

DOI: 10.19650/j.cnki.cjsi.J2209872

基于主动小样本学习的管道焊缝缺陷检测方法^{*}

刘金海¹, 赵 真¹, 付明芮², 左逢源¹, 王 雷¹

(1. 东北大学信息科学与工程学院 沈阳 110004; 2. 沈阳派得林科技有限责任公司 沈阳 110000)

摘 要: 基于 X 射线探伤的焊缝缺陷检测是维护管道安全的关键环节, 实现高精度、高效率的缺陷智能检测是推动无损检测智能化、现代化的重要方面。目前, 基于深度学习的缺陷检测方法很难达到较高的精度和效率, 因其需要大量标注样本且难以获取。针对这一问题, 提出了一种基于主动小样本学习的管道焊缝缺陷检测方法。首先, 基于轻量级神经网络提取小样本特征, 以数据驱动的方式训练缺陷检测器; 然后, 推理无标签样本计算检测及分类不确定度并充分挖掘价值样本; 最后, 根据高价值样本微调网络参数, 以最小的成本获得较高的性能提升。实验结果表明, 方法能够利用更少的样本, 在保证运行效率的前提下, 提高约 8% 的精度。

关键词: X 射线检测; 深度学习; 主动小样本学习; 价值样本挖掘

中图分类号: TE88 TP277 TH878⁺3 **文献标识码:** A **国家标准学科分类代码:** 440.55

Active small sample learning based the pipe weld defect detection method

Liu Jinhai¹, Zhao Zhen¹, Fu Mingrui², Zuo Fengyuan¹, Wang Lei¹

(1. School of Information Science and Engineering, Northeastern University, Shenyang 110004, China;

2. Shenyang Paidelin Technology Company, Shenyang 110000, China)

Abstract: The detection of weld defects based on the X-ray flaw detection is a key part of maintaining pipeline safety. The realization of high-precision and high-efficiency intelligent defect detection is an important aspect to promote the intelligence and modernization of nondestructive testing. At present, it is difficult to achieve high accuracy and efficiency with deep learning-based defect detection methods because they require a large number of labeled samples and are difficult to obtain. To address this problem, this article proposes an active small sample learning-based defect detection method for pipe welds. First, the defect detector is trained in a data-driven manner by extracting small sample features based on a lightweight neural network. Then, the inference of the unlabeled samples is used to calculate the detection and classification uncertainty, which could fully exploit the value samples. Finally, the network parameters are fine-tuned according to the high-value samples to obtain a high performance improvement with minimal cost. Experimental results show that the proposed method can improve the accuracy by about 8% with fewer samples and the guaranteed operational efficiency.

Keywords: X-ray testing; deep learning; active small sample learning; value sample mining

0 引 言

目前石化工业正在飞速发展, 长输管道以其高效率、低成本的优点被广泛使用^[1]。然而管道故障时有发生, 油气泄露会给国家带来巨大损失。因此管道异常检测成为了重要研究课题, 其中焊缝质量评估是管道维护中的关键一环^[2-3]。

焊缝处的缺陷会严重危害管道的安全。由于人工缺陷检测存在低效性和主观性, 近年来基于 X 射线的自动缺陷检测方法越来越受研究人员的重视^[4]。实现方案主要包含以图像处理为主的传统算法以及深度学习算法^[5]。传统方法处理流程繁琐且精度较低, 因此近些年大部分研究转向了深度学习领域^[6]。

深度网络以其强大的特征提取能力获得了研究人员的充分认可, 并在工业领域得到了广泛的应用^[7-9]。文

收稿日期: 2022-05-29 Received Date: 2022-05-29

^{*} 基金项目: 国家自然科学基金(U21A20481, 61973071)、辽宁省兴辽英才项目(XLYC2002046)资助

献[10]设计了一种基于贝叶斯网络的缺陷分割方法,采用了改进的 Xception 网络设计了多尺度金字塔框架,利用大量样本获得了较高的精度。文献[11]引入注意力机制,强化感兴趣区域的特征,提高了卷积网络的精度。为了提取更丰富的缺陷语义特征,文献[12]设计了基于卷积神经网络(convolutional neural network, CNN)的缺陷检测模型。文献[13]提出将 Faster RCNN、Cascade RCNN、YOLOv3 三模型融合的多模型融合机制,提高了缺陷检测的召回率。

尽管深度学习技术在各项具有挑战性的任务中取得了突破,但是深度网络目前仍是一个黑箱。如果模型要学习到待检测目标的高质量特征,需要海量的数据供给网络训练来优化大量的参数^[14-15]。然而,在焊缝缺陷检测任务中,缺陷样本数量较少,且对标注人员的知识储备要求较高,因此获得大量缺陷样本非常困难。本文提出的基于主动小样本学习的缺陷智能检测方法,能够缓解这一困难。相关研究表明,主动学习可以将专家经验引入检测算法来指导模型快速进步而不仅仅是网络本身在数据驱动下自行学习^[16-17]。

