

# 基于深度学习特征的铸件缺陷射线图像动态检测方法

余永维 杜柳青 闫哲 许贺作

(重庆理工大学机械工程学院, 重庆 400054)

**摘要:** 针对 X 射线检测中铸件微弱缺陷误检率和漏检率高的问题, 提出一种基于选择性注意机制和深度学习特征匹配的缺陷动态跟踪检测方法。基于射线图像序列, 采取帧内注意区域检测消除漏检、帧间深度学习特征匹配跟踪排除误检的策略。在帧内检测阶段, 提出通过中央-周边梯度搜索方法模拟生物视觉的中央-周边差运算, 根据梯度阈值直接检测各可疑缺陷区域, 无需分割出缺陷本身。在帧间跟踪阶段, 借鉴人类大脑视觉感知系统的深度学习层次结构, 建立基于卷积神经的深度学习网络, 可疑缺陷区域灰度信号直接作为输入, 自动抽取表征可疑缺陷区域的本质特征信息, 组成深度学习特征矢量。定义基于欧氏距离的特征矢量相似度, 通过连续图像中可疑缺陷区域的相似度匹配实现缺陷跟踪, 以消除噪声等伪缺陷。实验结果表明, 基于深度学习特征匹配方法的铸件缺陷图像动态检测, 误检率和漏检率均低于 3%, 缺陷检测准确率超过 97%, 证明了所提方法的有效性。

**关键词:** 铸件; 缺陷检测; 射线图像; 深度学习; 注意机制

中图分类号: TP391.41; TH878<sup>+</sup>.1 文献标识码: A 文章编号: 1000-1298(2016)07-0407-06

## Dynamic Detection of Casting Defects Radiographic Image Based on Deep Learning Feature

Yu Yongwei Du Liuqing Yan Zhe Xu Hezuo

(College of Mechanical Engineering, Chongqing University of Technology, Chongqing 400054, China)

**Abstract:** In order to reduce the misdetection ratio and false detection ratio of small casting defects in X radiographic testing, a dynamic defects tracking and detection method based on selective attention mechanism and deep learning feature matching was proposed. The misdetection of image sequences was eliminated with attention region detection of individual images and the false detection was also eliminated with feature matching among the image sequence. In the phase of individual images detection, a search method based on central - peripheral gradient was proposed to simulate the central - peripheral difference operation of biological vision. And the gradient threshold was defined. Then by comparing each regional gradient with threshold, the suspicious defect area was directly detected according to the gradient threshold. The defects did not need to be segmented from the suspicious image area. So the method avoided the great influence of the defects segmentation accuracy rate to defects tracking. In the phase of tracking among the image sequence, referencing to the deep learning hierarchy of human visual perception system, a deep learning network based on convolution neural was established. The gray level signal of the suspicious defect area was directly used as input. The network could automatically extract the essential feature which made up the deep learning feature vector. The similarity of feature vector was defined based on Euclidean distance. Defect tracking was achieved by similarity matching of suspicious defect regions in continuous frames. Then the noise and other false defects were eliminated. The experiments show that the false detection rate and the misdetection rate are less than 3%. The detection accuracy rate is more than 97%, which proved the method is advanced and effective.

**Key words:** casting; defect detection; radiographic image; deep learning; visual attention mechanism

收稿日期: 2016-04-07 修回日期: 2016-05-03

基金项目: 重庆市基础与前沿研究计划基金项目(cstc2013jcyjA70009)和国家自然科学基金青年基金项目(51075419)

作者简介: 余永维(1973—),男,高级工程师,博士,主要从事机器视觉系统研究,E-mail: ftong@126.com

## 引言

采用铸造工艺制造的发动机关键零部件如缸体、缸头、曲轴箱体、曲轴箱盖、气门盖等,内部不可避免会出现气孔、缩孔、疏松、渣眼、裂纹、冷隔等缺陷,必须对其进行X射线无损检测以保证结构安全。

缺陷自动识别是实现铸件内部缺陷X射线无损检测的关键技术,传统方法采用对单幅射线数字图像进行静态处理孤立评判的方法<sup>[1-5]</sup>。由于发动机铸件射线图像噪声多、对比度低、缺陷形态多样,在单幅图像中难以区分噪声与微弱及微小缺陷,因而漏检率和误检率高,可靠性与准确性差。

