

核燃料芯块的表面裂纹检测算法研究

宋文豪, 张斌*, 李峰宇, 杨腾达, 李建宁, 杨小会

郑州大学物理工程学院, 河南 郑州 450001

摘要 为保证反应堆的安全运行, 需要采用多种检测技术确保燃料芯块质量。针对燃料芯块表面裂纹检测中因图像对比度低、背景复杂而导致的裂纹误检率高的问题, 提出了一种基于卷积神经网络(CNN)和 Beamlet 算法相结合的表面裂纹检测算法。对图像进行等尺度分割作为裂纹识别模型(CrackCNN)的训练和测试样本; 采用训练完成的 CrackCNN 对图像中含裂纹的区域进行识别和定位; 采用 Beamlet 算法针对含裂纹区域进行裂纹检测。该算法将 CNN 和 Beamlet 相结合, 充分发挥两者的优势, 有效降低了裂纹误检概率, 提高了检测精度。实验结果表明, 相对于单独采用 Beamlet 算法, 本文算法的 F -measure 提升了 6.4%; 相对于双重阈值和张量投票算法, 本文算法的 F -measure 提升了 3.4%。

关键词 图像处理; 裂纹检测; 卷积神经网络; 核燃料芯块; Beamlet 算法

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.161008

Surface Crack Detection Algorithm for Nuclear Fuel Pellets

Song Wenhao, Zhang Bin*, Li Fengyu, Yang Tengda, Li Jianning, Yang Xiaohui

College of Physical Engineering, Zhengzhou University, Zhengzhou, Henan 450001, China

Abstract To ensure safe reactor operation, a variety of detection techniques are required to ensure the qualities of fuel pellets. To address high misdetection rate of cracks due to low contrast and complex background in the detection of surface cracks in fuel pellets, a surface crack detection algorithm based on convolutional neural networks (CNN) and the Beamlet algorithm is proposed. First, images are divided into equal-sized patches, which are used as training samples for the crack recognition model (CrackCNN). Then, the crack-containing region in the image is identified and located by the trained CrackCNN. Finally, a crack in identified region is detected by the Beamlet algorithm. The proposed method, which utilizes both CNNs and Beamlet, can improve detection accuracy and effectively reduce the probability of crack misdetection. Experimental results demonstrate that the F -measure of the proposed algorithm is enhanced by 6.4% and 3.4% compared to using only the Beamlet algorithm and using the double threshold and tensor voting algorithm, respectively.

Key words image processing; crack detection; convolutional neural networks; nuclear fuel pellet; Beamlet algorithm

OCIS codes 100.2000; 100.4996; 150.1135

1 引言

截至 2015 年, 中国核能发电量为 1689.93 亿千瓦时, 约占全国发电总量的 3.01%, 而核电利用率最高的法国, 约占 73.3%。可见, 我国核电领域仍有很大的发展空间^[1]。核燃料芯块作为反应堆的基础核心元件, 会经历压制、烧结、研磨等复杂的工艺过程, 在装棒之前必须确保燃料芯块外观无瑕疵, 以杜绝

芯块和包层发生相互作用^[2]。燃料芯块破损可能引起反应堆结构安全、热工安全、辐射屏蔽系统承受能力以及工作人员辐射安全等问题^[3]。目前主要采用的无损检测手段包括中子照相^[4]、DR/CT 成像^[5]等, 虽然能够对芯块内部和外部进行整体的质量检测, 但当检测任务仅仅针对芯块表面时^[6], 存在成本高、技术难度大、检测效率低的问题。因此研究更高效的燃料芯块的表面缺损检测方法, 特别是裂纹检

收稿日期: 2019-02-26; 修回日期: 2019-03-13; 录用日期: 2019-03-22

基金项目: 国家自然科学基金(81171410)

* E-mail: zb1967@zzu.edu.cn

测方法,极为重要。

在机器视觉领域,针对其他物体的裂纹检测算法已较为成熟。如文献[7]中将张量投票算法用于裂纹片段的连接,有效克服了复杂背景下裂纹检出不连续的问题,但该算法运行速度较慢且易受伪裂纹影响;文献[8]中提取图像的LBP特征,结合SVM对图像是否含有裂纹进行分类,该方法在图像背景较为复杂的情况下效果不好,且提取图像局部二值模式(LBP)特征耗时较长;文献[9]中利用卷积神经网络(CNN)对道路表面病害进行识别,克服了路面裂纹检测中复杂多变的光照条件,但仅适用于尺寸较大的裂纹;文献[10]中将Beamlet变换用于图像中线性特征的提取,能够在强噪声的背景中提取线性特征,但算法计算速度较慢,无法用于实时检测。同时,燃料元件为黑色圆柱体,且尺寸较小,标准规格为 $\Phi 8\text{ mm} \times 10\text{ mm}$,这进一步增大了表面裂纹的检测难度。