目前,主动学习在医学、遥感图像领域获得了广泛应用。为了充分挖掘高价值样本,文献[18]提出了一种混合主动学习框架,利用了神经网络的优势提取特征,然后通过挖掘多样性和差异性价值样本取得良好的效果。为了充分利用大量的无标记数据,文献[19]基于差异性选择策略提出了对抗主动学习去解决标记集与未知样本间的特征不一致问题。文献[20]基于对数似然估计考虑了3种不确定采样策略增加了样本选择的多样性,提升

了所选样本的信息量。文献[21]在主动学习基础之上引入多实例学习在减少专家标记量的同时为标注提供更有可靠的区域。

尽管主动学习已经取得了长足的进步,但是上述主动学习方法大多针对分类任务而设计,考虑到分类与检测的差异性,以上方法并不适用于缺陷检测任务。同时,实际管道的形貌和织构特征较为复杂,如焊接处存在余高,将导致焊缝厚度变大,X射线的透射程度降低,从而导致底片上焊缝处亮度变高,缺陷检测任务更加复杂。本文提出的复杂焊缝缺陷的主动小样本学习框架,能够解决上述问题,并且在实际应用中具有重要意义。

本文提出了一种基于主动小样本学习的管道焊缝缺陷检测方法。该方法能够在小样本下稳定、准确、快速地完成缺陷检测任务。本文提出了一种基于轻量全卷积神经网络,适用于小样本缺陷检测任务的缺陷检测器,为主动小样本学习提供了良好的基线模型。本文设计了一种适用于缺陷检测的不确定性采样策略,该策略同时考虑检测任务中的多元分类和位置回归的不确定性,保证筛选样本具备高价值信息。

1 方法概述

本文方法总体检测过程如图1所示,主要包含深度学习和主动学习两个主要过程。其中,主动学习包含5个要素,分别为少量的初始标签样本 $\{X_L^0, Y_L^0\}$ 、大量无标记样本池 X_U^0 、检测模型 M 、采样策略 S 和领域人员 Q 。




图1 主动学习检测方法框架

Fig. 1 Active learning detection method framework

在深度学习阶段,首先利用少量标记数据集 $\{X_L^0, Y_L^0\}$ 进行图像增强和增广,从而提高缺陷的对比度和模型的泛化能力。然后采用扩充后的样本集 $\{X_L^0, Y_L^0\}_{DA}$ 基于轻量神经网络训练具备缺陷分类与定位能力的初级检测器 M_0 。

在主动学习阶段,首先将无标记集 X_U^0 中的图像分批送入 M_0 获得缺陷检测信息。通过计算检测与分类不确定性设计采样策略 S ,进而选取 X_S^0 数量的价值样本。

接着经过领域人员标签查询后与初始训练集 X_L^0 合并形成新的训练集 X_L^1 , 其中 $X_L^1 = X_L^0 \cup X_S^0$ 。最后基于 X_L^1 对初级检测器 M_0 微调获得新的模型 M_1 。重复上述的过程将获得高性能模型缺陷检测模型 M 。

2 基于轻量全卷积网络的缺陷检测器设计

传统卷积网络的深度模型量级大,其庞大的参数量将对网络训练、推理的速度造成影响。因此,在保证网络精度的前提下,为提升网络速度,设计了适用于缺陷检测任务的轻量检测器。考虑到 X 射线具有低对比度特点,本文提出了基于改进浮雕算子的缺陷增强算法从而提升轻量网络的特征提取能力。

2.1 基于改进浮雕算子的缺陷特征增强算法

受实际管道形貌、织构特征以及焊缝余高的影响,工业射线底片存在噪声和低对比度的特点。本文改进的浮雕算法能够有效地减弱该问题的影响。为减弱噪声,使网络提取更优秀的特征,传统浮雕算法^[22]在滤波后图像上逐像素进行浮雕转换,如式(1)所示。

$$P'(i,j) = P(i-1,j-1) - P(i+1,j+1) + TH \tag{1}$$

式中: $P'(i,j)$ 表示优化后第 i 行 j 列的像素值; TH 通常选取为 128。在传统浮雕中,各像素点无论灰度大小,均得到相同的变换,并且缺陷特征区域的变换值较大。为突出这一特点,本文改进浮雕算子如下。

1) 原图为灰度矩阵 $P(i,j)$, i,j 表示原图有 i 行 j 列。对原图做平移填零处理,可得派生滤波矩阵 $\tilde{P}$ 如下:

$$\tilde{P}(i,j) = \begin{pmatrix} 0 & 0 \\ 0 & P(i',j') \end{pmatrix} \tag{2}$$

式中: $i' = i - 4, j' = j - 4$ 。保证派生滤波矩阵 $\tilde{P}$ 与灰度矩阵 P 维数相同的情况下,其余位置补零。

2) 在灰度矩阵上使用派生滤波矩阵滤波,并加上背景常数作灰度放缩处理,如式(3)所示。

$$P'(i,j) = [(P(i,j) - \tilde{P}(i,j)) + k_{bg}] \times k \tag{3}$$

式中: k_{bg} 为背景常数; k 为放缩倍数。最终将超过位图上下界的像素点映射为最大值与最小值,得到改进浮雕算法增强的图像,如图 2 所示。通过设定放缩倍数,缺陷特征得到增强,其灰度分布接近于正态分布。

