/document/9751148>.
- [24] ZHOU S, ZHANG D. Bilateral angle 2DPCA for face recognition[J]. IEEE Signal Processing Letters, 2019, 26(2):317-321.
- [25] LI J J, WANG X F, GE W M. Weld defect detection method based on deep subspace learning [J/OL]. Computer Integrated Manufacturing Systems; (2021-09-23) [2022-07-03]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20210922.1355.002.html>.
- 李进军, 王肖锋, 葛为民. 基于深度子空间学习的焊缝缺陷检测方法[J/OL]. 计算机集成制造系统, (2021-

09-23) [2022-07-03]. <http://kns.cnki.net/kcms/detail/11.5946.TP.20210922.1355.002.html>.

- [26] GE W M, SHEN Y H, WANG X F. Feature extraction and classification of weld surface defects in box gird structures[J]. Chinese Journal of Scientific Instrument, 2018, 39(12): 207-215.
- 葛为民, 申耀华, 王肖锋. 箱梁结构件焊缝表面缺陷特征提取及分类研究[J]. 仪器仪表学报, 2018, 39(12): 207-215.

作者简介:

王成林 (1988—), 男, 博士, 讲师, 主要研究领域为机器学习、模式识别.