

DOI:10.16136/j.joel.2022.08.0798

# 增量式块主成分分析的焊缝图像特征提取算法

张鹏<sup>1,2</sup>, 武刚<sup>\*</sup>, 任柯光<sup>1,2</sup>

(1. 天津理工大学 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. 天津理工大学 机电工程国家级实验教学示范中心, 天津 300384)

**摘要:**针对焊缝图像特征提取的实时性问题, 该文提出一种增量式块主成分分析(incremental block principal component analysis, IBlockPCA)算法, 用于焊缝特征主成分的提取。该算法先将焊缝表面图像分割成子图像块并对其进行重构, 然后利用提出的 IBlockPCA 算法对局部块图像进行增量式特征提取, 并采用 KNN 算法对提取的特征主成分进行分类识别; 最后在焊缝数据集上进行了算法的性能对比。实验结果表明, 该算法在收敛率、分类率及复杂度等方面均优于其他主成分分析(principal component analysis, PCA)算法, 其分类识别率为 97.5%, 其平均处理速度可达 50 frame/s, 能够满足焊缝表面图像的实时性处理需求。

**关键词:**块主成分分析; 焊缝图像; 特征提取; 分类识别; 增量迭代

**中图分类号:** TP301.6 **文献标识码:** A **文章编号:** 1005-0086(2022)08-0851-07

## Feature extraction algorithm of weld image based on incremental block principal component analysis

ZHANG Peng<sup>1,2</sup>, WU Gang<sup>\*</sup>, REN Keguang<sup>1,2</sup>

(1. Tianjin Key Laboratory for Advanced Mechatronical System Design and Intelligent Control, 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:** To solve the problems of real-time feature extraction on weld surface images, a feature evaluation algorithm based on incremental block principal component analysis (IBlockPCA) is proposed. First, the weld surface images are segmented into sub-image blocks, and then the blocks are reconstructed. Next, the incremental feature extraction is performed on the local block images by using the proposed IBlockPCA, and the KNN is used to classify and recognize the evaluated principal components. Finally, the performances are compared on the weld dataset. The experimental results show that the IBlockPCA is superior to other principal component analysis (PCA) algorithms in the convergence rate, classification rate and complexity. The classification rate is 97.5%, and the average processing speed can reach 50 frames per second. It can meet the real-time processing requirements of weld surface images.

**Key words:** block principal component analysis; weld images; feature extraction; classification and recognition; incremental iteration

## 1 引言

焊接已广泛应用铁路桥梁隧道、石油装备制造、桥梁建筑和航空航天等<sup>[1]</sup>诸多领域。但在焊接制造过程中, 由于生产环境和生产工艺的制约, 焊接质量难以保证, 不可避免地产生各种焊接缺

陷, 如裂纹、气孔、狭缝等<sup>[2,3]</sup>。因此, 研究焊接缺陷检测方法对控制产品质量、提高使用寿命和经济效益具有深远的意义。通常焊接缺陷的无损检测(NDT)方法主要有 3 大类: 视觉检测<sup>[4,5]</sup>、X 射线检测<sup>[6,7]</sup>和超声波检测<sup>[8,9]</sup>等。然而这些检测方法具有一定的局限性, 而且在时间和精度方面不

\* E-mail: 15822160735@163.com

收稿日期: 2021-11-28 修订日期: 2021-12-30

基金项目: 国家重点研发计划项目(2017YFB1303304)和天津市科技计划重大专项项目(17ZXZNGX00110)资助项目

能满足实际的要求。

针对上述应用需求,目前已有许多学者进行了研究与开发。高炜欣等<sup>[10]</sup>针对埋弧焊 X 射线图像,将主成分分析(principal component analysis, PCA)引入焊缝圆形和线形的缺陷类型识别。JIANG 等<sup>[11]</sup>从焊缝区域提取纹理特征,通过 PCA 降低特征矩阵的维数和部分冗余性,最后利用支持向量机(support vector machine, SVM)对焊缝缺陷进行分类识别。这些 PCA 相关算法均需将 2 维图像矩阵转换为 1 维列向量,再构造图像协方差矩阵,将大大增加计算量,影响特征提取的速度。YANG 等<sup>[12]</sup>提出了 2 维主成分分析算法(2-dimensional PCA, 2DPCA),直接对图像矩阵进行特征提取。它可以保持图像的空间结构特征,降低特征矩阵的维数。ZUO 等<sup>[13]</sup>提出了双向主成分分析算法(bi-directional PCA, BDPCA)。GAO 等<sup>[14]</sup>提出了 Angle-2DPCA 算法,通过准则函数求取数据的重构误差与方差之间的关系,然后提出一种求解 Angle-2DPCA 的快速迭代算法。YANG 等<sup>[15]</sup>提出了行列 2DPCA(row-column 2DPCA, RC2DPCA),在图像的行和列两个方向上进行特征提取,得到维数更小的特征矩阵,提升了特征提取性能。上述这些算法均属于批量算法。即使新增一个图像样本,也需要重新训练整个样本,无法满足焊缝图像特征提取的实时性需求。