由图 2(a)、(c) 可知,经本文改进浮雕算法处理后,缺陷边缘、纹理等特征得到明显的增强。由图 2(b)、(d) 可知,浮雕算法能够将原始图像灰度的不规则分布转换为正态分布,从而抑制噪声,减弱管道形貌、织构特征、焊缝余高和其他工况对缺陷检测任务所造成的影响。

为保证初级检测器的性能,在数据量有限的情况下,本文还通过数据增广来增加不同长度、广度和尺度的训练样本,提高卷积网络的泛化能力。




图 2 改进浮雕算法处理缺陷与原缺陷的对比
Fig. 2 Relief-enhanced defect vs. original defect

2.2 轻量全卷积网络

在神经网络的训练过程中,模型的运行效率至关重要。因此,本文基于 Darknet53 轻量全卷积网络^[23],构造了包含缺陷实例分类器 f_c 和边框位置回归器 f_r 的焊缝缺陷检测器,经小样本数据驱动训练后,用于估计无标记数据集中图像的不确定性。

为构造小样本下的缺陷检测模型,本文以迁移学习的方式,赋予主干网络 MSCOCO 数据集下的预训练参数,数据驱动训练轻量缺陷检测器。其中 G 表示加载预训练参数的特征提取器, θ_g 表示特征提取器参数,检测器所包含的分类器 f_c 和回归器 f_r 参数分别为 θ_c 和 θ_r 。记 $\Theta = \{\theta_g, \theta_c, \theta_r\}$ 表示检测器全部参数。本文所设计的轻量网络结构 G 如表 1 所示。其中, $\text{Conv}_{(3,2,1)}$ 表示卷积核大小为 3、卷积步长为 2、填充为 1 的卷积运算层, Res_u 为残差单元。

表 1 轻量网络结构
Table 1 Lightweight network architecture

Darknet 模组	卷积核大小	特征图尺寸
1	$\text{Conv}_{(3,2,1)} + 1 \times \text{Res}_u$	(320,320,32)
2	$\text{Conv}_{(3,2,1)} + 2 \times \text{Res}_u$	(160,160,64)
3	$\text{Conv}_{(3,2,1)} + 8 \times \text{Res}_u$	(80,80,128)
4	$\text{Conv}_{(3,2,1)} + 8 \times \text{Res}_u$	(40,40,256)
5	$\text{Conv}_{(3,2,1)} + 4 \times \text{Res}_u$	(20,20,512)

2.3 深度监督

为了更好的更新轻量网络的参数,加速网络收敛,本文提出如下深度监督方法。

对于给定训练集 $\{X_L, Y_L\}$, 任意图像 x_i 中的缺陷实例集可以表示为 $\{x_i^k, k = 1, \dots, n\}$, 每张图像的实例标签记作 $\{y_i^k, k = 1, \dots, n\}$ 。在检测器的训练过程中,将训练集分批次送入网络得到推理集 $\{\hat{y}_i^k, k = 1, \dots, m\}$, 和损失

L_0 。损失 L 包括两部分,分别是分类损失与回归损失:

$$L = \sum_i FL(\{y_i^k\}, \{\hat{y}_i^k\}) + CIoU(\{y_i^k\}, \{\hat{y}_i^k\}) \quad (4)$$

式中: $FL(\cdot)$ 为 Focal 分类损失函数; $CIoU(\cdot)$ 为边界框回归损失函数。根据计算得到的损失,优化器 $SGD(\cdot)$ 在迭代过程中将对网络全局参数 Θ 进行优化,直至损失函数最小,如式(5)所示。

$$\tilde{\Theta} = \min[SGD(\Theta, L)] \quad (5)$$

当损失值收敛时停止训练过程,可获得具备推理未知图像的缺陷分类和定位信息的检测器 M 。

3 基于不确定采样策略的主动小样本缺陷检测算法设计

深度学习模型旨在通过大数据驱动方式实现高精度的缺陷检测。然而,在焊缝缺陷检测任务中,很难获得大量的有标记样本。因此,本文设计了一种不确定性采样策略,并基于此设计主动小样本缺陷检测算法。

3.1 价值缺陷样本分析

在主动学习任务中,衡量样本的价值是最为关键的一步,样本的选择策略将直接影响最终模型的性能。两类高价值样本分析如图 3 所示。其中,图 3(a)表示分类价值样本,预测时出现类别混淆。图 3(b)表示检测价值样本,预测时类别置信度较低。




图 3 高价值样本分析

Fig. 3 High value sample analysis

在多类别检测任务中,分类性能至关重要,当检测器 M_0 对未知缺陷图像 x_i 不确定时,将会在缺陷位置输出两个重叠度较高的不同类别的检测框,如式(6)所示。

$$IoU_{box_1, box_2} = \frac{S_{box_1} \cap S_{box_2}}{S_{box_1} \cup S_{box_2}} > 0.5 \mid cls_{box_1} \neq cls_{box_2} \quad (6)$$