针对上述情况,本文提出基于CNN和Beamlet变换的算法。该算法采用CNN和窗口滑动技术识别图像中的含裂纹区域,去除伪裂纹和背景的干扰;针对含

裂纹区域采用Beamlet算法提取裂纹特征;根据形态学判断去除干扰,得到裂纹检测结果。由于真实芯块具有放射性,不便于在实验室长期使用。在系统算法设计和验证阶段,采用中国原子能科学研究院提供的高仿真类陶瓷仿体作为研究和检测对象。实验结果表明,相比于文献[7]中方法,本文算法的F-measure提升了3.4%,相比于文献[10]中方法,F-measure提升了6.4%,且检测速度大幅提高。

2 算法实现

本文算法流程如图1所示,主要包括以下几个步骤:1)预处理,包括去除图像背景和对图像进行等尺度分割,建立数据集,见图1的第一个虚线框。2)搭建并训练CrackCNN网络,结合窗口滑动技术,识别和定位图像中的含裂纹区域,去除图像中无裂纹和伪裂纹区域,见图1的第二个虚线框。3)采用Beamlet算法对含裂纹区域进行处理,提取裂纹特征,并根据区域形态学信息,去除干扰,最终得到裂纹检测结果,见图1的第三个虚线框。

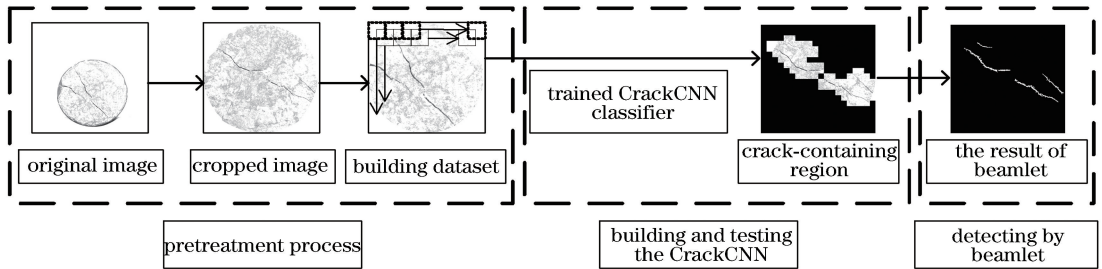


图1 本文算法流程图

Fig. 1 Flow chart of proposed method

2.1 图像预处理

待检燃料仿体端面图像如图2(a)所示,仿体边界特征复杂,影响裂纹提取,且图像中存在大量无效背景区域,故作以下处理:1)计算图像的局部标准偏差,得到仿体端面区域,计算该区域左右方向上的最大距离 d 和最大距离所在行的中点,以该中点为圆心, $d/2 - 30$ 为半径作圆,得到端面去除边界后的区域 R ,见图2(b)中黑色网格区域。




图2 预处理过程。(a)原始图像;(b)掩模区域;(c)感兴趣区域图像

Fig. 2 Pretreatment process. (a) Original image; (b) mask region; (c) region of interest

2)将区域 R 与原图像求交集,从原图像中提取感兴趣区域,并根据区域 R 的最小外接矩形,对交集得到的图像进行裁剪,从而去除大量无效背景,效果如图2(c)所示,此时图像尺寸约为 $600\text{ pixel} \times 600\text{ pixel}$ 。3)为方便后续处理,同时尽可能少地改变图像尺寸信息,将所得图像归一化到 $600\text{ pixel} \times 600\text{ pixel}$,得到待处理图像。接下来所有工作针对待处理图像进行。