利用图像时间序列进行缺陷识别和消除误检是当前国内外研究的热点。DOMINGO等<sup>[6]</sup>提出对铝铸件射线图像序列进行分析,跟踪潜在缺陷以实现缺陷自动检测;周正干等<sup>[7]</sup>研究航空发动机叶片缺陷的自动识别技术,提出基于多幅X射线数字图像进行缺陷提取和缺陷跟踪的方法。上述利用图像序列基于约束条件进行缺陷跟踪消除误检的方法,前提是待检工件的运动参数是已知的,但是,实际应用中工件的运动参数大多是未知的。田原等<sup>[8]</sup>利用时间序列图像,提出帧内分割与帧间跟踪相结合的焊缝缺陷检测技术,采用基于局部位置特征、面积特征和对比度特征的缺陷特征匹配跟踪方法,但对于微弱缺陷以及缺陷图像旋转后的匹配效果较差。

缺陷跟踪的难点在于特征选择、描述及匹配的有效性和鲁棒性。现有利用图像特征匹配的方法,必须在帧内阶段准确提取缺陷,再采用局部位置特征、面积特征和对比度特征等人工缺陷特征匹配,该缺陷跟踪方法有两方面不足:因射线图像模糊、对比度低、缺陷形态多样,许多缺陷较微弱或微小,所以帧内阶段缺陷提取的准确性往往得不到保证;人工特征的有效描述和人工特征的准确选取往往是很困难的,需要启发式方法和非常专业的知识,很大程度上也靠个人经验,并且要求特征具有对旋转、缩放和平移的不变性,所以上述人工特征对于微弱缺陷以及缺陷图像旋转后的匹配效果较差。

人类视觉感知系统具有深度学习的层次结构,能在极大降低处理数据量的同时,自动抽取能真正表征物体的有用的本质特征信息<sup>[9-12]</sup>。因此,本文提出一种基于深度学习特征匹配的铸件缺陷图像动态识别方法,其基本思路是在图像的运动序列中,借鉴生物选择性注意机制完成帧内缺陷快速检测以消除漏检,利用深度学习特征匹配实现帧间缺陷跟踪以消除误检,解决目前视觉检测中普遍存在的可靠性与准确性差等问题。

## 1 系统结构与原理

如图1所示,系统主要由工件运输小车、工件运动控制装置、检测工作台、射线实时成像系统、图像分析处理系统等组成,自动完成工件运输、运动、成像等过程。两台运输小车自动完成工件装卸以及在待检区、检测室、检测完毕区之间的运输。工件由伺服系统控制在检测台上做精确平移和旋转运动,配合射线实时成像系统生成工件不同视角下的多帧投影图像。

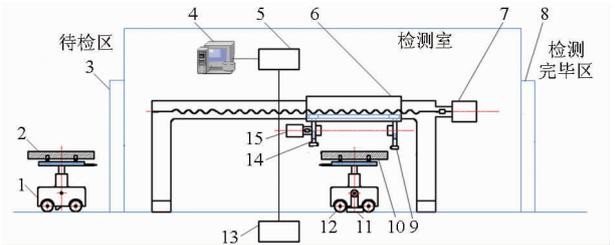


图1 系统结构示意图

Fig. 1 Schematic diagram of system structure

1. 运输小车 1
- 2, 10. 铸件
- 3, 8. 安全门
4. 图像处理系统
5. 射线实时成像系统
6. 检测工作台
7. 平移步进电动机
- 9, 11, 14. 传感器
12. 运输小车 2
13. 射线发生器
15. 旋转步进电动机

获得的射线检测图像序列在计算机中进行自动处理和分析。系统的关键在于缺陷图像的动态检测,其分为帧内缺陷提取和帧间缺陷跟踪两个阶段,前者基于选择性注意机制进行可疑缺陷区域检测,尽可能减少漏检,对于产生的误检,则通过第二阶段基于深度学习特征匹配的帧间缺陷跟踪予以消除,其原理如图2所示。