式中: IoU_{box_1, box_2} 反映了两个检测框的重叠度,分属不同类别。对于图 3(a)中类别 2 和类别 3 均为线性状缺陷,这时根据检测框的 IoU 做非极大值抑制是不合适的,因为 0.03 的分类置信度的差距会抑制掉正确的预测。同时,缺陷检测框的置信度代表着检测模型的检测性能以及检测结果的可信程度,如图 3(b)所示,其分类正确但置信度得分较低,说明检测框中的物体不一定是该类别。因此,以上两种样本均为高价值样本。

3.2 基于不确定采样策略的价值样本挖掘

通过上述分析的缺陷价值样本类型,提出一种适用于缺陷检测任务的样本不确定度计算规则。为逐步提升模型的性能,采取小批量探测的原则从无标记样本池中将样本分批送入检测器。对于无标记池 X_U 中的一个批次样本 X_U^{batch} ,当缺陷图像 $x_i \in X_U^{batch}$ 经过初级检测器后,输出分类概率 $P_{x_i}^{cls}$ 与位置概率 $P_{x_i}^{obj}$,其中当前缺陷图像概率分布由网络模型 M 中分类器 f_c 得到:

$$P_{x_i}^{cls} = M_{f_c}^{cls}(g(x_i)) \quad (7)$$

$$P_{x_i}^{obj} = M_{f_c}^{obj}(g(x_i))$$

式中: $P_{x_i}^{cls}$ 与 $P_{x_i}^{obj}$ 分别为 n 维向量, n 为检测框个数。检测框由网络模型 M 中回归器 f_r 得到:

$$B_{x_i}^{reg} = \{box_j\} = M_{f_r}^{reg}(g(x_i))$$

$$j = 0, 1, \dots, n; \quad (8)$$

根据式(7)、(8)可得,第 k 检测框 box_k 的置信度 $P_{x_i}^{conf \mid box_k}$ 可描述为:

$$P_{x_i}^{conf \mid box_k} = P_{x_i}^{cls \mid box_k} \cdot P_{x_i}^{obj \mid box_k} \quad (9)$$

式中: $P_{x_i}^{cls \mid box_k}$ 与 $P_{x_i}^{obj \mid box_k}$ 分别代表检测框 box_k 输出类别为 cls 的最大分类概率与检测概率。最大输出类别概率 $P_{x_i}^{cls \mid box_k}$,满足式(10)。

$$P_{x_i}^{cls \mid box_k} = \max(P_{x_i}^{cls_1 \mid box_k}, P_{x_i}^{cls_2 \mid box_k}, P_{x_i}^{cls_3 \mid box_k} \dots) \quad (10)$$

针对图 3 分析的易混淆缺陷样本设计了不确定度计算规则如下:

$$s_1 = \begin{cases} \frac{1}{\sum_{k,l} \argmin(|P_{x_i}^{conf \mid box_k} - P_{x_i}^{conf \mid box_l}|)}, & IoU_{box_k, box_l} > IoU_{thre} \\ 0, & IoU_{box_k, box_l} \leq IoU_{thre} \end{cases} \quad (11)$$

式中: IoU_{box_k, box_l} 代表 box_k 与 box_l 的重叠度,同时有 $cls_{box_k} \neq cls_{box_l}$; n 表示每张图像中检测到的缺陷实例数量; IoU_{thre} 为两检测框的重叠度阈值,本文选取 $IoU_{thre} = 0.5$ 。

在模型推理时,针对置信度 $P_{x_i}^{conf}$ 较低情形所设计的不确定度为:

$$s_2 = \frac{1}{\sum_{k=1}^n \argmin(P_{x_i}^{conf \mid box_k})} \quad (12)$$

则待查询样本最终的不确定度得分可表示为: $score = s_1 + s_2$,通过对批样本 X_U^{batch} 进行不确定度得分降序排序,即可确定前 k 个价值样本 X_s^k 和标签 Y_s^k 。