增量 PCA<sup>[16]</sup>(incremental PCA, IPCA)在特征提取前不需要获取所有的训练数据,特征信息随着样本的连续输入逐步更新,提高了实时性能。WENG 等<sup>[17]</sup>提出的直观协方差无关增量式主成分分析算法(candid covariance-free IPCA, CCIPCA)可以通过增量迭代的方式快速估算图像矩阵的主成分,且收敛性能好。王肖锋等<sup>[18]</sup>引入了泛化的概念,提出了泛化的 CCIPCA(generalized CCIPCA, GCCIPCA)算法,减少了图像样本内部模型的变化对收敛率的影响。GE 等<sup>[19]</sup>在 CCIPCA 算法的基础上提出了增量的 2DPCA(incremental 2DPCA, I2DPCA)算法。接着,又提出了一种泛化的 I2DPCA<sup>[20]</sup>(generalized I2DPCA, GI2DPCA)算法。这两种增量算法均通过迭代的方式对 2 维图像进行特征主成分的估计,无需将图像矩阵向量化,加快了特征提取速度。上述增量算法仅提取了图像的横向特征,无法完整体现图像的深层次信息及局部信息。

为此,本文提出了一种增量式块主成分分析(incremental block PCA, IBlockPCA)算法。先将焊缝表面图像分割成更小的子图像块,矢量化为 1 维行向量后重构成新的图像,并对新图像矩阵进

行特征主成分的增量迭代。该算法能够提取图像的深层次信息及局部信息,不仅具有增量学习能力,而且还能够完整体现原图像的数据结构。

## 2 IBlockPCA 算法

### 2.1 IBlockPCA 算法推导

设连续 2 维训练样本矩阵为  $\mathbf{X}(i) = (i = 1, 2, \dots, n)$ , 其大小为  $p \times q$ 。将采集到的每一幅焊缝图像分割成大小为  $r \times s$  的子图像块。这些子图像在数学上表示为:

$$\mathbf{I}_{i,j}(h,k) = \mathbf{I}_i \left[ \frac{p}{r}(j-1) + h, \frac{q}{s}(j-1) + k \right], \quad (1)$$

式中,  $i = 1, 2, \dots, n, j = 1, 2, \dots, rs, h = 1, 2, \dots, p/r, k = 1, 2, \dots, q/s, r$  和  $s$  分别表示行列方向上子图像的块数。

将子图像块  $\mathbf{I}_{i,j}(h,k)$  矢量化为 1 维的行向量, 表示为:

$$\mathbf{I}_{i,j}(h,k)_{\frac{p}{r} \times \frac{q}{s}} \rightarrow \mathbf{I}'_{i,j}(h,k)_{1 \times \frac{pq}{rs}}. \quad (2)$$

将矢量化为 1 维的行向量  $\mathbf{I}'_{i,j}(h,k)$  重新构成新的图像样本矩阵  $\mathbf{R}'(i) (i = 1, 2, \dots, n)$ , 则

$$\mathbf{R}'(i) = [\mathbf{I}'_{i,1}, \mathbf{I}'_{i,2}, \dots, \mathbf{I}'_{i,rs}]^T. \quad (3)$$

维数为  $p \times q$  的原图像样本  $\mathbf{X}(i)$  经过分块处理后,能够突出图像的局部信息。考虑到子图像块特征信息之间的相关性,将子图像块矢量化为 1 维的行向量,并重新构成维数为  $rs \times (pq/rs)$  的新图像样本进行计算。

因此,对重构后的图像样本矩阵  $\mathbf{R}'(i)$  构造成协方差矩阵为:

$$\mathbf{S} = \frac{1}{n} \sum_{i=1}^n \mathbf{R}'^T(i) \mathbf{R}'(i), \quad (4)$$

式中,  $\mathbf{R}(i) = \mathbf{R}'(i) - \bar{\mathbf{R}}(n), \bar{\mathbf{R}}(n) = 1/n \sum_{i=1}^n \mathbf{R}(i)$ , 分别表示为焊缝图像样本重构后的中心化矩阵和均值矩阵。

为了避免直接求解图像协方差矩阵的特征值与特征向量,定义一个中间变量  $\mathbf{v}(n)$  为估计向量, 表示为:

$$\mathbf{v}(n) = \lambda \boldsymbol{\alpha}(n) = \mathbf{S} \boldsymbol{\alpha}(n), \quad (5)$$