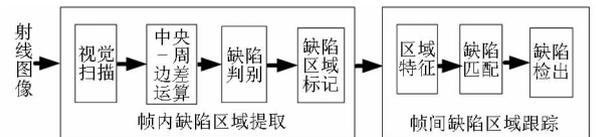


图2 缺陷动态检测过程框图

Fig. 2 Process block of defect dynamic detection

## 2 基于选择性注意机制的可疑缺陷区域检测

现有方法在帧内提取阶段,必须用各种二值化方法分割出缺陷,由于铸件射线图像模糊、缺陷微弱且形态多样,分割准确性较低,制约了后续帧间缺陷跟踪的可靠性。

人眼视觉所具有的选择性注意机制在面对复杂场景时能迅速地将自己的注意力聚焦在一些显著的目标上,选择性注意机制的核心是视觉神经的中央-周边差运算,特别适用于检测局部显著性较强的区域<sup>[13-16]</sup>。缺陷区域在整幅发动机铸件等射线图像中只占很小的一部分,本文将注意机制引入到帧内

缺陷检测中,提出一种基于选择性注意机制的可疑缺陷区域快速检测方法,通过模拟人眼视觉注意机制的中央-周边差计算来直接快速地搜索帧内可疑区域,算法实现步骤为:

(1)从第1列(或第1行)开始对射线图像进行逐列(或行)视觉扫描。

(2)搜索第 $j$ 列灰度曲线各局部极小峰值点 $p(x_i, y_j)$  ( $i=1, 2, \dots, l$ ),  $l$ 为扫描线灰度极小值点的数量;各扫描线极小值点对应的像素坐标为 $(x_i, y_j)$  ( $i=1, 2, \dots, l$ )。

设 $p(x_i, y_j)$ 为扫描线灰度极小值点,以 $p(x_i, y_j)$ 为起点,搜索其8邻域的区域灰度极小值点即区域中央点 $c(x_m, y_n)$ ,然后向中央点 $c(x_m, y_n)$ 的8个邻域方向上分别搜索离其最近的顶部,8个顶部对应的像素点 $h(x_{mk}, y_{nk})$  ( $k=1, 2, \dots, 8$ )即周边点,如图3所示。

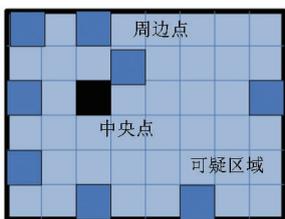


图3 可疑缺陷区域

Fig. 3 Suspicious defect area

(3)定义中央区域 $A(x_m, y_n)$ 为8个周边点之间的像素组成(如图3所示),为可能存在缺陷的注意区域。

定义8邻域方向上中央-周边差 $\Delta h(x_{mk}, y_{nk}) = h(x_{mk}, y_{nk}) - h(x_m, y_n)$  ( $k=1, 2, \dots, 8$ );定义最大者为区域中央-周边差 $\Delta h$ 。

(4)将区域中央-周边差 $\Delta h$ 与给定阈值 $T$ 进行比较。若 $\Delta h < T$ ,则判定该注意区域间没有缺陷;若 $\Delta h \geq T$ ,则判定该注意区域间存在缺陷,标记该区域为可疑缺陷区域。进一步判断可疑缺陷区域范围,若 $\Delta h(x_{mk}, y_{nk}) > T$ ,则中央点 $(x_m, y_n)$ 与周边点 $(x_{mk}, y_{nk})$ 之间为缺陷像素。

阈值 $T$ 确定方法:扫描一幅同类型无缺陷射线图像,计算并搜索其各注意区域的中央-周边差 $\Delta h$ ,假设最大中央-周边差为 $\Delta h_{\max}$ ,则 $T = \Delta h_{\max} + \lambda \sigma$ 。其中 $\sigma$ 为多幅无缺陷射线图像 $\Delta h_{\max}$ 的标准偏差, $\lambda$ 为常系数,一般可取1~5。

