

基于改正二维主成分分析的焊缝表面缺陷检测

周兆逸¹, 张亚南¹, 王肖锋^{1,2}, 刘军^{1,2}

(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: 机器人焊接因零件形状不规则和焊接工艺复杂不可避免带来各种焊缝缺陷。针对二维主成分分析应用于焊缝表面缺陷检测时面临计算复杂度高、分类准确率低及无法进行增量学习等问题, 提出了一种基于均值更新的增量二维主成分分析 (mean updated incremental two-dimensional principal component analysis, MUI2DPCA) 算法, 并将 MUI2DPCA 和前馈神经网络 (feedforward neural network, FNN) 相结合进行焊缝表面缺陷在线检测。首先, 对相机捕获的视频帧图像进行预处理得到焊缝局部块图像。然后, 利用 MUI2DPCA 在线提取局部块图像的模式特征。MUI2DPCA 对图像的特征主成分进行增量迭代估计, 降低计算复杂度, 并且能够增量更新当前的样本均值, 减少无关特征变化对主成分收敛性的影响。最后, 利用 FNN 建立提取的模式特征与焊缝类别之间的联系, 实时返回焊缝表面缺陷的检测信息。试验结果表明, 该检测方法平均分类准确率为 95.40%, 平均处理速度可达 29 帧/s, 能够满足焊缝在线检测的实时性要求。

创新点: (1) 所提 MUI2DPCA 算法能够更新当前的样本均值, 增量学习焊缝图像的模式特征, 降低计算复杂度。
(2) 基于改进 2DPCA 和 FNN 的焊缝表面缺陷检测方法能够满足在线检测的实时性要求。

关键词: 焊缝表面缺陷检测; 二维主成分分析; 特征提取; 均值更新; 前馈神经网络

中图分类号: TG 441.7 文献标识码: A doi: 10.12073/j.hjxb.20210412001

0 序言

在建筑、船舶、铁道车辆、压力容器等大型基础结构件的制造技术中, 焊接工艺几乎完全取代了铆接、整铸、整锻等工艺。在焊接过程中, 受焊接零件形状不规则和焊接工艺复杂等影响, 焊接质量难以保证, 不可避免产生各种焊缝缺陷, 如气孔、裂纹、夹渣、焊瘤等^[1-2], 这将直接影响到基础结构件的使用寿命和使用安全。因此, 需要对焊缝缺陷进行高效、准确的检测与评判。

随着人工智能的快速发展, 学者开始研究利用机器视觉技术对焊缝表面缺陷进行检测^[3-4]。其主要步骤包括焊缝图像采集、图像预处理^[5]、特征提取与分类识别^[7-8]。因其非接触、智能化、高精度、无损

伤等优点, 已在焊缝表面缺陷检测领域^[9-10] 得到广泛应用。

特征提取是焊缝缺陷图像分类识别的前提。通常捕获的焊缝图像含有工件背景等冗余信息^[11-12], 难以有效提取其模式特征。针对该问题, Jiang 等人^[13] 利用主成分分析 (principal component analysis, PCA) 对高维的纹理特征进行特征提取, 然后采用多类支持向量机对焊缝缺陷进行分类识别。Cruz 等人^[14] 采用 PCA 与 Wilcoxon- Mann-Whitney 相结合的统计方法选择最优特征, 再利用人工神经网络对焊缝缺陷进行分类识别。He 等人^[15] 应用声频发射信号确定铝合金惰性气体焊接过程中的焊接状态, 并提出了一种基于同步压缩小波与 PCA 相结合的时频特征提取方法。上述方法采用 PCA 提取焊缝图像特征时, 需先对图像进行向量化处理, 再将这些向量构成图像协方差矩阵。其协方差矩阵维数过高, 严重影响焊缝缺陷在线检测的实时性。Yang 等人^[16] 提出了一种二维 PCA(two-dimensional PCA, 2DPCA) 方法, 直接利用二维图像构造协方差矩阵, 其协方差矩阵维数相比 PCA 大大降低。这种方法已经广

收稿日期: 2021-04-12

基金项目: 国家重点研发计划项目 (2017YFB1303304); 国家自然科学基金青年项目 (52005370); 天津市科技计划智能制造重大专项 (17ZXZNGX00110); 天津市大学生创新创业训练计划项目 (202010060033)。

泛应用于人脸等模式识别领域^[17-18]. 2DPCA 及相关改正算法^[19-20]均为批量处理方法, 如添加新样本或新增焊缝缺陷类型, 则需要重新计算整个样本的图像协方差矩阵, 计算复杂度较高, 依然难以满足在线检测的实时性要求.