式中,  $\lambda$  为协方差矩阵  $\mathbf{S}$  的特征值,  $\boldsymbol{\alpha}(n)$  为特征值所对应的特征向量。

将式(4)代入上式中,估计向量  $\mathbf{v}(n)$  改写为:

$$\mathbf{v}_k(n) = \frac{1}{n} \sum_{i=1}^n \mathbf{R}'^T_k(i) \mathbf{R}'_k(i) \boldsymbol{\alpha}_k(i), \quad (6)$$

式中,  $\mathbf{v}_k(n)$  为第  $k$  步估计向量。对于第  $k$  步迭代,考虑到  $\lambda_k = \|\mathbf{v}_k\|$ ,  $\boldsymbol{\alpha}_k = \mathbf{v}_k / \|\mathbf{v}_k\|$ , 可以近似认为  $\boldsymbol{\alpha}_k(n) \approx \boldsymbol{\alpha}_k(n-1) = \mathbf{v}_k(n-1) / \|\mathbf{v}_k(n-1)\|$ , 代入式(6)中可得:

$$\begin{aligned} \mathbf{v}_k(n) &= \frac{1}{n} \sum_{i=1}^n \mathbf{R}_k^T(i) \mathbf{R}_k(i) \frac{\mathbf{v}_k(i-1)}{\|\mathbf{v}_k(i-1)\|} = \\ &= \frac{1}{n} \sum_{i=1}^{n-1} \mathbf{R}_k^T(i) \times \mathbf{R}_k(i) \frac{\mathbf{v}_k(i-1)}{\|\mathbf{v}_k(i-1)\|} + \\ &= \frac{1}{n} \mathbf{R}_k^T(n) \mathbf{R}_k(n) \frac{\mathbf{v}_k(n-1)}{\|\mathbf{v}_k(n-1)\|} = \\ &= \frac{n-1}{n} \mathbf{v}_k(n-1) + \frac{1}{n} \mathbf{R}_k^T(n) \mathbf{R}_k(n) \frac{\mathbf{v}_k(n-1)}{\|\mathbf{v}_k(n-1)\|}, \end{aligned} \quad (7)$$

上式为增量迭代的形式,引入遗忘参数表示为:

$$\mathbf{v}_k(n) = \frac{n-1-l}{n} \mathbf{v}_k(n-1) + \frac{1+l}{n} \mathbf{R}_k^T(n) \mathbf{R}_k(n) \frac{\mathbf{v}_k(n-1)}{\|\mathbf{v}_k(n-1)\|}, \quad (8)$$

式中,  $l$  为遗忘参数,用于调整新增的中心化图像样本  $\mathbf{R}_k(n)$  和历史估计向量  $\mathbf{v}_k(n-1)$  之间的权值。在迭代过程中,当输入一个新的图像样本数据  $\mathbf{R}'(i)$  时,首先需要对其进行中心化处理,并相应地更新样本均值  $\bar{\mathbf{R}}(n)$ 。其样本均值的增量迭代形式表示为:

$$\bar{\mathbf{R}}(n) = \frac{n-1}{n} \bar{\mathbf{R}}(n-1) + \frac{1}{n} \mathbf{R}'(n). \quad (9)$$

式(8)只是估算得到协方差矩阵  $S$  的第  $k$  步估计向量。当计算其他  $(k+1)$  步估计向量时,应将第  $n$  幅图像样本的第  $k$  步估计向量的输入  $\mathbf{R}_k(n)$ , 减去其在第  $k$  步估计向量  $\mathbf{v}_k(n)$  上的投影所得到的残差作为第  $(k+1)$  步估计向量的输入,表示为:

$$\mathbf{R}_{k+1}(n) = \mathbf{R}_k(n) - \mathbf{R}_k(n) \frac{\mathbf{v}_k(n)}{\|\mathbf{v}_k(n)\|} \frac{\mathbf{v}_k^T(n)}{\|\mathbf{v}_k(n)\|}, \quad (10)$$

式中,  $\mathbf{R}_{k+1}(n)$  为第  $n$  个焊缝图像样本的第  $(k+1)$  步输入,初始时  $\mathbf{R}_1(n) = \mathbf{R}(n)$ 。

将式(10)代入式(8),通过递归估计方式可以得到前  $k$  阶高阶特征向量组成的投影矩阵为:

$$\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_k]. \quad (11)$$

将焊缝图像样本矩阵  $\mathbf{R}'(n)$  在维数为  $(pq/MN) \times k$  的投影矩阵  $\mathbf{W}$  上进行投影,可以获得  $MN \times k$  的特征矩阵为:

$$\mathbf{Z}(i) = \mathbf{R}'(i) \mathbf{W}. \quad (12)$$

## 2.2 复杂度分析

对于 2DPCA、RC2DPCA、BDPCA、Angle-2DPCA 等批量算法,需要存储所有的图像样本,其空间复杂度均为  $O(npq)$ 。对于 I2DPCA、GCCIPCA、IBlockPCA 等增量学习算法,仅需存储新增的图像样本,其空间复杂度与样本数无关,仅为  $O(pq)$ 。CCIPCA 算法的空间复杂度为  $O(p^2, q^2)$ 。各算法的时间复杂度分析如表 1 所示。