(5)标记注意区域中的可疑缺陷像素,以其外接最小长方形为基础外延至64像素×64像素区域,作为帧间跟踪的图像区域。

(6)从步骤(2)停止搜索的最右像素点开始,继续列扫描,重复执行步骤(2)~(5),直至扫描完成

整幅射线图像。

(7)如缺陷为亮缺陷即高灰度值性质缺陷,重复执行步骤(1)~(6)。只是在步骤(2)、(3)时搜索局部极大灰度值,再搜索最近的谷底。扫描标记出含高灰度值缺陷的可疑帧间缺陷区域。

### 3 基于深度学习特征匹配的可疑缺陷区域跟踪

在帧内阶段获取可疑缺陷区域的基础上,提出基于深度学习特征匹配的帧间可疑缺陷区域跟踪方法,建立基于卷积神经网络的深度学习特征提取模型,将可疑区域的像素灰度信号直接作为已训练模型的输入,自动挖掘可疑缺陷区域的本质特征,组成深度学习特征矢量,通过特征矢量匹配,实现对帧间可疑缺陷区域的准确跟踪。

#### 3.1 深度学习特征自动提取

模拟生物视觉感知系统的神经网络模型,提出的基于深度卷积神经网络的深度学习特征自动抽取原理如图4所示,除了原始图像输入层、特征矢量输出层外,还含有若干由相应数量二维特征图构成的卷积层和降采样层,可逐层抽取可疑区域的更高级本质特征,且抽取的特征具有对旋转、缩放和平移的不变性,这正是缺陷匹配所必需的。

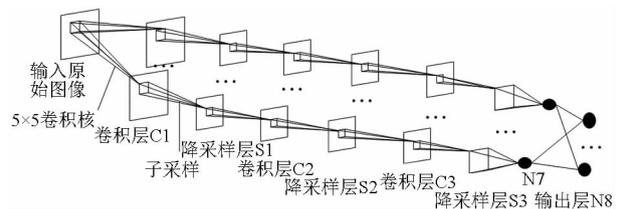


图4 深度学习特征自动抽取原理图

Fig. 4 Principle diagram of automatic extraction based on deep learning features

深度学习网络层次结构及参数如表1所示。

表1 层次结构及参数

Tab. 1 Hierarchy and parameters

层数	类型	特征图个数	特征图尺寸	卷积核
0	输入层 X0	1	64 × 64	
1	卷积层 C1	12	60 × 60	5 × 5
2	降采样层 S1	12	30 × 30	2 × 2
3	卷积层 C2	24	26 × 26	5 × 5
4	降采样层 S2	24	13 × 13	2 × 2
5	卷积层 C3	24	10 × 10	4 × 4
6	降采样层 S3	24	5 × 5	2 × 2
7	全连接层 N7	24	1 × 1	5 × 5
8	特征输出层 N8	32	1 × 1	

(1)输入层。通过模拟注意机制的中央-周边差计算标记出的64像素×64像素可疑匹配区域直接对应网络输入层神经元。

(2)卷积层。前一层(输入层或降采样层)的相应特征图  $X_{l-1,j}$  与卷积核  $k_{l,x} \times k_{l,y}$  进行二维卷积后,再通过组合得到卷积层的特征图  $X_{l,j}$ ,第  $l$  卷积层的第  $j$  个特征图  $X_{l,j}$  为

$$X_{l,j} = f\left(\sum_{i \in M_j} X_{l-1,j} w_{l,i,j} + b_{l,j}\right) \quad (1)$$

式中  $M_j$ ——相连的前一层输入特征图  $X_{l-1,j}$  集合  
 $b_{l,j}$ ——偏置常量  
 $w_{l,i,j}$ ——对应权值

卷积层 C1 共有 12 个特征图,分别由  $60 \times 60$  个神经元组成。每个神经元分别与输入层 X0 对应的  $5 \times 5$  邻域相连,以抽取该区域内的特征。