为了解决上述问题, 引入增量学习^[21-22]思想, 提出均值更新的增量二维主成分分析 (mean updated incremental 2DPCA, MUI2DPCA) 算法, 并与前馈神经网络 (feedforward neural network, FNN) 相结合进行焊缝表面缺陷的在线检测研究. 先利用图像预处理算法从捕获的视频流中准确分割出焊缝表面图像. 然后, 利用提出的 MUI2DPCA 算法在线迭代估算焊缝特征主成分, 降低特征提取的计算复杂度, 减少无关特征变化对主成分收敛性的影响. 接着, 利用 FNN 进行分类识别, 并采取相应的跨区域处理方法进行优化, 提高焊缝缺陷的分类准确率. 最后, 通过焊缝数据集及试验平台的验证, 所提出的方法可以应用于实际的焊缝缺陷在线检测, 能够实时得到焊缝缺陷的类别及相应位置.

1 试验平台

试验平台由机器人焊接子系统、视频采集子系统和缺陷检测子系统组成, 如图 1 所示. 焊接子系统包括六轴机械臂 (ABB-IRB2600)、控制柜 (ABB-RC5)、焊机 (Kemppi-SYN300)、焊丝送丝机 (Kemppi-DT400) 和焊枪 (Kemppi TIG). 六轴机械臂配备焊枪, 以 80% 以上的气态氦气作为惰性气体, 对 Q235 低碳钢工件进行自动电弧焊接. 视频采集子系统由 CMOS 型摄像机和由 Sinamicsv90 型伺服驱动器控制的三自由度行走十字架组成.

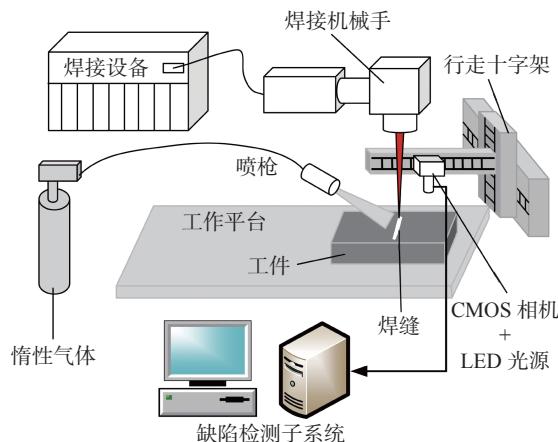


图 1 焊接试验平台

Fig. 1 Welding experimental platform

在实际检测过程中, 当焊接机械手完成预先规划的 2~4 m 路径时, 视频采集子系统实时采集缺陷检测所需的焊缝区域视频信息, 并记录焊缝相应位置. 与工业条件相比, 试验平台的规模有限. 焊接和摄像机的移动速度仅为 26.6 cm/min. 缺陷检测子系统利用视频帧图像来识别焊缝缺陷. 数据处理环境为 Win10 操作系统, 处理器为 i7-9750(2.30 GHz), 8 GB 内存.

2 试验方法

2.1 焊缝图像采集与预处理

当 CMOS 摄像机捕获焊缝帧图像时, 图像质量易受工件表面杂质、自然光照条件和振动等因素影响. 此外, 捕获的焊缝图像包含大量工件背景信息, 不利于焊缝图像的特征提取与分类识别. 因此, 为了在线提取焊缝的有效特征, 对采集的焊缝表面视频帧图像进行预处理, 其过程如图 2 所示. 首先, 将采集的灰度图像进行滤波降噪处理. 再利用 Sobel 算子检测焊缝边缘. 接着, 将灰度图像转化为二值图像, 再采用 Otsu 自适应阈值分割方法, 最小化二值图像的白色前景和黑色背景的类内方差, 直观地呈现出焊缝区域, 效果如图 2c 所示. 最后, 进行形