表 1 时间与空间复杂度分析

Tab. 1 Time and space complexity analysis

Algorithm	Time complexity	Spatial complexity
CCIPCA <sup>[17]</sup>	$O(nk p^2 q^2)$	$O(p^2 q^2)$
2DPCA <sup>[12]</sup>	$O(np^3 + npq)$	$O(npq)$
I2DPCA <sup>[19]</sup>	$O(nk q^2)$	$O(pq)$
RC2DPCA <sup>[15]</sup>	$O(2np^3 + npq + npk)$	$O(npq)$
BDPCA <sup>[13]</sup>	$O(np^3 + nq^3)$	$O(npq)$
GCCIPCA <sup>[18]</sup>	$O(nk, pq + nk, pq)$	$O(pq)$
Angle-2DPCA <sup>[14]</sup>	$O(np^2 q + npk^2 + np^2 k)$	$O(npq)$
IBlockPCA	$O(nkM^2 N^2)$	$O(pq)$

## 3 实验结果与分析

### 3.1 焊缝图像数据集

焊缝图像数据集包括焊瘤、表面气孔、焊接飞溅和合格焊缝共 4 类焊缝图像。每类焊缝选择 100 幅图像,分辨率为  $120 \times 80$ 。图 1 展示了焊缝图像数据集的部分图像。

实验软件环境为 Windows7、Microsoft Visual Studio 2015 和 OpenCV 2.4.10,采用 Intel i5-5200U (2.2 GHz) 处理器,8 GB 内存的硬件环境。

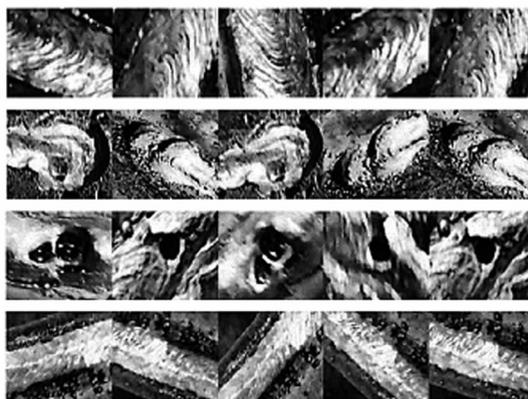


图 1 焊缝数据集图像

Fig. 1 Weld dataset image

### 3.2 重构误差实验

为了验证图像分块能否使算法在计算数据时对孤立的噪声点更加敏感和分块数目  $r, s$  对 IBlockPCA 算法重构性能的影响,进行了重构误差实验,实验结果如图 2 和图 3 所示。图中重构误差随着特征向量的个数  $k$  的增加,均呈现逐渐减少的趋势。在  $k=8$  附近时,特征矩阵包含了较多的图像信息,使其重构误差的下降速度趋于平缓。从图 2 可以进一步看出,当图像行列方向上的分块数互换时,其重构误差曲线几乎完全重合。因此,当图像分块总数相同时,图像行列方向上分块数互换将不会影响其重构

误差性能。从图 3 可以进一步看出,随着图像分块总数的增加,重构误差逐渐减小。考虑到焊缝表面图像维数为  $120 \times 80$ ,行列方向分块数目不能过小,

选取最大的分块总数为  $64(8 \times 8)$ 。为了平衡数据维数与计算复杂度,在后续实验中,设置  $k=8$ ,即提取焊缝图像前 8 个最大特征值所对应的特征向量。