卷积层 C2 和 C3 与卷积层 C1 的连接及特征抽取过程类似。

(3)降采样层。降采样层的每个特征图与前一卷积层每个特征图对应相连,通过降采样函数  $\text{down}(X_{l-1,j})$  对各 4 像素  $\times$  4 像素区域进行局部平均处理,以产生平移不变性。第  $l$  降采样层的第  $j$  个特征图  $X_{l,j}$  为

$$X_{l,j} = f(\beta_{l,j} \text{down}(X_{l-1,j}) + b_{l,j}) \quad (2)$$

式中  $\beta_{l,j}$ ——乘性偏置常量

降采样层 S1 共有 12 个二维特征图,分别由  $30 \times 30$  个神经元组成。每个神经元与 C1 中相对应特征图的  $2 \times 2$  邻域相连接,进行子采样,每个特征图缩小到 C1 层特征图的  $1/4$  大小,但保留了有用信息。

降采样层 S2 和 S3 与降采样层 S1 的连接及特征抽样过程类似。

(4)全连接层 N7。N7 层与 S3 层之间为全连接,N7 每个神经元与 S3 层各  $5 \times 5$  特征图对应相连。卷积核的大小相同,也为  $5 \times 5$ ,因此 N7 特征图的大小为  $1 \times 1$ ,N7 层共含 200 个神经元。

(5)输出层 N8。特征输出层 N8 通过组合 N7 层特征获得 32 个深度学习特征。

由 N8 层抽取的 32 个隐性特征组成深度学习特征矢量  $\mathbf{A} = (a_1, a_2, \dots, a_{32})$ 。

### 3.2 缺陷动态跟踪

通过平移、旋转工件获得连续 3 帧不同视角下的投影图像,分别检查相邻两帧图像间的缺陷匹配来实现缺陷动态跟踪,以消除误检。不同帧间缺陷是否匹配是以深度学习特征矢量的相似度来判别,两个可疑缺陷区域的相似度  $K$  定义为其深度学习特征矢量之间的欧氏距离。

$$K(\mathbf{A}_{(m,n)}, \mathbf{B}_{(x,y)}) = \frac{\|\mathbf{A}_{(m,n)} - \mathbf{B}_{(x,y)}\|}{\sqrt{\sum_{i=1}^{32} (a_{(m,n)}^{(i)} - b_{(x,y)}^{(i)})^2}} \quad (3)$$

其中  $\mathbf{A}_{(m,n)} = (a_{(m,n)}^{(1)}, a_{(m,n)}^{(2)}, \dots, a_{(m,n)}^{(32)})$

$\mathbf{B}_{(x,y)} = (a_{(x,y)}^{(1)}, a_{(x,y)}^{(2)}, \dots, a_{(x,y)}^{(32)})$

式中  $\mathbf{A}_{(m,n)}$ 、 $\mathbf{B}_{(x,y)}$ ——中央点坐标分别为  $(m, n)$  和  $(x, y)$  的可疑区域深度学习特征矢量

第  $a$  帧射线图像有  $p$  个可疑缺陷区域,与第  $b$  帧射线图像的  $q$  个可疑缺陷区域两两匹配,如相似度  $K(\mathbf{A}_{(m,n)}, \mathbf{B}_{(x,y)}) < \xi$  时( $\xi$  为一极小判别阈值),则深度学习特征矢量匹配,判定该两缺陷区域为同一区域,缺陷存在。否则,区域中的可疑缺陷为噪声等伪缺陷。深度学习特征是缺陷区域的全局特征,不同缺陷区域间有较大的区分度,实验证明不同帧间图像中的不同缺陷区域相似度大于 1.1,而相同缺陷区域的相似度小于 0.2,因此,实验中  $\xi$  取定值 0.5。

## 4 实验

图 5 所示为含有 4 个直径为 0.6 ~ 1.0 mm 渣孔缺陷铸件的 3 帧连续射线图像,b 帧图像相对 a 帧图像铸件有平移运动,c 帧图像相对于 a 帧图像铸件既有平移运动又有旋转运动。

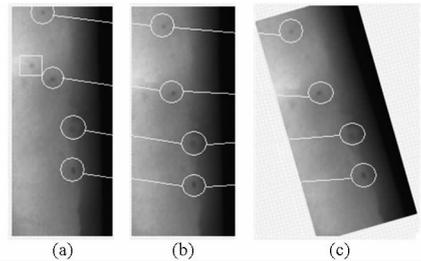


图 5 缺陷跟踪过程

Fig.5 Defect tracking process

通过提出的模拟视觉注意机制的中央-周边差算法,在 a、b、c 帧射线图像中分别检出了 5、4、4 个可疑缺陷区域,在图中用白色圆框或方框表示。然后基于深度卷积神经网络自动提取各可疑区域的深度学习特征,并组成特征矢量  $\mathbf{F}$ 。