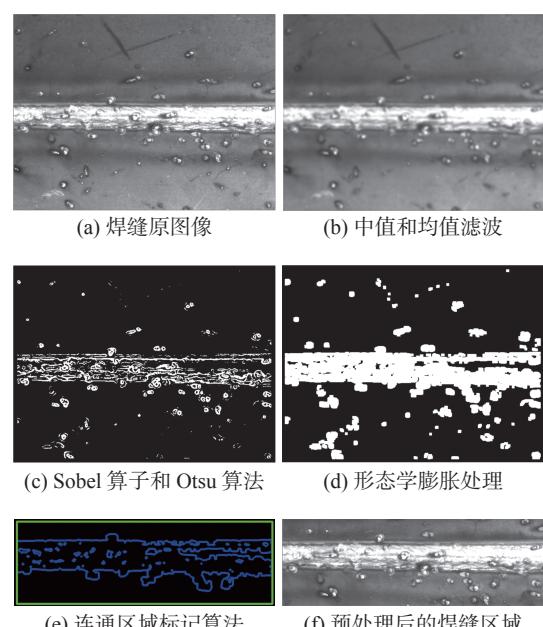


图 2 焊缝区域图像预处理

Fig. 2 Image preprocessing of weld regions. (a) original image of weld; (b) median and mean filter; (c) sobel operator and Otsu algorithm; (d) morphological dilation processing; (e) connected component; (f) weld regions after preprocessing

形态学膨胀处理将不连续焊缝区域连接起来,通过矩形框标记出焊缝区域,如图 2d~图 2f 所示。

采用滑动窗口方法,用特定的步长沿焊接区域图像从左到右连续移动,将焊接区域图像分割为包含有效焊接区域的局部块图像序列。为了适应焊缝区域,在减少计算量的前提下提取焊缝特征,将局部块图像尺寸设定为 80 像素 \times 60 像素,且相邻局部块图像包含了重叠区域,如图 3 所示。

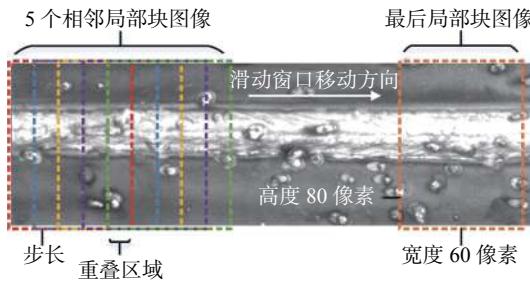


图 3 局部块图像分割
Fig. 3 Local block segmentation

2.2 MUI2DPCA 特征提取算法

2DPCA 算法直接对原始二维图像进行线性变换,寻找在投影矩阵 V 下满足最大方差的优化目标,表征原始图像的特征主成分。通过图像矩阵点乘投影矩阵 V ,实现在低维空间下表征原始图像。构建的图像协方差矩阵 $S(n)$ 可表示为

$$S(n) = \frac{1}{n} \sum_{i=1}^n [A(i) - \bar{A}(n)]^T [A(i) - \bar{A}(n)] = \frac{1}{n} \sum_{i=1}^n A'(i)^T A'(i) \quad (1)$$

式中: $A(i)$ 为第 i 幅图像样本矩阵; n 为图像样本数; $\bar{A}(n) = 1/n \sum_{i=1}^n A(i)$ 为 n 幅图像样本均值矩阵; $A'(i)$ 为图像中心化样本矩阵。

如新增一个训练样本,则需要重新计算图像均值矩阵并重新构造图像协方差矩阵,这将导致计算量显著增加,无法满足在线特征提取的需求。为了满足焊缝表面缺陷在线检测的实时性要求,提出 MUI2DPCA 算法,增量迭代估计求出投影矩阵。以下为估算第一阶特征向量(第一个特征主成分)具体推导过程。

