

# 控制与决策

Control and Decision

## 基于异构扩散模型的输油管道缺陷及组件检测方法

神祥凯, 刘金海

引用本文:

神祥凯, 刘金海. 基于异构扩散模型的输油管道缺陷及组件检测方法[J]. *控制与决策*, 2025, 40(3): 937-945.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0713>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于SAPSO算法的RBF神经网络设计

Design of RBF neural network based on SAPSO algorithm

控制与决策. 2021, 36(9): 2305-2312 <https://doi.org/10.13195/j.kzyjc.2020.0176>

#### 基于稀疏化神经网络的浮选泡沫图像特征选择

Selection method for froth image characters based on sparse neural network

控制与决策. 2021, 36(7): 1627-1636 <https://doi.org/10.13195/j.kzyjc.2019.1788>

#### 基于局部信息增量与MPLS的质量相关故障检测方法

Quality-related fault detection method based on local information increment and MPLS

控制与决策. 2021, 36(7): 1647-1654 <https://doi.org/10.13195/j.kzyjc.2019.1402>

#### 周围神经MicroCT图像中神经束轮廓获取算法的改进

An improved approach to obtain contours of fascicular groups from MicroCT images of peripheral nerve

控制与决策. 2021, 36(7): 1601-1610 <https://doi.org/10.13195/j.kzyjc.2019.1664>

#### 脉冲神经网络研究进展综述

Spiking neural networks A survey on recent advances and new directions

控制与决策. 2021, 36(1): 1-26 <https://doi.org/10.13195/j.kzyjc.2020.1006>

# 基于异构扩散模型的输油管道缺陷及组件检测方法

神祥凯, 刘金海<sup>†</sup>

(东北大学 信息科学与工程学院, 沈阳 110819)

**摘要:** 高精度的缺陷检测和组件检测对确保管道的安全运行至关重要. 针对现有检测方法存在精度低和泛化性差的难题, 提出一种基于异构扩散模型的新型管道缺陷和组件检测方法. 首先, 将原始的漏磁信号预处理以降低信号采集中噪声等负面因素的影响; 其次, 针对特征提取困难的问题, 设计一种基于稀疏注意力模块的特征提取方法, 通过稀疏化的方式建立漏磁信号间的长距离依赖关系, 进而实现模型对缺陷和组件的信息聚焦; 此外, 将传统的特征金字塔网络替换为路径聚合特征金字塔网络, 充分确保多尺度特征的完备性; 最后, 设计一种基于异构扩散模型的检测机制, 将候选框回归过程转换为随机框的去噪过程, 减少模型对预先设定的锚点的依赖, 进而提升模型的泛化性和准确性. 基于实际管道对其有效性进行验证, 实验结果表明, 所提出方法的平均检测精度达到 97.4%, 优于最先进的对比方法 3.5%, 确保了其在应用中的前景.

**关键词:** 漏磁检测; 管道缺陷检测; 管道组件检测; 卷积神经网络; 注意力机制; 扩散模型

中图分类号: TE973; TP391.4 文献标志码: A

DOI: 10.13195/j.kzyjc.2024.0713

引用格式: 神祥凯, 刘金海. 基于异构扩散模型的输油管道缺陷及组件检测方法 [J]. 控制与决策, 2025, 40(3): 937-945.

## Defect and component detection method of oil pipeline based on heterogeneous diffusion model

SHEN Xiang-kai, LIU Jin-hai<sup>†</sup>

(College of Information Science and Engineering, Northeastern University, Shenyang 110819, China)

**Abstract:** High-accurate defect and component detection are essential to ensure the safe operation of pipelines. Aiming at the difficulties of low accuracy and poor generalization of existing detection methods, this paper proposes a novel pipeline defect and component detection method based on a heterogeneous diffusion model. First, the raw magnetic flux leakage (MFL) signal is pre-processed to reduce the influence of negative factors such as noise in the signal acquisition. Second, to address the difficulty of feature extraction, a feature extraction method based on sparse attention module is designed, which establishes the long-distance dependence relationship between the MFL signals through sparsification and then enables the model to focus on the information of defects and components. In addition, the traditional feature pyramid network is replaced by the path aggregation feature pyramid network, which fully ensures the completeness of multi-scale features. Finally, a detection mechanism based on the heterogeneous diffusion model is designed, which converts the candidate frame regression process into a denoising process for random frames, which reduces the model's dependence on a predefined anchor window, and in turn improves the model's generalizability and accuracy. The experimental results show that the average detection accuracy of the proposed method reaches 97.4%, which is better than the state-of-the-art comparative method by 3.5%, which ensures the prospect of its practical application.

**Keywords:** magnetic flux leakage testing; pipeline defect detection; pipeline component detection; convolutional neural network; attention mechanism; diffusion model

## 0 引言

石油资源对促进国民经济的发展至关重要, 管道作为一种可靠的运输媒介, 为石油资源的安全运输提供了重要保障<sup>[1-2]</sup>. 随着管道服役时间的增加, 管

道不可避免地会产生缺陷, 如果缺陷未能被及时检测并修复, 将会导致能源泄漏甚至爆炸等严重事故<sup>[3-5]</sup>. 此外, 在检测和修复缺陷的过程中, 准确地记录缺陷位置是至关重要的. 然而, 在长距离输油管道

收稿日期: 2024-06-16; 录用日期: 2024-08-21.