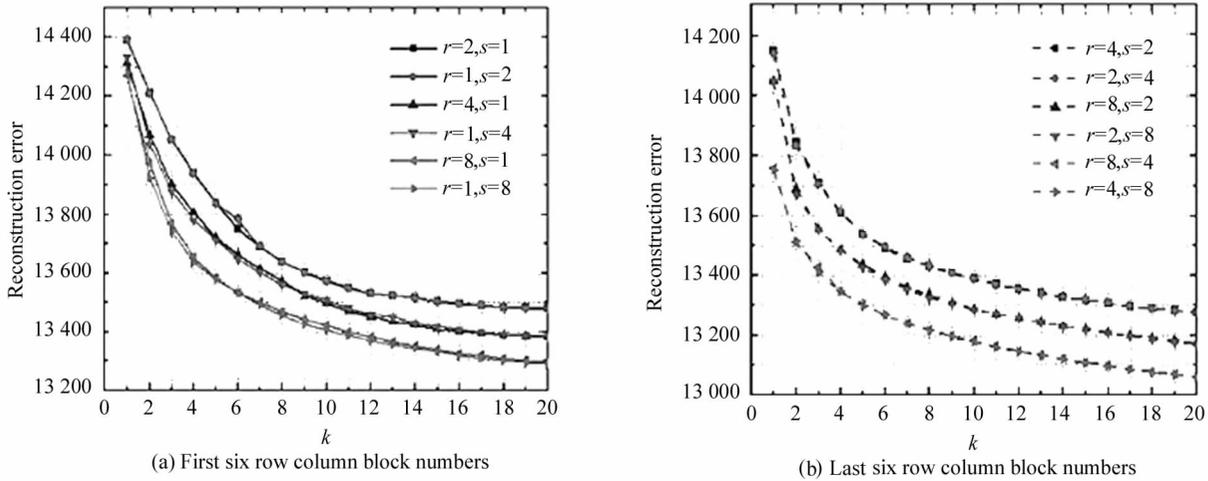


图 2 不同行列分块数下的重构误差

Fig. 2 Reconstruction error under different row column block numbers

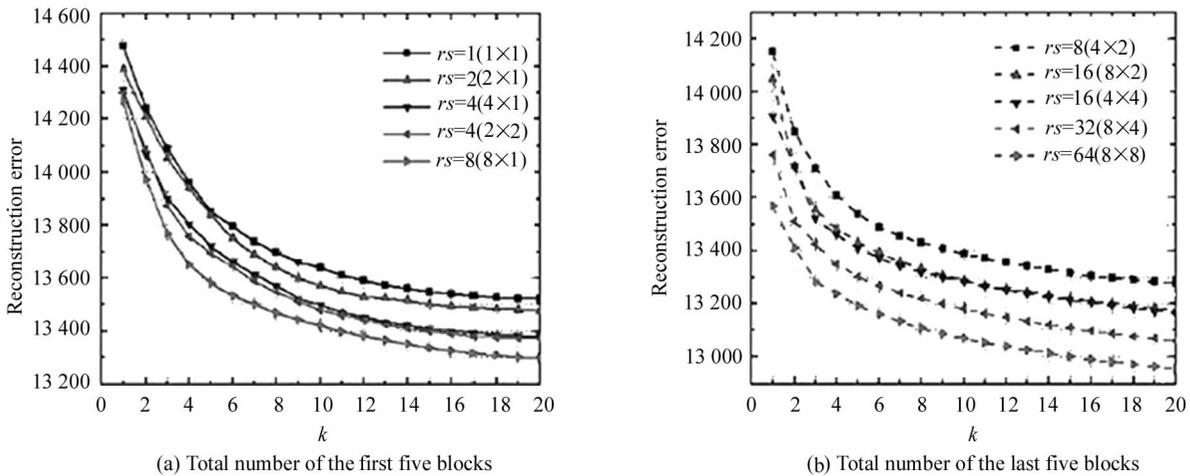


图 3 分块总数下的重构误差

Fig. 3 Reconstruction error under the total number of blocks

### 3.3 收敛性实验

为了验证 IBlockPCA 增量迭代算法的有效性,进行收敛率实验,遗忘参数  $l$  设置为 2。使用  $w_i$  表示批量算法计算得到的第  $i$  个最大真实特征值对应的特征向量,  $\hat{w}_i$  表示增量算法计算得到的第  $i$  个最大估计特征值对应的特征向量。用估计特征向量与对应真实特征向量的内积的绝对值  $|\hat{w}_i \cdot w_i|$  来表示特征向量的收敛性。IBlockPCA 算法前 8 个最大特征值所对应的特征向量的收敛率如图 4 所示。可以看出,随着图像样本数的不断增多,前 3 个特征向量收敛趋势明显并趋近于 1,后 5 个特征向量的收敛性相对较弱。因此,IBlockPCA 算法估计的特征向量能

够逐步趋于真实的特征向量。

为了进一步验证 IBlockPCA 算法在大样本数据下的收敛性,将整个焊缝图像样本进行迭代,循环输入 10 次后,收敛率的实验结果如图 5 所示。可以看出,IBlockPCA 特征向量在经过 10 次循环之后,特征向量的收敛率更加稳定,前 3 个特征向量的收敛率接近 1,后 5 个特征向量的收敛率也达到了 0.9 以上。因此,IBlockPCA 算法在大样本数据下具有更好的收敛性能,其估计的特征向量更接近于对应的真实特征向量,能够满足焊缝图像特征提取实时性需求。