先将样本均值矩阵 $\bar{A}(n)$ 改成增量形式为

$$\bar{A}(n) = \frac{n-1}{n} \bar{A}(n-1) + \frac{1}{n} A(n) \quad (2)$$

式中: $A(n)$ 为第 n 幅图像样本矩阵。

考虑到实际应用中需加载大量焊缝图像,如仅对当前样本进行中心化,容易忽视当前样本均值与

先前历史均值之间的差异,无法准确进行均值更新。因此,需要对历史样本进行修正。定义局部均值变化矩阵 $\Delta\bar{A}(n)$ 为

$$\Delta\bar{A}(m) = \bar{A}(n) - \bar{A}(n-m) \quad (3)$$

式中: m 为局部均值更新的样本数。

将当前中心化样本 $A'(n)$ 改写成含局部均值更新的中心化样本 $\hat{A}(n)$ 表示为

$$\hat{A}(n) = A'(n) - \beta \Delta\bar{A}(m) \quad (4)$$

式中: β 为权重系数。

将 $\hat{A}(n)$ 代入式(1),可得到式(5)。

$$S(n) = \frac{1}{n} \sum_{i=1}^n \hat{A}(i)^T \hat{A}(i) \quad (5)$$

式中: 协方差矩阵 $S(n)$ 可以看作是特征值对特征向量缩放得到的线性变换。定义一个中间向量 $w(n)$ 来表示这种变换,可得到

$$w(n) = \lambda \hat{v}(n) = S(n) \hat{v}(n) \quad (6)$$

式中: λ 为特征值; $\hat{v}(n)$ 为其对应的特征向量。

将式(5)代入式(6)进一步得到,即

$$w(n) = \sum_{i=1}^n \hat{A}(i)^T \hat{A}(i) \hat{v}(n) \quad (7)$$

将式(7)改写成增量形式为

$$w(n) = \frac{n-1}{n} \sum_{i=1}^{n-1} \hat{A}(i)^T \hat{A}(i) \hat{v}(n-1) + \frac{1}{n} \hat{A}(n)^T \hat{A}(n) \hat{v}(n-1) \quad (8)$$

考虑到 $\lambda = \|w(n)\|$ 和 $\hat{v}(n) = w(n) / \|w(n)\|$, 可以近似估计 $\hat{v}(n) \approx w(n-1) / \|w(n-1)\|$, 将其代入式(8), 得到递归形式表示为

$$w(n) = \frac{n-1-l}{n-1} w(n-1) + \frac{1+l}{n} \hat{A}(n)^T \hat{A}(n) \frac{w(n-1)}{\|w(n-1)\|} \quad (9)$$

式中: l 为遗忘参数($l > 0$)。

由式(9)可求得第一阶特征向量 \hat{v}_1 表达式为

$$\hat{v}_1 = \frac{w(n-1)}{\|w(n-1)\|} \quad (10)$$

其余高阶特征向量(特征主成分)以残差的形式求解,表示为

$$\Delta\bar{A}_{j+1}(m) = \Delta\bar{A}_j(m) - \Delta\bar{A}_j(m) \hat{v}_j \hat{v}_j^T \quad (11)$$

$$A_{j+1}(n) = A_j(n) - A_j(n) \hat{v}_j \hat{v}_j^T \quad (12)$$

式中: \hat{v}_j 为第 j 阶特征向量, $j \in [1, k-1]$; k 为提取的特征主成分个数。 $\Delta\bar{A}_{j+1}(m)$, $A_{j+1}(n)$ 分别为当前图像样本的第 $(j+1)$ 阶局部均值变化矩阵和第 $(j+1)$ 阶图像样本输入。通过递归估计依次可得前 k 阶特征向量,得到估计投影矩阵 $\hat{V} = [\hat{v}_1, \dots, \hat{v}_k]$, 维数为 $p \times q$ 。

MUI2DPCA 算法直接利用中心化图像矩阵,

通过递归公式表征图像主成分信息的投影矩阵 \hat{V} , 从而减小计算复杂度。因此, 它符合增量学习的要求。MUI2DPCA 算法更新局部先前图像的均值矩阵, 减少当前样本图像与先前样本图像的均值矩阵之间的差异。该算法能减少图像特征的剧烈变化对估计主成分收敛性的影响, 可以处理大规模、高维与多类数据。

2.3 分类识别算法

选用典型的 3 层 FNN 进行分类识别, 利用其强大的非线性拟合能力建立模式特征与焊缝类别之间的联系, 以局部块图像的特征向量作为输入, 以每个可分辨的焊缝类别被赋予的概率作为输出。考虑到学习速度和泛化能力, 计算隐藏层的神经元数目^[23] 表示为

$$m = \text{Integer}(\sqrt{l+n}) \quad (13)$$

式中: l , m 和 n 分别表示输入层、隐含层和输出层神经元数目。图 4 展示了 3 层 FNN 框架。通过 SoftMax 函数处理输出, 指示对应焊缝类别的最大概率, 并将此概率设为置信度。显然, 置信度属于 $[0, 1.0]$, 且受相邻局部块图像和相邻帧图像中焊缝重叠区域的影响。为了提高重叠区域缺陷识别的准确性, 采用两步处理跨帧优化方法。第一步是根据位置信