3.3 主动小样本缺陷检测算法

主动小样本学习缺陷检测的算法伪代码如下。

算法：焊缝缺陷检测主动学习算法

输入：训练集 $\{X_L, Y_L\}$ ，无标记池 X_U ，每次迭代批次 X_U^{rbatch}

查询样本 X_s ，主干网络预训练参数 θ_g

输出：高性能检测模型 M

1: **Initialize**

2: $\{X_L, Y_L\}_{DA} \leftarrow \{X_L, Y_L\}$ //优化并扩充训练样本

3: $M_r \leftarrow \text{train}(\Theta, \{X_L, Y_L\}_{DA})$ //训练检测模型

4: $r = 1$ //初始化迭代次数

5: **repeat**

6: **for** $x_i \in X_U^{rbatch}$ **do**

7: $P_{x_i}^{cls}, P_{x_i}^{obj} = M_{f_c}(x_i)$ //计算当前样本概率分布

8: $score = s_1 + s_2$ //计算当前不确定度

9: **end for**

10: $X_{sort} \leftarrow \text{sort}(X_U^{rbatch}, \{scores\}_{in})$ //递减排序

11: $X_s \leftarrow X_{sort} \{i = 1, \dots, top_k\}$ //选择 k 个价值样本

12: $Y_s \leftarrow \text{query}\{X_s\}$ //价值样本标签查询

13: $\{X_L, Y_L\}^r \leftarrow \{X_L, Y_L\} \cup \{X_s, Y_s\}$ //更新训练集

14: $M_{r+1} \leftarrow \text{train}(\theta_{e,r}, \{X_L, Y_L\}_{DA}^r) \mid \text{freeze}(M_r(\theta_g))$

15: $X_U \leftarrow X_U - X_U^{rbatch}$ //清除当前批次样本

16: $r \leftarrow r + 1$ //执行下一次迭代

17: **Until** 检测性能满足要求



图 4 管道焊接数据现场采集过程

Fig. 4 Pipe weld data collection on site




图 5 X 射线图像缺陷样例

Fig. 5 Examples of X-ray image defects

学习率 $\alpha = 0.04$ ，动量参数 0.96，权值衰减设置为 3.6×10^{-4} ，训练批次设置为 200。主动学习迭代次数 r 为 4 次，每次查询 $k = 20$ 个价值样本。

本文选取缺陷的类别分别为圆形缺陷(类别 1)、条形缺陷(类别 2)和未熔合(类别 3)。在实际的管道中，缺陷类别众多且易混淆。本文选取的 3 类缺陷较为常见，且易于采集样本。圆形缺陷的影像特征体现为圆点、斑点状区域，在浮雕图上黑白斑点变化明显。条形与未熔合轮廓特征较为相似，均为细长条状，易发生混淆；但两类缺陷在管道上的位置信息不同、粗细也不同，因此本文网络能够区分两类缺陷。

本文深度学习的环境配置如下：GPU 为 NVIDIA RTX 3090，深度学习框架为 Pytorch 1.7.1+CUDA11.3，RAM 为 64 GB。本文使用的数据集如表 2 所示。

表 2 焊缝缺陷训练集
Table 2 Weld defect dataset

缺陷类别	类别 1	类别 2	类别 3	整体
泛化前训练集	158	167	142	467
泛化后训练集	540	535	660	1 735
测试集	100	75	80	255

3) 模型评价指标

为验证本文方法的可行性，采用的具体评价指标包括准确率 P 和召回率 R ：

$$P = \frac{TP}{TP + FP}$$
$$R = \frac{TP}{TP + FN}$$

(13)

除此之外，在目标检测中 $P - R$ 曲线的面积精度值

4 实验与分析

实验对本文所提方法进行有效性验证，包括优化训练样本对初级检测器性能验证以及本文所提不确定采样策略的验证，并与其他先进的缺陷检测方法进行综合性能对比。

4.1 实验设置

1) 数据获取

管道焊接缺陷图像由工业底片扫描仪扫描 X 射线胶片获得。本文实验采用中国北部地区管道焊缝原始数据，管道焊接工艺为手工焊，管径 1 219 mm，壁厚 18.4 mm。使用工业 X 射线探伤仪的数据收集过程如图 4 所示。无损检测人员使用 X 射线探伤机探测管道焊缝，并在胶片上成像。通过扫描仪将胶片扫描为数字化图像后，即可获得焊缝缺陷图像如图 5 所示。

2) 参数设置与环境配置

实验参数设置如下：批大小(batch size)设置为 64，

(average precision, AP) 通常用于反映检测结果的质量, AP 值越大,模型的检测能力越好。

4.2 有效性验证

对本文方法作有效性验证,首先验证图像增强和增广对缺陷检测器性能的影响,然后验证不同采样策略下,主动小样本学习网络性能的提升效果。

1) 图像增强与增广有效性验证

为验证增强训练样本前后对模型检测性能的影响,分别按照以下方式获得 3 种缺陷检测器。

模型 1,训练原始灰度图所得模型。

模型 2,训练增强图像所得模型。

模型 3(本文采用模型),训练图像增强与增广后的训练集所得模型。在测试集上得到如下检测结果,其中整体缺陷检测的 $P-R$ 曲线如图 6 所示。




图 6 不同数据处理方法的 $P-R$ 曲线对比

Fig. 6 $P-R$ curve comparison of different data processing methods

由图 6 可以看出,直接采用 X 射线图像训练模型仅能获得 0.726 的精度,仅使用图像增强方法能够将精度提高到 0.768。使用图像增强与增广相结合的方法,可获得性能最高的缺陷检测器,其精度达 0.801。

取置信度阈值为 0.2,3 种模型的全部类别的检测结果如表 3 所示。该结果表明,模型 3 的 AP 对各类缺陷均有提升,其中小样本下的缺陷(类别 1)提升效果显著,证明本文采用图像增强增广方法能适应小样本数据,增强缺陷特征,从而提升缺陷检测精度。