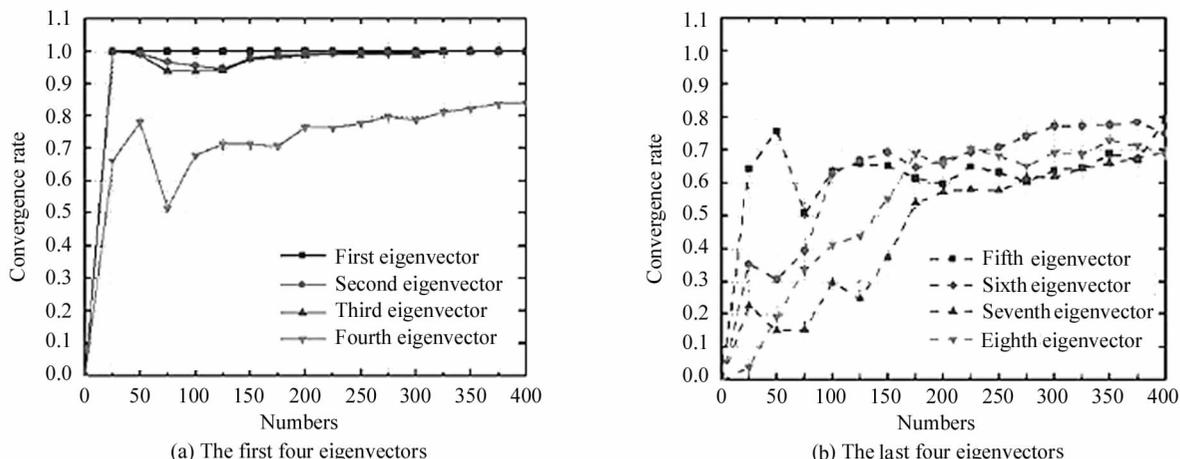


图 4 前 8 个特征向量的收敛率

Fig. 4 Convergence rate of the first eight eigenvectors

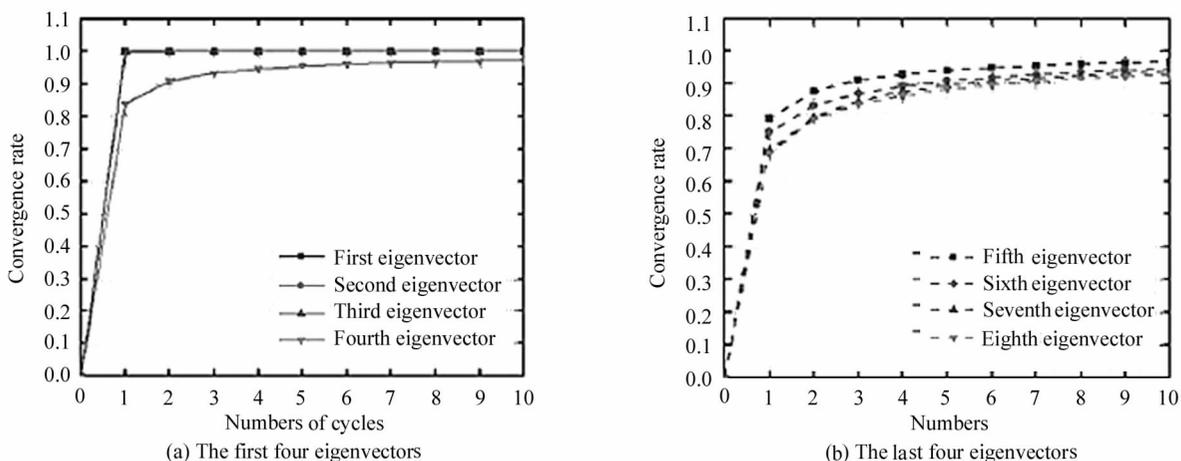


图 5 IBlockPCA 循环多次特征向量的收敛率

Fig. 5 The convergence rates of IBlockPCA multiple-cycle eigenvectors

表 2 焊缝数据集下的分类率

Tab. 2 Classification rate under weld data set

Number( $\times 4$ )	50	100	150	200	250
CCIPCA <sup>[17]</sup> (1 $\times$ 8)	0.815	0.860	0.875	0.890	0.890
Angle-2DPCA <sup>[14]</sup> (120 $\times$ 8)	0.870	0.890	0.925	0.930	0.930
2DPCA <sup>[12]</sup> (120 $\times$ 8)	0.860	0.885	0.905	0.915	0.920
I2DPCA <sup>[19]</sup> (120 $\times$ 8)	0.915	0.920	0.935	0.940	0.950
RC2DPCA <sup>[15]</sup> (8 $\times$ 8)	0.870	0.875	0.885	0.890	0.890
BDPCA <sup>[13]</sup> (8 $\times$ 8)	0.865	0.870	0.875	0.880	0.890
GCCIPCA <sup>[18]</sup> (8 $\times$ 8)	0.920	0.930	0.945	0.960	0.960
IBlockPCA (64 $\times$ 8)	<b>0.925</b>	<b>0.940</b>	<b>0.965</b>	<b>0.975</b>	<b>0.975</b>