得到待处理图像后,按照 60 pixel×60 pixel 的窗口、30 pixel 步长对其进行分割,如图 3 所示。对分割窗口进行两次扫描,防止裂纹在某一次分割时,处于窗口边缘而导致特征不够明显。第一次分割的起始位置为(0,0),终止位置为(600,600),扫描轨迹如图 3 的虚边框小矩形所示;第二次分割的起始位置为(30,30),终止位置为(570,570),如图 3 的实边框小矩形所示。分割时步长选取 30 pixel,以保证图像块之间重叠区域较小,降低样本之间的相似性^[11]。




图 3 窗口扫描轨迹

Fig. 3 Window scanning trace

最后,按照 1 : 1 的比例,从所有分割图像块中挑选出无裂纹图像块和含裂纹图像块,将无裂纹图像块标记为 0,含裂纹图像块标记为 1,作为 CrackCNN 的数据集,共得到 12000 组标记数据。为了使 CNN 能更好地识别微裂纹特征,提高识别

准确率,将数据集中所有图像块的大小变换为 120 pixel×120 pixel。

2.2 CNN 的构建与实现

在裂纹识别中,含裂纹图像块和无裂纹图像块在灰度、形貌、纹理等方面存在差异,可以用 CNN 对其进行分类,达到裂纹识别的目的。因此根据建立的数据集,按照 4 : 1 的比例将其分为训练集和测试集两种,用于训练和测试搭建 CrackCNN 模型。CrackCNN 的结构设计如图 4 所示,输入是 120 pixel×120 pixel 的灰度图像,输出为二维向量,其中 Conv、MP 和 Fc 分别表示卷积层、最大池化层和全连接层。表 1 给出了模型各层的具体参数。

表 1 CrackCNN 模型参数配置

Table 1 Parameter configurations of CrackCNN

Layer	Kernel shape	Output channel	Stride	Variable
Conv1	3×3×1	32	1	320
Pool1	3×3×1	—	2	0
Conv2	3×3×32	48	1	13872
Pool2	3×3×1	—	2	0
Conv3	5×5×48	64	1	76864
Pool3	3×3×1	—	2	0
Conv4	3×3×64	80	1	46160
Pool4	3×3×1	—	2	0
Fc1	8×8×80	100	—	512100
Fc2	100	2	—	202




图 4 CrackCNN 的结构

Fig. 4 Structure of CrackCNN

1) 通过卷积层对输入图像进行卷积运算,提取图像特征,网络中所有卷积核采用高斯分布初始化,标准差设为 0.05。卷积计算公式为

$$\mathbf{x}_i^l = f\left(\sum_{i \in M_j} \mathbf{x}_i^{l-1} * \mathbf{W}_j^l + \mathbf{b}_j^l\right), \quad (1)$$

式中: l 表示第 l 层卷积层; \mathbf{W}_j^l 为该层的第 j 个卷积核的权值矩阵; $*$ 代表卷积运算; \mathbf{b}_j^l 为该卷积核对应的偏置项, \mathbf{b}_j^l 为由 b_j^l 组成的矩阵; \mathbf{x}_i^{l-1} 为网络上一层第 i 个输出灰度图; M_j 为第 j 个卷积核的感受野。线性整流激活函数 ReLU 的表达式为

$$f(x) = \max(0, x), \quad (2)$$

该激活函数能有效解决模型梯度消失和梯度爆炸的问题。

2) 对于卷积层得到的特征图层,为了降低特征维度,提升训练效率,一般采用池化层对其进行降维。最大池化使网络具有一定的平移不变性,可以更好地保留图像裂纹特征,因此选用最大池化进行池化操作。

3) 通过多个卷积池化层,将图像的底层特征转化为高层特征,并经过全连接层对其逐层融合,组成

图像的全局特征表述,有效减少了特征信息的损失。由于裂纹分类的互斥性(有无裂纹),网络最后一层神经元数目设定为 2,并采用 softmax 函数输出分类结果的概率分布。同时,为了防止网络过拟合,在全连接层之间采用 Dropout 方法^[12-13]。

采用交叉熵损失函数作为损失函数,通过最小化损失函数,寻找模型最优参数。假定训练集合 $S_m = \{X, Y\}$,共有 m 个元素,其中 X 为集合的图像样本, Y 为图像对应类别的标签。样本有两种类别,故标签 $Y \in \{0, 1\}$ 。其中 x_a 为集合中第 a 个元素,其标签为 y_a 。则损失函数 $J(W, b)$ 可以表示为

$$J(W, b) = -\frac{1}{m} \left[\sum_{a=1}^m \sum_{t=1}^n 1\{y_a = n\} \ln \left(\frac{\exp z_t^a}{\sum_{i=1}^n \exp z_i^a} \right) \right], \quad (3)$$