表 3 不同数据处理方法 AP 对比

数据集	类别 1	类别 2	类别 3	整体
模型 1	0.636	0.815	0.728	0.726
模型 2	0.704	0.820	0.779	0.768
模型 3	0.800	0.821	0.781	0.801

2) 不确定采样策略的有效性验证

为证明本文不确定采样策略的有效性,与随机采样策略(random sample, RS)和文献[24]的基于熵值不确定性进行对比验证,得到精度对比如图 7 所示。通过观察可以发现,随着迭代次数的增加,本文所提采样策略对模型性能的提升明显高于其他采样方式,当迭代停止时,可以获得最高的整体缺陷检测精度($AP=0.897$)分别比其他采样方式高出 4.3%,3.2%。




图 7 3 种方法的 AP 对比

Fig. 7 AP comparison of the three methods

同时,为进一步说明采样策略对模型识别不同类别缺陷的影响,本文实验得到结果如表 4 所示。

表 4 不同采样方法下的性能对比

Table 4 Performance comparison under different sampling methods

指标	采样策略	类别 1	类别 2	类别 3	整体
P	RS	0.742	0.837	0.888	0.822
	文献[24]	0.951	0.909	0.935	0.932
	本文	0.957	0.979	0.938	0.958
R	RS	0.796	0.903	0.810	0.837
	文献[24]	0.852	0.892	0.805	0.850
	本文	0.883	0.905	0.813	0.867
AP	RS	0.803	0.888	0.872	0.854
	文献[24]	0.874	0.899	0.834	0.865
	本文	0.905	0.929	0.855	0.897

结果表明,针对类别 1 的缺陷,本文所提采样策略在召回率上明显高于其他方法(较随机采样方法提升了 10%,较文献[24]提升了 3%),而针对易混淆的缺陷类别 2 和 3 本文所提采样策略也提升了模型准确率。从整体上看,AP 值相比于随机采样提升了 4.3%,较文献[24]提升了 3.2%,证明本文的不确定性采样策略是有效的。

4.3 与现有方法的对比实验

将本文所提基于主动小样本学习的缺陷智能检测方法
与文献[25-26]中所述的其他先进缺陷智能检测方法
进行性能对比。为保证实验的科学严谨性,其他方法均
使用本文所提优化训练样本建立模型。为了验证本文方
法在不同样本集下的性能,分别基于全部数据集的 25%、
50%、75%、100% 作为训练集与其他方法进行对比(其他
方法均采用全部训练样本)。每种算法的超参数设置均
按照相应文献所述进行配置,得到检测结果如表 5 所示。

表 5 不同方法的性能对比

Table 5 Performance comparison of different methods					
指标	检测方法	类别 1	类别 2	类别 3	整体
P	文献[25]	0.802	0.856	0.789	0.817
	文献[26]	0.857	0.847	0.809	0.845
	25% 标签	0.772	0.911	0.856	0.846
	50% 标签	0.941	0.909	0.880	0.910
	75% 标签	0.952	0.963	0.934	0.950
	100% 标签	0.957	0.979	0.938	0.958
R	文献[25]	0.845	0.844	0.822	0.837
	文献[26]	0.850	0.849	0.831	0.843
	25% 标签	0.768	0.710	0.609	0.696
	50% 标签	0.767	0.851	0.777	0.799
	75% 标签	0.868	0.906	0.820	0.865
	100% 标签	0.883	0.905	0.813	0.867
AP	文献[25]	0.794	0.855	0.770	0.806
	文献[26]	0.831	0.829	0.818	0.826
	25% 标签	0.744	0.706	0.575	0.675
	50% 标签	0.773	0.856	0.766	0.798
	75% 标签	0.889	0.921	0.854	0.886
	100% 标签	0.905	0.929	0.855	0.897

由表 5 可知,使用不同比例的训练样本,即主动学习
程度不同,对模型推理结果具有一定影响。仅使用 25%
标签作为初始训练样本时,精度仅为 0.675。当使用全
部训练样本时精度能够达到 0.897。对比文献[25-26]
方法,本文使用 25% 与 50% 初始数据集所得最终模型没
有使用 75% 和 100% 标签的 AP 高,但本文所提价值样本
采集是有效的,相较于目前最好的其他深度学习方法,本
文所提的基于主动小样本学习的方法获得更高的准确
率。从整体上看,本文所提的主动小样本学习方法,使用
50% 标签时可以获得近似其他先进方法的 AP 值。这主
要体现在准确率提升较大,检出率略有回退。当使用
75% 标签时可以获得更全面的精度提升,AP 值分别高于
文献[25] 所述 8% 和文献[26] 所述 6%。