### 3.4 分类率实验

从每个类别的 100 幅焊缝表面图像中, 随机选取 50 幅图像作为训练样本, 其余 50 幅作为测试样本。重复 5 次进行分类率实验, 得到分类率如表 2 所

示, 括号内为算法相应的特征维数。可以看出, 随着训练样本数的增加, 各个算法的分类率均呈上升趋势。IBlockPCA 分类率均高于其他 7 种算法, 其分类率最高可达 97.5%。相比其他算法, IBlockPCA

具有较低的特征维数同时,其分类性能更高。因此,IBlockPCA 算法能够满足焊缝图像特征提取实时性需求。

### 3.5 复杂度实验

复杂度实验是以各算法获取最佳分类率时,其特征提取和分类识别所需时间和内存如表 3 和表 4 所示。同其他增量算法相比,IBlockPCA 的特征提取时间略优于 I2DPCA,这是因为对图像列方向进行特征提取时,IBlockPCA 分块处理后列方向的维数

略小于 I2DPCA,其计算量减少所致。IBlockPCA 的特征提取所需时间约为 GCCIPCA 的一半,这是由于 GCCIPCA 在列方向上增加了对行方向的特征提取,导致其计算量增加。与其他批处理算法相比,IBlockPCA 算法具有明显的优势。通过表 3 可以得到,在特征提取速度上,IBlockPCA 约为 55 frame/s。从表 4 可以看出,随着样本数的不断增加,IBlockPCA 算法在特征提取所需内存上优势更加明显。因此,所提出的算法适用于大样本的增量特征提取,能

表 3 焊缝数据集处理所需时间(s)

Tab. 3 Time required for weld data set processing (s)

Number(×4)	50	100	150	200	250
CCIPCA <sup>[17]</sup> (1×8)	245.708	480.952	736.058	995.656	1233.370
Angle-2DPCA <sup>[14]</sup> (120×8)	11.856	25.201	43.047	57.588	68.372
2DPCA <sup>[12]</sup> (120×8)	4.069	11.859	23.257	39.443	57.438
I2DPCA <sup>[19]</sup> (120×8)	4.397	8.679	12.449	16.893	20.603
RC2DPCA <sup>[15]</sup> (8×8)	5.448	14.601	27.471	45.406	65.259
BDPCA <sup>[13]</sup> (8×8)	6.391	18.901	37.646	63.372	96.110
GCCIPCA <sup>[18]</sup> (8×8)	8.186	14.991	21.802	28.860	38.772
IBlockPCA(64×8)	<b>3.782</b>	<b>7.805</b>	<b>11.324</b>	<b>14.211</b>	<b>18.134</b>

够满足焊缝图像特征提取实时性需求。

表 4 焊缝数据集处理所需内存(kB)

Tab. 4 Memory required for weld data set processing (kB)

Number(×4)	50	100	150	200	250
CCIPCA <sup>[17]</sup> (1×8)	779242	779266	779270	779324	779113
Angle-2DPCA <sup>[14]</sup> (120×8)	18326	33672	48996	64360	79761
2DPCA <sup>[12]</sup> (120×8)	18223	33719	49194	64569	79986
I2DPCA <sup>[19]</sup> (120×8)	4257	4340	4228	4343	4261
RC2DPCA <sup>[15]</sup> (8×8)	4178	6612	9025	10449	12800
BDPCA <sup>[13]</sup> (8×8)	36270	67274	98256	129040	159764
GCCIPCA <sup>[18]</sup> (8×8)	4534	4520	4431	4621	4470
IBlockPCA(64×8)	<b>3680</b>	<b>3637</b>	<b>3727</b>	<b>3792</b>	<b>3825</b>

## 4 结 论

本文提出了一种 IBlock PCA 算法,能有效降低特征矩阵的维数与计算复杂度。IBlockPCA 算法通过图像的分块处理,矢量化后重构的新图像包含了原图像深层次信息及局部信息,能够更加完整体现图像的结构特征信息,提高了焊缝分类识别率。通过增量迭代的方式,对焊缝图像进行特征向量估计,其计算复杂度大为降低,提高了特征提取速度。以焊缝图像作为样本数据集,图像特征维数由 120×80 降到 64×8,并包含了图像绝大部分特征信息,分类

识别率可达 97.5%,相比其他算法具有明显的分类优势。特征提取的平均处理速度可达 50 frame/s,能够满足焊缝图像特征提取的实时性需求。

### 参考文献:

[1] ZHANG Y, LI F Z, LIANG Z C, et al. Correlation analysis of penetration based on keyhole and plasma plume in laser welding[J]. Journal of Materials Processing Technology, 2018, 256: 112.