式中: z_t^a 是第 a 个样本的最后一层第 t 个神经元的输出,该输出与模型所有层的卷积核的权值矩阵 W_j^l 和偏置项 b_j^l 有关,故此处 W 是关于模型所有层中卷积核权值矩阵 W_j^l 的函数; b 是关于所有偏置项 b_j^l 的函数; $t_n = 2$,代表有两种分类结果; $1\{\cdot\}$ 为示性函数,当括号内表达式为真时,输出为 1,否则输出为 0。

为了使损失函数最小化,采用梯度下降和反向传播算法对模型参数进行更新^[14-15],权值矩阵 W_j^l 和偏置 b_j^l 迭代公式为

$$\begin{cases} W_{fj}^l(q+1) = W_{fj}^l(q) - \alpha \frac{\partial}{\partial W_{fj}^l(q+1)} J(W, b) \\ b_j^l(q+1) = b_j^l(q) - \alpha \frac{\partial}{\partial b_j^l(q+1)} J(W, b) \end{cases}, \quad (4)$$

式中: $W_{fj}^l(q)$ 为 W_j^l 第 q 次迭代的权值矩阵元; q 、 $q+1$ 为训练过程中的迭代次数; α 为网络学习速率,用于控制梯度下降步长和参数更新速度。

在训练过程中,学习率初始值为 0.01,每 5000 次迭代变为原来的 0.1 倍, batch_size 大小设置为 64。网络训练过程中对应的损失函数和测试集上的准确率如图 5 所示。10000 步后,模型在测试集上准确率趋于稳定,达到 97% 左右。采用此时的模型参数对图像中含裂纹区域进行识别和定位,达到去除伪裂纹和无效区域干扰的目的。

2.3 Beamlet 裂纹检测算法

Beamlet 算法是由 Donoho 等^[16]提出的具有局部性、方向性和多尺度特性的图像几何分析工具。该方法在强噪声图像中线特征提取效果较好,但计

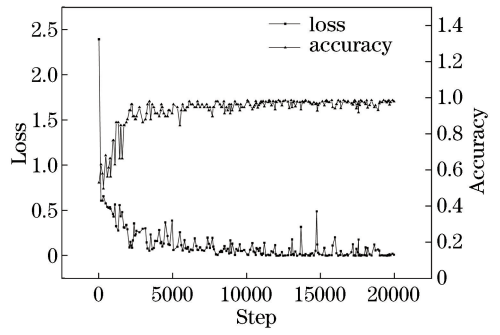


图 5 CrackCNN 的损失和准确率

Fig. 5 Loss and accuracy of CrackCNN

算量较大。因此本文只针对 CrackCNN 识别得到的含裂纹区域进行裂纹检测,极大地减少了 Beamlet 算法的计算量,检测效率大幅度提升。Beamlet 算法中有两个重要概念: Beamlet 基和 Beamlet 变换。

对于一幅 $n \times n$ 的图像,并且 $n = 2^K$,定义图像边长为单位长度 1,则所有像素的相对坐标都位于 $[0, 1]^2$ 内。在尺度 $0 < k < K$ 上,图像分为 $2^k \times 2^k$ 个边长为 2^{-k} 的子正方形, k 为尺度因子。取固定分辨率 $\delta = 2^{-k-p}$ ($p \geq 0, \delta \geq \frac{1}{n}$),以 δ 在每个子正方形的边界上标记顶点。任意一个子正方形中连接任意一对顶点作为一个 Beamlet 基。图 6 所示为不同尺度、不同方向和位置的 Beamlet 基。




图 6 不同尺度下的 Beamlet 基。(a) 尺度为 0; (b) 尺度为 1; (c) 尺度为 2; (d) 尺度为 3

Fig. 6 Beamlets at different scales. (a) Scale is 0; (b) scale is 1; (c) scale is 2; (d) scale is 3