为了进一步体现本文方法在缺陷混淆程度方面的检
测性能,按照分类的评价指标混淆矩阵将本文基于 75%
训练集建立模型与其他两种缺陷检测方法对比缺陷分类
方面的性能,得到混淆矩阵如图 8 所示。其中,图 8(a)
表示文献[25] 检测结果;图 8(b) 表示文献[26] 检测结
果;图 8(c) 为本文方法检测结果。图 8 的混淆矩阵说明
不同方法在缺陷分类方面的性能,具体反映了缺陷与背景
之间,缺陷与缺陷之间的混淆情况。通过对比图 8(a) ~
(c) 发现,图 8(a)、(b) 在类别 2 与类别 3 上的检测混淆
程度大于图 8(c),而本文方法无论是缺陷之间的混淆,
还是缺陷与背景之间的精度,均高于其他两种方法。

本文进一步对 3 种方法在测试集上的推理结果进行
可视化,如图 9 所示。其中,图 9(a) 和 (b) 分别表示
文献[25-26] 的实验结果,图 9(c) 为本文所提方法的试
验结果。试验结果表明,本文方法最终可以有效的识别
类型 1 的缺陷,其检出率较高。而其余两种方法均有漏
检情况发生。对于易混淆缺陷,本文方法检测置信度较
高,已具备区分二者的能力,而文献[25-26] 的方法,其置
信度较低,仍然无法对易混淆缺陷进行精准的识别。




图 8 不同方法混淆矩阵对比

Fig. 8 Confusion matrix comparison of different methods




图 9 可视化检测结果
Fig. 9 Visualize the test results

表 6 运行效率对比

Table 6 Operational efficiency comparison			
方法	本文	文献[25]	文献[26]
推理时间/s	0.021	0.130	0.174
模型大小/M	15.2	330.4	547.9

本文最后对比了所有方法的运行效率,如表 6 所示。在推理时间上,本文方法的推理时间用时更少。这是因为本文所使用模型轻量化,模型大小仅 15.2 M。这证明了本文方法的快速性,并且能够满足实际工程项目的快速运行的需要。

综上所述,实验结果表明,本文方法在进行多次主动学习迭代之后可以获得更高的检测精度,同时模型轻量化易于部署和实时推理。

5 结 论

在管道焊缝缺陷的无损检测领域中,由于实际管道的形貌和织构特征较为复杂,标注样本人员需要具备较强的专业知识,因此无法获取大量的有标签样本,导致深度学习模型检测精度较差。针对上述问题,并考虑检测任务与分类任务的差异,本文提出基于主动小样本学习的缺陷检测方法。通过使用增强和增广后的 X 射线缺陷图像训练缺陷轻量检测器。依据检测器推理无标记样本时获得的概率分布,设计了一种针对焊缝缺陷的不确定采样策略,有效地收集置信度较低类别以及易混淆类别的有价值样本。最后实验与分

析部分,将本文所提方法的性能与传统基于深度学习的检测算法进行对比实验。实验结果表明,与完备训练的深度网络相比,本文所提基于主动小样本学习的缺陷检测方法获得了更高的精度。

参考文献

[1] LIU J H, REN Y F. A general transfer framework based on industrial process fault diagnosis under small samples[J]. IEEE Transactions on Industrial Informatics, 2021, 17(9): 6073-6083.

[2] 宋寿鹏, 乔梦丽. 基于 NLFM Barker 编码的板材焊缝缺陷超声检测方法研究[J]. 仪器仪表学报, 2020, 41(4): 246-254.

SONG SH P, QIAO M L. Research on ultrasonic detection method of plate weld defects based on NLFM Barker coding [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 246-254.

[3] 刘金海, 赵贺, 神祥凯, 等. 基于漏磁内检测的自监督缺陷检测方法[J]. 仪器仪表学报, 2020, 41(9): 180-187.

LIU J H, ZHAO H, SHEN X K, et al. A self-supervised defect detection method based on magnetic flux leakage internal detection [J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 180-187.

[4] BOARETTO N, CENTENO T M. Automated detection of welding defects in pipelines from radiographic images dwdi[J]. NDT & E International, 2017, 86: 7-13.