[2] WANG L, FU Q, AN J L, et al. Multi zone fatigue crack propagation behavior of 2A12-T4 aluminum alloy friction stir welding[J]. Transactions of the China Welding Institution, 2021, 42(2): 24-29.

王磊,付强,安金岚,等. 2A12-T4 铝合金搅拌摩擦焊多区域疲劳裂纹扩展行为[J]. 焊接学报, 2021, 42(2): 24-29.

[3] ZHANG Y X, YOU D Y, GAO X D, et al. Welding defects detection based on deep learning with multiple optical sensors during disk laser welding of thick plates[J]. Journal of Manufacturing Systems, 2019, 51: 87-94.

[4] ZHU T, SHI Y H, CUI S W, et al. Recognition of weld penetration during K-TIG welding based on acoustic and visual sensing[J]. Sensing and Imaging, 2019, 20(3): 1-21.

[5] YAN Z H, SHI B W, SUN L P, et al. Surface defect detection of aluminum alloy welds with 3D depth image and 2D gray image [J]. The International Journal of Advanced

- Manufacturing Technology, 2020, 110(3-4): 741-752.
- [6] MOVAFEGHI A, MIRZAPOUR M, YAHAGHI E. Using interpolation with nonlocal autoregressive modeling for defect detection in welded objects[J]. Journal of Nondestructive Evaluation, 2020, 39(3): 1-8.
- [7] ZHANG Z F, REN W J, YANG Z, et al. Real-time seam defect identification for Al alloys in robotic arc welding using optical spectroscopy and integrating learning[J]. Measurement, 2020, 156: 107546.
- [8] YAN Y, LIU D, GAO B, et al. A deep learning-based ultrasonic pattern recognition method for inspecting girth weld cracking of gas pipeline[J]. IEEE Sensors Journal, 2020, 20(14): 7997-8006.
- [9] PAYAO J D, MAIA V P, PASSOS E K D, et al. Probability of detection of discontinuities by ultrasonic phased array inspection of 9% Ni steel joints welded with alloy 625 as the filler metal[J]. Ultrasonics, 2022, 119: 106582.
- [10] GAO W X, HU Y H, WU X M. Research on image classification algorithm of submerged arc welding X-ray weld defects[J]. Chinese Journal of Scientific Instrument, 2016, 37(3): 518-524.  
高伟欣, 胡玉衡, 武晓朦. 埋弧焊 X 射线焊缝缺陷图像分类算法研究[J]. 仪器仪表学报, 2016, 37(3): 518-524.
- [11] JIANG H Q, ZHAO Y L, GAO J M. Weld defect classification based on texture features and principal component analysis[J]. Insight-Non-Destructive Testing and Condition Monitoring, 2016, 58(4): 194-200.
- [12] YANG J, ZHANG D, FRANGI A F. 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.
- [13] ZUO W M, ZHANG D, WANG K Q. Bidirectional PCA with assembled matrix distance metric for image recognition[J]. IEEE Transactions on Systems Man and Cybernetics Part B-Cybernetics, 2006, 36(4): 863-872.
- [14] GAO Q X, MA L, LIU Y. Angle 2DPCA: a new formulation for 2DPCA[J]. IEEE Transactions on Cybernetics, 2018, 48(5): 1672-1678.
- [15] YANG W K, SUN C Y, RICANEK K. Sequential row-column 2DPCA for face recognition[J]. Neural Computer and Applications, 2012, 21(7): 1729-1735.
- [16] DIAZ-CHITO K, FERRI F, HERNANDEZ-SABATE A. An overview of incremental feature extraction methods based on linear subspaces[J]. Knowledge-Based Systems, 2018, 145: 219-235.
- [17] WENG J Y, ZHANG Y L, HWANG W. Candid covariance-free incremental principal component analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(8): 1034-1040.
- [18] WANG X F, ZHANG M L, LIU J. Robot perceptual learning method based on incremental bidirectional principal component analysis[J]. Journal of Electronics & Information Technology, 2018, 40(3): 618-625.  
王肖锋, 张明路, 刘军. 基于增量式双向主成分分析的机器人感知学习方法研究[J]. 电子与信息学报, 2018, 40(3): 618-625.
- [19] GE W N, SUN M Y, WANG X F. An incremental two-dimensional principal component analysis for object recognition[J]. Mathematical Problems in Engineering, 2018, 2018: 1-13.
- [20] GE W N, SHEN Y H, WANG X F. Feature extraction and classification of weld surface defects in bos girder 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:

武刚 (1974-), 男, 硕士, 实验师, 主要研究领域为机器学习。