为了方便计算机处理,一个 Beamlet 基的离散 Beamlet 变换就是这个基上所有像素点的灰度值加权。整幅图像中离散 Beamlet 变换^[17]定义为

$$T(c) = \sum_{(x,y) \in c} G(x,y), c \in C, \quad (5)$$

式中: c 为某一尺度下某一方向和一个位置的 Beamlet 基; C 为所有尺度下 Beamlet 基的集合, G

(x, y) 是 c 上像素点 (x, y) 的灰度值。

提取裂纹特征时,计算每个基的能量统计,然后将能量统计小于阈值的基置 0 并作为背景,大于阈值的基组成裂纹特征。能量统计公式为

$$Y^+ = \max\{T(c) / \sqrt{L(c)}; c \in C\}, \quad (6)$$

式中: $L(c)$ 为基 c 的几何长度; $T(c)$ 为基 c 的离散 Beamlet 变换系数。

3 实验结果与分析

核燃料芯块表面裂纹检测中,检测精度和检测效率都非常重要。高精度的检测能够有效降低漏判带来的安全隐患,避免大量误判带来的经济损失;高效率的检测能提高芯块产能。因此,随机挑选 30 个含裂纹仿体,采用 Basler Aca 1600-20gm 相机进行端面图像采集,并在 Intel(R) Xeon (R) E5-2637 V3 @3.5 GHz CPU 和 NVIDIA Quadro K 2200 GPU 平台上,对这 30 幅图像进行实验,对本文算法性能进行评估。评估指标主要有以下 3 个^[18],查准率 (P);查全率(R)和 F -measure(F),定义分别为

$$P = \frac{\sum_{(x,y)} G(x,y)B(x,y)}{\sum_{(x,y)} B(x,y)} = \frac{L_r}{L_n}, \quad (7)$$

$$R = \frac{\sum_{(x,y)} G(x,y)B(x,y)}{\sum_{(x,y)} G(x,y)} = \frac{L_r}{L_s}, \quad (8)$$

$$F = \frac{2 \times P \times R}{P + R}, \quad (9)$$

式中: G 为人工标记的裂纹图像,作为该图像中裂纹的真实值; B 为算法检测得到的裂纹结果; L_r 为检测结果中属于真实裂纹的部分; L_n 为检测结果中所有的裂纹; L_s 为人工标记的真实裂纹; F 为关于 P 和 R 的综合评价指标。

3.1 Beamlet 变换中本文阈值方法和固定阈值方法结果对比

在选取 Beamlet 线段时,阈值的设定对检测结果的影响很大。阈值过大可能会引起漏检,过小则可能导致误检,且不同图片之间理想阈值差异较大。为了获得最佳的阈值效果,本文选取一系列固定阈值对 30 幅含裂纹图像进行处理,即每一个阈值均对 30 幅图像进行裂纹检测,并计算裂纹检测结果的平均 F ,作为最终阈值选取的评价指标。如图 7 中方形折线所示,在 0.4~0.8 阈值(T)范围内,每隔 0.04 取一次值作为固定阈值,在 $T=0.6$ 时, F 最高,为 0.708。可以明显看出,采用固定阈值并不能很好地

检测裂纹。因此,尝试采用动态阈值替换传统的阈值方法。通过大量实验发现,选用动态阈值 $T=M-0.16$ 时,裂纹检测结果的平均 F 达到 0.804,明显优于传统的固定阈值方法,其中 M 是该基所在的子正方形的灰度平均值,0.16 是经验值。从图 7 中两种阈值方法检测结果对比可知,选择动态阈值 $T=M-0.16$ 。