息确定当前处理帧图像和先前帧图像中的重叠区域。第二步是根据最大置信度分数对应的识别结果作为重叠区域的当前识别结果。

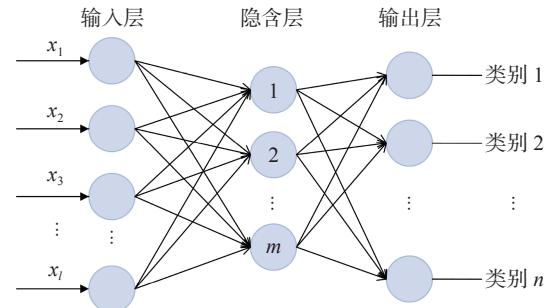


图 4 3 层前馈神经网络
Fig. 4 Three-layer feedforward neural network

3 试验结果与分析

3.1 焊缝数据集试验

利用焊缝数据集对提出的 MUI2DPCA 算法进行性能评估, 该数据集包含焊瘤、表面气孔、焊接飞溅、合格焊缝 4 个类别共 400 幅, 大小为 80 像素 \times 60 像素的灰度图像, 每个类别由 100 幅图像组成, 4 种类别的部分图像样本如图 5 所示。参数设置为 $m = 5$, $\beta = 1.5$, $l = 2$ 。

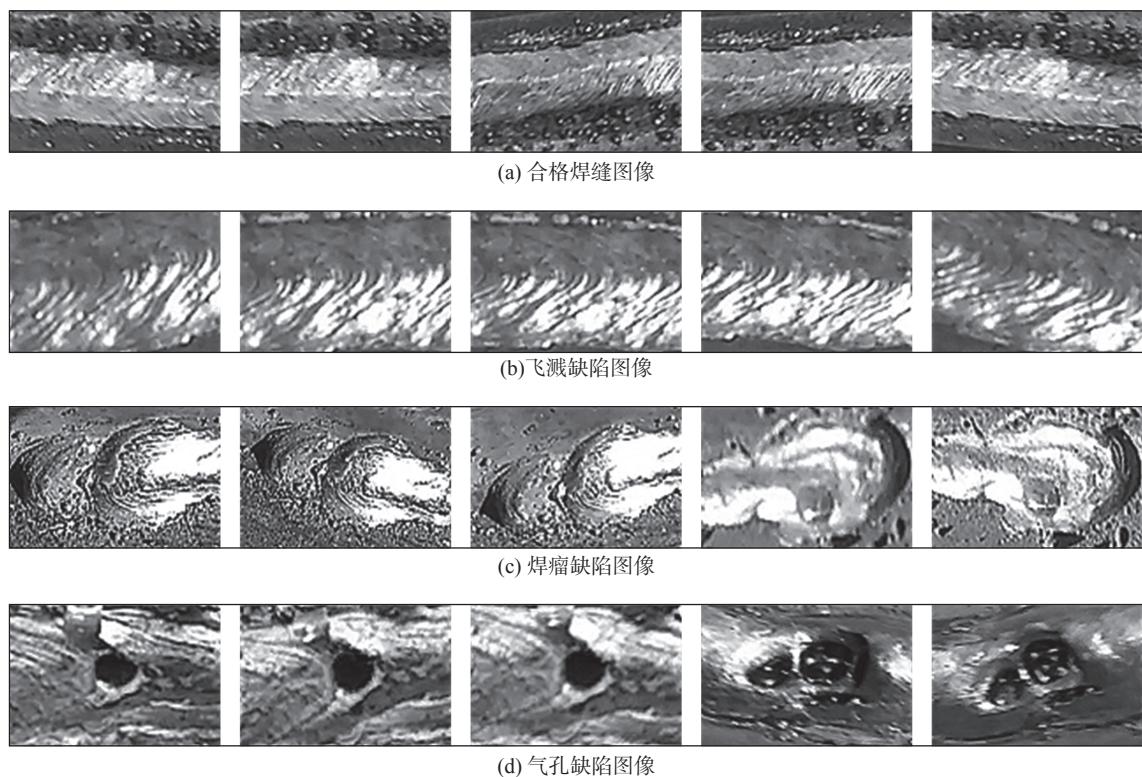


图 5 焊缝数据集图像样本

Fig. 5 Image samples of weld database. (a) qualified weld images; (b) welding spatter images; (c) welding tumor images; (d) gas cavity images

3.1.1 最优的特征向量阶数试验

为了选择最优的特征向量阶数, 满足在线提取焊缝表面缺陷特征的要求, 通过评价函数度量提取主成分的有效性与实时性之间的关系。定义重构误差 E 反映 MUI2PCA 算法提取主成分的贡献值。重构误差 E 计算公式为

$$E = \frac{1}{n} \sum_{i=1}^n \|A(i) - A(i)\hat{V}\hat{V}^T\| \quad (14)$$

式中: $A(i)$ 为第 i 幅图像样本矩阵; \hat{V} 为估计投影矩阵。

评价函数为

$$Q = \sqrt{\gamma E + (1-\gamma)t^2} \quad (15)$$

式中: t 为运行时间; γ 为 $0 \sim 1$ 之间的常数。

考虑到分类准确率是缺陷识别的首要目标, 所以将 γ 设置为 0.7。使用 MUI2DPCA 算法进行重构误差、重构图像试验, 结果如表 1 所示。

表 1 前 k 阶特征向量评价值

Table 1 Evaluation value of the first k -order eigenvectors

特征向量阶数 k (个)	重构误差 E	运行时间 t/s	评价值 Q
2	4 185.99	18.709	55.09
4	3 762.56	31.773	54.19
6	3 519.44	47.377	56.01
8	3 344.40	63.382	59.55
10	3 219.00	80.712	64.87
12	3 086.90	96.118	70.23
14	2 972.33	112.484	76.66