铸件不同缺陷中,直径 1 mm 以下的微小缺陷因其面积小以及易受噪声干扰是最难区分的,其训练与测试误分类率曲线如图 6 所示,训练的误分类率可达到 5%,对其他类型缺陷的分类准确率更高。

进一步,对 a 帧与 b、c 帧图像中的可疑缺陷区域进行两两匹配,计算各区域的相似度  $K$ ,a 帧中有 4 个可疑区域在 b、c 帧实现了跟踪,如图中白色圆框和连接线所示,确定为真实缺陷。而 a 帧图像中用白色方框表示的可疑区域在 b、c 帧中都没有匹配区域,因此判定为伪缺陷成功排除。实验证明了本文方法能对旋转、缩放和平移后的射线缺陷图像准

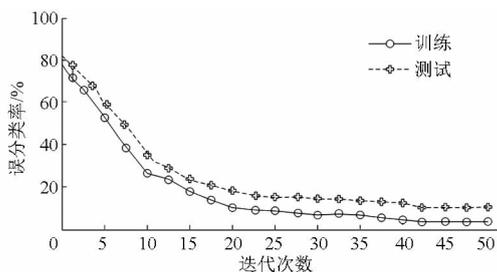


图 6 微小缺陷误分类率变化曲线

Fig. 6 Error rate curves of the small defect

确动态跟踪判别。

用本文方法对 166 幅不同铸件射线图像缺陷进行了连续检测,检测结果如表 2 所示,误检率和漏检率都较低,检测的总准确率超过 97%,而前述传统方法的准确率都低于 90%,说明了本文方法的先进性和有效性。

表 2 实验检测结果

Tab. 2 Experimental result

产品总数	误检数	误检率/%	漏检数	漏检率/%	准确率/%
166	2	1.2	3	1.8	97.0

为了进一步说明本文方法的有效,对本文所述实验对象,与文献[7]中极线约束跟踪方法和文献[8]中传统特征匹配跟踪方法进行对比实验,结果如表 3 所示。实验表明,本文方法的误检率和漏检率都低于其他方法,准确率比其他方法高 5 个百分点以上,并且实现了动态检测过程的自动化。因此,本文方法具有一定先进性。

为评价本文方法运算效率,比较几种方法的缺陷匹配所用时间,结果如表 4 所示。算法都是在 Intel i5-4590 CPU,8 GB 内存的计算机上用 Matlab 2015a 实现,如用 C++ 语言编程实现,所需计算时

表 3 对比实验数据

Tab. 3 Data of comparative experiments %

参数	极线约束跟踪	传统特征匹配	本文方法
	方法	跟踪方法	
误检率	7.6	4.5	1.2
漏检率	8.2	3.1	1.8
准确率	84.2	92.4	97.0

表 4 铸件缺陷检测时间对比

Tab. 4 Comparison of consuming time

方法	极线约束	传统特征匹配	本文方法
	跟踪方法	跟踪方法	
时间/ms	1 015	896	760

间应会更少,满足 60 件/min 的检测要求。

## 5 结论

(1)通过模拟人眼视觉注意机制的中央-周边差计算方法来直接检测可疑缺陷区域,无需分割出缺陷本身,避免了帧内缺陷分割提取正确性对帧间跟踪的极大影响,因此,在提高检测速度的同时大大降低了漏检率。

(2)建立了基于卷积神经的深度学习网络,自动抽取表征可疑缺陷区域的本质特征信息,通过连续帧图像中可疑缺陷区域的深度学习特征匹配,实现了缺陷准确动态跟踪,消除了噪声等伪缺陷,大大降低了误检率。