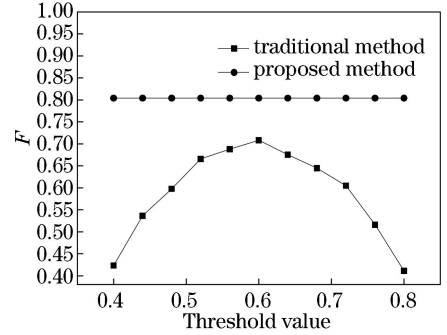


图 7 不同阈值方法对比

Fig. 7 Comparison of different threshold methods

3.2 裂纹检测结果分析

将本文算法与双重阈值、张量投票算法^[7]、传统 Beamlet 算法^[10]进行对比。实验过程中, CrackCNN 模型的建立和测试使用的数据集共 12000 个样本,其中训练集为 9600 个,测试集为 2400 个,该数据集中不含用于算法性能评估的 30 幅图像。模型在 10000 步后测试集准确率达到 97% 并趋于稳定,选取此时模型参数用于算法性能分析。采用的 Beamlet 算法的尺度因子 k 为 3,阈值为 3.1 节介绍的动态阈值 $T=M-0.16$ 。3 种算法的检测对象均采用 2.1 节介绍的预处理方法进行处理,表 2 显示了 3 种算法分别对 30 幅图像处理后,裂纹检测结果的平均查准率 P 、查全率 R 和 F -measure(F) 的值。图 8 所示为 3 幅不同图像的裂纹检测结果。其中,第一、二行为仿体端面裂纹图像,第三行为采用线扫描相机拍摄得到的仿体侧面裂纹图像,均采用同样方法进行检测。

表 2 不同方法对比

Table 2 Comparison of different methods

Method	Precision	Recall	F -measure	Time /s
Beamlet	0.701	0.783	0.74	13.6
Double threshold and tensor voting	0.740	0.803	0.77	6.93
Proposed method	0.775	0.836	0.804	2.41

每列分别为原始图像、真实裂纹,以及双重阈值和张量投票算法、Beamlet 算法和本文算法的检测结果,可以看出,本文算法可以应用于整个仿体表面的裂纹检测。

从表 2 可以看出,本文算法的查准率为 0.775,明显高于单独采用 Beamlet 算法的 0.701,这说明本文算法中采用 CrackCNN 对裂纹识别定位,有效避免了伪裂纹的影响,降低了裂纹误检概率,如图 8 第一行的第三和第五个检测结果所示;而相比文献[7]中算法的 0.74,本文算法的查准率没有明显提高的原因在于利用 Beamlet 算法进行裂纹检测时,在一个子图像块中可能提取多个基,检出裂纹的宽度往往略大于真实裂纹,查准率会有所下降。

本文算法的查全率为 0.836,高于文献[7]中算法的 0.803,说明 Beamlet 算法对裂纹的提取效果更好,如图 8 第二行的第四和第五个检测结果所示;且仅对含裂纹区域检测时,不用考虑伪裂纹等因素的影响,Beamlet 算法的阈值设定更有针对性,因此相比文献[10]中方法对整幅图像检测,查全率从 0.783 提升至 0.836,如图 8 第三行的第三和第五个检测结果所示。而本文算法的综合评价指标 F -measure 为 0.804,同样高于其他两种算法的 0.74 和 0.77,说明本文算法对裂纹的检测效果优于其他两种算法。同时,从算法处理速度来看,本文算法用时明显少于其他两种算法,为工业产线的实际应用提供了可能。




图 8 3 种方法检测结果

Fig. 8 Detection results of three methods

4 结 论

针对传统检测方法中伪裂纹误检以及噪声干扰影响较大的问题,提出 CNN 与 Beamlet 相结合的算法,并在燃料芯块仿体上对算法性能进行测试分析。实验结果表明,本文算法有效克服了伪裂纹区域和噪声干扰的问题,具有较高的裂纹检出率,大幅提高了 Beamlet 算法的检测效率,且在仿真生产线上进行验证,满足相关技术指标,为真实核燃料的表面裂纹检测提供了重要参考。但采用 Beamlet 算法对裂纹区域检测时,由于在一个子图像块中可能提取多个基,检出裂纹的宽度往往略大于真实裂纹。后续需要对该问题进行深入研究,进一步提高算法性能。

参 考 文 献

- [1] Xu J M. Research on the status of China's nuclear power development and international development countermeasures [J]. Power Equipment Management, 2018, 2: 1-2.
许建明. 中国核电发展现状与国际化发展对策研究[J]. 电力设备管理, 2018, 2: 1-2.
- [2] Piro M H A, Sunderland D, Livingstone S, *et al.* A review of pellet-clad interaction behavior in zirconium alloy fuel cladding [M] // Sereni J G R. Reference module in materials science and materials engineering. Amsterdam: Elsevier, 2017: 1-68.
- [3] Lin X L. A scheme for establishing of criterions for reactor safe operation in condition of fuel clad failure