从表 1 可以看出, 随着特征向量阶数 k 的增加, 重构图像越清晰, 即主成分的贡献值总和越来越大。但运行时间呈线性增长趋势, 逐渐在评价函数中起主导作用。当 $k=4$ 时, 评价函数 Q 值最小, 即此时提取焊缝图像主成分最优。在后续试验中, 均提取前 4 阶特征向量进行焊缝缺陷分类识别。

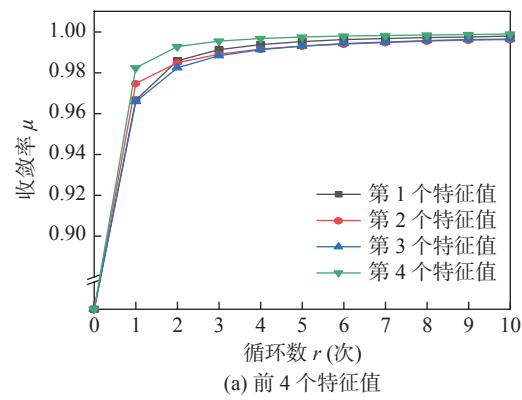
3.1.2 主成分收敛性试验

为了评估 MUI2DPCA 算法在大量样本输入下估计主成分的准确性, 将整个焊缝数据集循环输入 r 次, 则第 i 个特征主成分在第 r 次输入下的收敛率可表示为

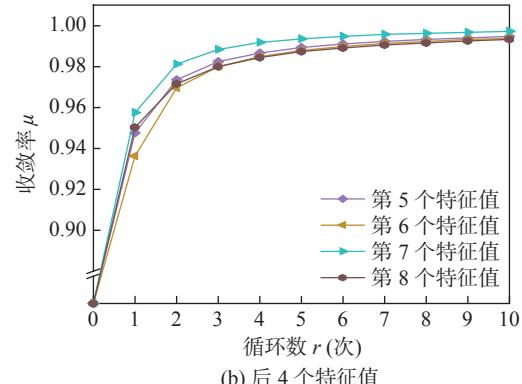
$$\mu_i^r = \left| \frac{\hat{\lambda}_i^r}{\lambda_i^r} \right| \quad (16)$$

式中: λ_i^r 表示 2DPCA 算法在第 r 次输入下计算得到的第 i 个真实特征值; $\hat{\lambda}_i^r$ 表示 MUI2DPCA 算法在第 r 次输入下计算得到的第 i 个估计特征值。

图 6 为前 8 个特征值收敛率。从图 6 可以看出, 随着大量样本的输入, 特征值的收敛率更加稳定, 也更加趋近于 1。前 8 个特征值的收敛率 5 次循环后大于 0.98, 在 10 次循环后大于 0.99。结果表明, MUI2DPCA 算法通过修正样本间历史均值差异能够降低无关特征对主成分收敛率的影响, 估计的主成分能较快收敛, 与真实特征主成分几乎一致, 满足在线学习需求。



(a) 前 4 个特征值



(b) 后 4 个特征值

图 6 前 8 个特征值收敛率

Fig. 6 Convergence rates of the first eight eigenvalues. (a) first four eigenvalues; (b) last four eigenvalues

3.1.3 分类准确率及计算复杂度试验

为了验证 MUI2DPCA 算法提取焊缝表面图像特征主成分的有效性, 将焊缝数据集中每个类别 100 幅图像随机分成 50 个训练样本和 50 个测试样本, 多次重复输入训练样本以获得足够多的训练样本。分别使用 MUI2DPCA 和 2DPCA 算法提取特征主成分, 记录所需时间及内存, 将得到的特征主成分作为 FNN 分类器的输入。试验结果如表 2 所示。

从表 2 可以看出, 在分类性能上, 随着训练样本数的增加, 2DPCA 的分类准确率仅有小幅提升, 而 MUI2DPCA 算法最高可达到 96.5%。在计算复杂度上, MUI2DPCA 算法特征提取所需时间与样