(3)实验结果与理论分析基本相符,本文方法的误检率和漏检率均低于 3%,缺陷检测准确率超过 97%。与极线约束跟踪等方法比较,准确率提高 5 个百分点以上,证明了本文方法的先进性和有效性。

## 参 考 文 献

- 1 BANIUKIEWICZ P. Automated defect recognition and identification in digital radiography [J]. Journal of Nondestructive Evaluation, 2013, 33(3):327-336.
- 2 ALAKNAND A, ANAND R S, KUMAR P. Flaw detection in radiographic weldment images using morphological watershed segmentation technique[J]. NDT & E International, 2009, 42(1):2-8.
- 3 郭文川,梁玮,宋怀波.基于邻差和的农产品 X 射线图像分割算法[J].农业机械学报,2012,43(11):214-219. GUO Wenchuan, LIANG Wei, SONG Huaibo. Segmentation method of agricultural products' X-ray image based on sum of neighborhood differences [J]. Transactions of the Chinese Society for Agricultural Machinery, 2012, 43(11):214-219. (in Chinese)
- 4 王中宇,付继华,孟浩,等.基于灰色关联分析和区域生长的微小缺陷提取[J].农业机械学报,2008,39(12):166-169. WANG Zhongyu, FU Jihua, MENG Hao, et al. Small defect extracting based on region growing algorithm and grey relational analysis [J]. Transactions of the Chinese Society for Agricultural Machinery, 2008, 39(12):166-169. (in Chinese)
- 5 余永维,殷国富,殷鹰,等.基于视觉显著度的射线图像微小缺陷提取方法[J].农业机械学报,2015,46(7):365-371. YU Yongwei, YIN Guofu, YIN Ying, et al. Detection of tiny defect in radiographic images based on visual saliency [J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(7):365-371. (in Chinese)
- 6 DOMINGO M, DIETER F. Automated flaw detection in aluminum castings based on the tracking of potential defects in a radioscopic image sequence [J]. IEEE Transactions on Robotics and Automation, 2002, 18(6):890-900.
- 7 周正干,杜圆媛.基于多幅 X 射线数字图像的缺陷自动识别技术[J].机械工程学报,2006,42(3):77-80.

- ZHOU Zhenggan, DU Yuanyuan. Automated defects recognition technique based on multiple radiographic images[J]. Journal of Mechanical Engineering, 2006,42(3): 77-80. (in Chinese)
- 8 田原, 都东, 侯润石, 等. 基于 X 射线图像序列的焊缝缺陷自动检测方法 [J]. 清华大学学报: 自然科学版, 2007, 47(8): 1278-1281.
- TIAN Yuan, DU Dong, HOU Runshi, et al. Automatic inspection of weld defects using X-ray image sequences[J]. Journal of Tsinghua University: Natural Science, 2007, 47(8): 1278-1281. (in Chinese)
- 9 BENGIO Y. Learning deep architectures for AI[J]. Foundations and Trends in Machine Learning, 2009, 2(1): 1-127.
- 10 谭文学, 赵春江, 吴华瑞, 等. 基于弹性动量深度学习神经网络的果体病理图像识别[J]. 农业机械学报, 2015, 46(1): 20-25.
- TAN Wenxue, ZHAO Chunjiang, WU Huarui, et al. A deep learning network for recognizing fruit pathologic images based on flexible momentum[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 20-25. (in Chinese)
- 11 ABDEL H O, MOHAMED A R, JIANG H, et al. Convolutional neural networks for speech recognition [J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2014, 22(10): 1533-1545.
- 12 SWIETOJANSKI P, GHOSHAL A, RENALS S. Convolutional neural networks for distant speech recognition [J]. IEEE Signal Processing Letters, 2014, 21(9): 1120-1124.
- 13 SILITO A M, GRIEVE K L, JONES H E. Visual cortical mechanisms detecting foveal orientation discontinuities[J]. Nature, 1995, 378: 492-496.
- 14 ITTI L, KOCH C, NIEBUR E. A model of saliency-based visual attention for rapid scene analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254-1259.
- 15 ITTI L. Visual attention and target detection in cluttered natural scenes[J]. Optical Engineering, 2001, 40(9): 1784-1793.
- 16 VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371-3408.