- [J]. Nuclear Power Engineering, 2013, 34(2): 126-128.
林晓玲. 建立反应堆燃料元件破损运行判据的思考[J]. 核动力工程, 2013, 34(2): 126-128.
- [4] Wei G H, Chen D F, Han S B, *et al.* Study on quantitative non-destructive test method for nuclear fuel rods by three dimensions neutron images [J]. Nuclear Power Engineering, 2017, 38(S1): 71-73.
魏国海, 陈东风, 韩松柏, 等. 核燃料元件三维中子成像定量无损检测方法研究[J]. 核动力工程, 2017, 38(S1): 71-73.
- [5] Tu X J. DR/CT testing system development for spherical fuel elements used in high temperature gas-cooled reactor [D]. Beijing: Beihang University, 2013: 32-49.
涂修佳. 高温气冷堆球形燃料元件质量 DR/CT 检测与系统开发[D]. 北京: 北京航空航天大学, 2013: 32-49.
- [6] de Oliveira A F, de Abreu Mól A C, Lapa C M F, *et al.* Automatic defect identification on PWR nuclear power station fuel pellets [J]. Nuclear Engineering and Design, 2012, 245: 62-77.
- [7] Li H X, Zhang B, Liu D, *et al.* Surface crack detection algorithm based on double threshold and tensor voting[J]. Laser & Optoelectronics Progress, 2018, 55(5): 051010.
李慧娟, 张斌, 刘丹, 等. 基于双重阈值和张量投票的表面裂纹检测算法[J]. 激光与光电子学进展, 2018, 55(5): 051010.
- [8] Chen F C, Jahanshahi M R, Wu R T, *et al.* A texture-based video processing methodology using Bayesian data fusion for autonomous crack detection on metallic surfaces [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(4): 271-287.
- [9] Sha A M, Tong Z, Gao J. Recognition and measurement of pavement disasters based on convolutional neural networks [J]. China Journal of Highway and Transport, 2018, 31(1): 1-10.
沙爱民, 童峥, 高杰. 基于卷积神经网络的路表病害识别与测量[J]. 中国公路学报, 2018, 31(1): 1-10.
- [10] Li Q R. A method of line feature extraction based on Beamlet transform [J]. Journal of Projectiles, Rockets, Missiles and Guidance, 2009, 29(3): 96-98.
李庆嵘. 一种基于 Beamlet 变换的线特征提取方法[J]. 火箭与制导学报, 2009, 29(3): 96-98.
- [11] Zhang L, Yang F, Daniel Zhang Y M, *et al.* Road crack detection using deep convolutional neural network[C]//2016 IEEE International Conference on Image Processing (ICIP), September 25-28, 2016, Phoenix, AZ, USA. New York: IEEE, 2016: 3708-3712.
- [12] Sutskever I, Hinton G, Krizhevsky A, *et al.* Dropout: a simple way to prevent neural networks from overfitting [J]. Journal of Machine Learning Research, 2014, 15: 1929-1958.
- [13] Qu L, Wang K R, Chen L L, *et al.* Fast road detection based on RGBD images and convolutional neural network [J]. Acta Optica Sinica, 2017, 37(10): 1010003.
曲磊, 王康如, 陈利利, 等. 基于 RGBD 图像和卷积神经网络的快速道路检测[J]. 光学学报, 2017, 37(10): 1010003.
- [14] Cha Y J, Choi W, Büyüköztürk O. Deep learning-based crack damage detection using convolutional neural networks [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [15] Wang M, Liu K X, Liu L, *et al.* Super-resolution reconstruction of image based on optimized convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(11): 111005.
王民, 刘可心, 刘利, 等. 基于优化卷积神经网络的图像超分辨率重建[J]. 激光与光电子学进展, 2017, 54(11): 111005.
- [16] Donoho D L, Huo X M. Beamlets and multiscale image analysis[M]//Barth T J, Chan T, Haimes R. Multiscale and multiresolution methods. Lecture notes in computational science and engineering. Berlin, Heidelberg: Springer, 2002, 20: 149-196.
- [17] Donoho D, Huo X M. Applications of beamlets to detection and extraction of lines, curves and objects in very noisy images [C] // Proceedings of Nonlinear Signal and Image Processing(NSIP), Baltimore. [S. l. : s. n.], 2001.
- [18] Xu W, Tang Z M, Lü J Y. Pavement crack detection based on image saliency [J]. Journal of Image and Graphics, 2013, 18(1): 69-77.
徐威, 唐振民, 吕建勇. 基于图像显著性的路面裂缝检测[J]. 中国图象图形学报, 2013, 18(1): 69-77.