本数量大致成正比, 最高处理速度可达 52 帧/s, 所需时间及内存较 2DPCA 算法优势显著。结果表明, MUI2DPCA 能适应不同焊缝类别特征提取, 在线学习性能优越, 能够满足焊缝表面缺陷特征在线提取的实时性需求。

表 2 MUI2DPCA 和 2DPCA 分类准确率及复杂度试验
Table 2 Classification accuracy and complexity experiments of MUI2DPCA and 2DPCA

算法	样本数 n (个)	分类准确率 η (%)	运行时间 t /s	内存 M/kB
MUI2DPCA	200	94.0	3.992	6 500
	400	94.5	8.174	6 504
	600	95.0	11.794	6 483
	800	95.0	15.553	6 516
	1 000	96.5	19.094	6 508
2DPCA	200	94.0	2.917	18 202
	400	94.0	9.232	33 575
	600	94.0	18.956	48 950
	800	94.5	31.560	64 257
	1 000	94.5	47.465	79 610

3.2 焊接平台测试

在焊接试验平台上分别对具有未熔合、飞溅和漏焊 3 类缺陷的焊缝视频流进行检测。记录测试视频帧的分辨率为 640 像素 \times 480 像素, 每帧分割为 14~26 个局部块图像, 其大小为 80 像素 \times 60 像素, 每段视频持续 12 s, 视频帧速率为 30 帧/s。3 种情况下的分类准确率分别为 94.47%, 94.68% 和 97.04%, 平均分类准确率为 95.40%。图 7 展示了部分测试输出结果。

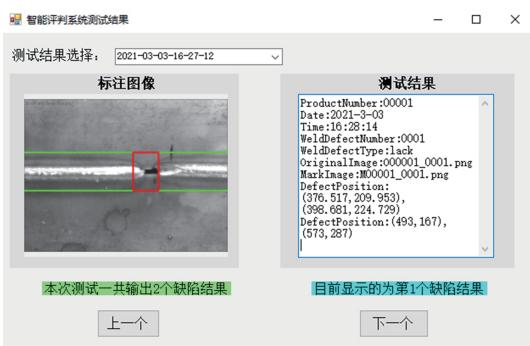


图 7 焊接试验平台检测结果
Fig. 7 Test results of welding experiment platform

焊接试验平台测试所需时间如表 3 所示。在图 7 的标注图像一栏中, 绿色和红色矩形框分别对应合格和缺陷焊缝。在测试结果一栏, 返回产品编

号、测试时间、缺陷数目、缺陷类型和缺陷位置等信息, 并生成检测报告。通过表 3 可计算得到平均检测速度为 29 帧/s, 接近视频帧的速率。测试结果表明, 提出的缺陷检测方法有效, 能够应用于实际的焊缝缺陷在线检测。

表 3 焊接试验平台检测焊缝缺陷所需的时间
Table 3 Required time of weld defect detection using the platform running test

检测步骤	时间 t/s
图像预处理	32.694
特征提取	2.847
FNN 分类	0.454
跨帧优化	0.978
总计	36.973

4 结论

(1) 基于改进的二维主成分分析法和 FNN 的焊缝表面缺陷检测方法, 包括视频采集、图像预处理、特征提取和分类识别, 该检测方法在实际应用中是有效可靠, 平均分类准确率为 95.40%, 平均处理速度为 29 帧/s, 满足在线检测的实时性要求, 并能实时返回缺陷检测信息。

(2) 与常规的批量处理算法相比, 提出的 MUI2DPCA 算法在线迭代估计主成分, 计算复杂度低, 在线学习性能优越, 能够进行增量学习焊缝图像的模式特征。

(3) MUI2DPCA 算法对历史样本进行均值更新, 降低了图片的剧烈变化对主成分收敛率的影响, 估计特征值与对应实际特征值几乎一致, 从大量样本中能够学习到更多样本的共性特征。

参考文献

- [1] Hou W H, Zhang D S, Wei Y, et al. Review on computer aided weld defect detection from radiography images[J]. Applied Sciences-Basel, 2020, 10(5): 1878.
 - [2] Kermorgant O. A magnetic climbing robot to perform autonomous welding in the shipbuilding industry[J]. Robotics and Computer-Integrated Manufacturing, 2018, 53: 178~186.
 - [3] 于朋, 刚铁. 基于全聚焦成像技术的焊缝近表面平面类缺陷检测 [J]. 焊接学报, 2019, 40(12): 36~40.
- Yu Peng, Gang Tie. Use total focusing method to image the near-