- [5] HOU W H, WEU Y, JIN Y. Deep features based on a DCNN model for classifying imbalanced weld flaw types[J]. Measurement, 2019, 131: 482-489.
- [6] LIAN J, JIA W, ZAREAPOOR M, et al. Deep-learning-based small surface defect detection via an exaggerated local variation-based generative adversarial network[J]. IEEE Transactions on Industrial Informatics, 2020, 16(2): 1343-135.
- [7] 胡旭光, 马大中, 郑君, 等. 基于关联信息对抗学习的综合能源系统运行状态分析方法[J]. 自动化学报, 2020, 46(9): 1783-1797.
- HU X G, MA D ZH, ZHENG J, et al. A method for analyzing the operating state of an integrated energy system based on adversarial learning of associated information[J]. Journal of Automatica, 2020, 46(9): 1783-1797.
- [8] LIU J H, QU F M, HONG X W, et al. A small-sample wind turbine fault detection method with synthetic fault data using generative adversarial nets[J]. IEEE Transactions on Industrial Informatics, 2019, 15(7): 3877-3888.
- [9] 李少波, 杨静, 王铮, 等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
- LI SH B, YANG J, WANG ZH, et al. Review of development and application of defect detection technology[J]. Journal of Automatica, 2020, 46(11): 2319-2336.
- [10] 金侠挺, 王耀南, 张辉, 等. 基于贝叶斯 CNN 和注意力网络的钢轨表面缺陷检测系统[J]. 自动化学报, 2019, 45(12): 2312-2327.
- JIN X T, WANG Y N, ZHANG H, et al. Rail surface defect detection system based on Bayesian CNN and attention network[J]. Journal of Automatica, 2019, 45(12): 2312-2327.
- [11] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
- CHEN R X, ZHAN Z, HU X L, et al. Defect detection of printed circuit boards under noise interference based on multi-attention Faster RCNN[J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 167-174.
- [12] 季玉坤, 高向东, 刘倩雯, 等. 焊接缺陷磁光成像卷积神经网络识别方法[J]. 仪器仪表学报, 2021, 42(2): 107-113.
- JI Y K, GAO X D, LIU Q W, et al. Welding defect magneto-optical imaging convolutional neural network identification method[J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 107-113.
- [13] 杨珂, 方诚, 段黎明. 基于深度学习模型融合的铸件缺陷自动检测[J]. 仪器仪表学报, 2021, 42(11): 150-159.
- YANG K, FANG CH, DUAN L M. Automatic detection of casting defects based on deep learning model fusion[J]. Chinese Journal of Scientific Instrument, 2021, 42(11): 150-159.
- [14] 陶显, 侯伟, 徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报, 2021, 47(5): 1017-1034.
- TAO X, HOU W, XU D. A survey of surface defect detection methods based on deep learning[J]. Journal of Automatica, 2021, 47(5): 1017-1034.
- [15] QU F M, LIU J H, ZHOU H F, et al. A data-driven interpretable method based on reversely-built FIS and its applications in measurement[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [16] BUDD S, ROBINSON E C, KAINZ B. A survey on active learning and human-in-the-loop deep learning for medical image analysis[J]. Medical Image Analysis, 2021, 71: 1361-8415.
- [17] DI W, CRAWFORD M M. Active learning via multi-view and local proximity co-regularization for hyperspectral image classification[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 618-628.
- [18] XING W, CHEN CH, ZHOU M Y, et al. HAL: Hybrid active learning for efficient labeling in medical domain[J]. Neurocomputing, 2021, 456: 563-572.
- [19] YU G, YANG Y W, WANG X Y, et al. Adversarial active learning for the identification of medical concepts and annotation inconsistency[J]. Journal of Biomedical

- Informatics, 2020, 108:103481.
- [20] NATH V, YANG D, LANDMAN B A, et al. Diminishing uncertainty within the training pool: Active learning for medical image segmentation [J]. IEEE Transactions on Medical Imaging, 2020, DOI: 10.1109/TMI.2020.3048055.
- [21] MELENDEZ J, VAN GINNEKEN B, MADUSKAR P, et al. On combining multiple-instance learning and active learning for computer-aided detection of tuberculosis[J]. IEEE Transactions on Medical Imaging, 2016, 35(4): 1013-1024.
- [22] LI Z, WANG S, YU J, et al. Restoration of brick and stone relief from single rubbing images [J]. IEEE Transactions on Visualization and Computer Graphics, 2012, 18(2): 177-187.
- [23] VASAVI S, PRIYADARSHINI N K, HARSHAVARADHAN K. Invariant feature-based darknet architecture for moving object classification[J]. IEEE Sensors Journal, 2021, 21(10):11417-11426.
- [24] WANG K, ZHANG D, LI Y, et al. Cost-effective active learning for deep image classification [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(12): 2591-2600.
- [25] LIU Z, TANG R, DUAN G, et al. Truingdet: Towards high-quality visual automatic defect inspection for mental surface[J]. Optics and Lasers in Engineering, 2021, 138:106423.
- [26] CHENG X, YU J. RetinaNet with difference channel attention and adaptively spatial feature fusion for steel surface defect detection [J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70:1-11.

作者简介



刘金海 (通信作者), 2009 年于东北大学获得博士学位, 现为东北大学教授, 博士生导师, 主要研究方向为工业人工智能, 数据驱动故障诊断理论与技术。

E-mail: jh_lau@126.com

Liu Jinhai (Corresponding author) received his Ph. D. degree from Northeastern University in 2009. He is currently a professor and Ph. D. supervisor at Northeastern University. His main research interests include industrial artificial intelligence, data-driven fault diagnosis theory and technology.



赵真, 2021 年于中国地质大学 (武汉) 获得学士学位, 现为东北大学硕士研究生, 主要研究方向为数据驱动故障诊断理论与技术。

E-mail: 2170903@stu.neu.edu.com

Zhao Zhen received his B. Sc. degree from China University of Geosciences (Wuhan) in 2021. He is currently a M. Sc. candidate at Northeastern University. His main research direction is data-driven fault diagnosis technology.