- surface planar defect in welded joint[J]. Transactions of the China Welding Institution, 2019, 40(12): 36 – 40.
- [4] Sun J, Li C, Wu X J, et al. An effective method of weld defect detection and classification based on machine vision[J]. IEEE Transactions on Industrial Informatics, 2019, 15(12): 6322 – 6333.
- [5] 马增强, 钱荣威, 许丹丹, 等. 线结构光焊接图像去噪方法 [J]. 焊接学报, 2021, 42(2): 8 – 15.
Ma Zengqiang, Qian Rongwei, Xu Dandan, et al. Denoising of line structured light welded seams image based on adaptive top-hat transform[J]. Transactions of the China Welding Institution, 2021, 42(2): 8 – 15.
- [6] 胡宏伟, 张婕, 彭刚, 等. 基于 LBP-KPCA 特征提取的焊缝超声检测缺陷分类方法 [J]. 焊接学报, 2019, 40(6): 34 – 39.
Hu Hongwei, Zhang Jie, Peng Gang, et al. Defect classification for ultrasonic inspection in weld seam based on LBP-KPCA feature extraction[J]. Transactions of the China Welding Institution, 2019, 40(6): 34 – 39.
- [7] Zhang L, Zhang Y J, Dai B C, et al. Welding defect detection based on local image enhancement[J]. IET Image Processing, 2019, 13(13): 2647 – 2658.
- [8] Shao W J, Huang Y, Zhang Y. A novel weld seam detection method for space weld seam of narrow butt joint in laser welding[J]. Optics and Laser Technology, 2018, 99: 39 – 51.
- [9] Oh S J, Jung M J, Lim C, et al. Automatic detection of welding defects using faster R-CNN[J]. Applied Sciences-Basel, 2020, 10(23): 8629.
- [10] Zhang Z F, Wen G R, Chen S B. 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.
- [11] Wang Y, Guo H. Weld defect detection of X-ray images based on support vector machine[J]. IETE Technical Review, 2014, 31(2): 137 – 142.
- [12] Chu H H, Wang Z Y. A vision-based system for post-welding quality measurement and defect detection[J]. International Journal of Advanced Manufacturing Technology, 2016, 86(9-12): 3007 – 3014.
- [13] Jiang H Q, Zhao Y L, Gao J M, et al. Weld defect classification based on texture features and principal component analysis[J]. Insight, 2016, 58(4): 194 – 199.
- [14] Cruz F C, Simas E F, Albuquerque M C S, et al. Efficient feature selection for neural network-based detection of flaws in steel welded joints using ultrasound testing[J]. Ultrasonics, 2017, 73: 1 – 8.
- [15] He K F, Li X J. 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.
- [16] Yang J, Zhang D, 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.
- [17] Esmaeili M, Ahmadi M, Kazemi A. Kernel-based two-dimensional principal component analysis applied for parameterization in history matching[J]. Journal of Petroleum Science and Engineering, 2020, 191: 107134.
- [18] Bi P F, Xu J, Du X, et al. ℓ_2 , p-norm sequential bilateral 2DPCA: a novel robust technology for underwater image classification and representation[J]. Neural Computing and Applications, 2020, 32(22): 17027 – 17041.
- [19] Can J, Zhang F, Wang J J, et al. Robust principal component analysis with intra-block correlation[J]. Neurocomputing, 2020, 386: 165 – 178.
- [20] Wang Q Q, Gao Q X, Gao X B, et al. Optimal mean two-dimensional principal component analysis with F-norm minimization[J]. Pattern Recognition, 2017, 68: 286 – 294.
- [21] Weng J Y, Zhang Y L, Hwang W S. Candid covariance-free incremental principal component analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(8): 1034 – 1040.
- [22] Ge W M, Sun M Y, Wang X F. An incremental two-dimensional principal component analysis for object recognition[J]. Mathematical Problems in Engineering, 2018(3): 1 – 13.
- [23] Li Yongyan, Zhao Weimin, Xue Haitao, et al. Defect recognition of resistance spot welding based on artificial neural network[C]// Proceedings of 2010 International Conference on Services Science, Management and Engineering. Berlin, Heidelberg: Springer, 2012, 115: 423-430.

第一作者:周兆逸, 硕士; 主要从事无损检测和机器学习方面的工作; Email: China_zhouzhaoyi@163.com.

通信作者:王肖锋, 副教授; Email: wangxiaofeng@tjut.edu.cn.

(编辑: 戴红)