基金项目: 国家自然科学基金项目 (U21A20481, 62373085).

<sup>†</sup>通信作者. E-mail: liujinhai@mail.neu.edu.cn.

的检测过程中,探测器的里程记录可能会出现偏差.此时,工程师需要检测各种组件来纠正里程偏差<sup>[6]</sup>.因此,缺陷和组件的高精度检测对确保管道的安全运行具有重要意义.漏磁内检测是管道检测中最常用的方法之一,研究人员通过分析漏磁信号实现管道缺陷和组件的检测.现有的基于漏磁信号的数据分析方法主要分为信号处理方法、浅层机器学习方法和深度学习方法.

信号处理方法主要采用数据变换和特定阈值来实现缺陷检测.文献[7-8]分别提出基于改进多尺度熵和基于小波分解的管道缺陷检测方法.浅层机器学习方法通过组合手工特征和机器学习算法来实现缺陷检测.文献[9-10]分别提出基于随机森林和基于马尔可夫随机场模型的管道缺陷检测方法.尽管上述信号处理方法和浅层机器学习方法在特定条件下能取得令人满意的性能,然而在实际管道检测中,高维度、强非线性的漏磁信号使得恰当的阈值和通用的手工特征难以被有效地选取,这削弱了该类方法的实际应用效果.针对上述研究现状,基于深度学习的方法因其自动提取特征和强大的非线性拟合能力而受到广泛的研究<sup>[11-13]</sup>.文献[14]提出了一种基于改进卷积神经网络的方法实现管道缺陷识别.文献[15]设计了一种多尺度检测器(multiscale single shot multibox detector, MSSD)实现管道漏磁图像检测,其中扩散卷积和残差模块被引入来提升小缺陷的检测效果.文献[16]提出了一种基于漏磁机理的自监督方法(MFL mechanismbased self-supervised method, MMSM),它将漏磁知识与神经网络相结合实现了少标注样本下的管道缺陷检测.尽管基于深度学习的方法在管道缺陷检测领域已经取得了显著的进步,但在基于深度学习的管道缺陷和组件检测中仍有一些问题需要被进一步解决:1) 缺陷和组件的形状复杂、尺度多变,如何确保模型对多尺度目标的有效特征提取亟待解决.2) 现有研究的候选框生成依赖预先设定的锚点,而管道缺陷和组件的尺寸多变且不统一,这导致预先设定的锚点难以适应多变的工况,降低了检测方法的泛化性和准确性.

鉴于此,本文提出一种基于异构扩散模型的新型管道缺陷和组件检测方法,所提出方法能够有效聚焦管道缺陷和组件的关键特征.此外,所提出方法不需要预先设定锚点信息,降低了模型对先验知识的依赖.具体而言,本文的贡献点如下:

1) 针对管道缺陷和组件检测中特征提取困难的问题,提出一种基于稀疏注意力机制的特征提取模块,以稀疏化的方式实现网络对缺陷和组件核心特

征的聚焦.此外,将传统的特征金字塔网络替换为路径聚合特征金字塔网络,充分确保管道缺陷和组件的多尺度特征的完备性和有效性.

2) 针对现有检测方法因过度依赖预先设定的锚点信息而导致的模型泛化性差的问题,提出一种基于异构扩散模型的检测机制,所提出方法不需要预先设定锚点信息,将基于锚点信息的候选框生成过程转换为随机框的去噪过程,显著降低模型对预设锚点信息的依赖并提升其对多尺度目标的检测泛化性和准确性.

## 1 扩散模型和所提出方法概述

### 1.1 扩散模型

扩散模型的建模思想是通过迭代的高斯加噪过程,将服从分布 $v(s_0)$ 的样本 $s_0$ 逐步转换为 $T$ 时刻服从高斯分布的纯噪声样本 $s_T$ .接着,通过训练神经网络模型实现去噪.定义管道数据集的初始标签 $s_0 = \{c_{gt}, b_{gt}\}$ .其中: $c_{gt} \in \mathbb{R}^{N \times c}$ 和 $b_{gt} \in \mathbb{R}^{N \times 4}$ 分别为类别标签和边界框标签, $c$ 为被检测量的类别数, $N$ 为真值框的个数; $b_{gt} = \{x, y, w, h\}$ , $(x, y)$ 为边界框的左上角坐标, $w, h$ 为边界框的宽度和高度.具体而言,扩散模型的扩散过程 $v(\cdot)$ 是将管道数据集的初始标签 $s_0$ 转换为 $t$ 时刻的噪声数据 $s_t$ ,该过程通过加入由噪声方差 $\alpha_t$ 控制的噪声完成, $t \in \{0, 1, \dots, T\}$ .其扩散过程如下所示:

$$v(s_t | s_0) = \mathcal{N}(s_t | \sqrt{\bar{\beta}_t} s_0, (1 - \bar{\beta}_t) I). \quad (1)$$

其中: $\bar{\beta}_t = \prod_{m=1}^t \beta_m$ , $\beta_t = 1 - \alpha_t$ , $I$ 和 $\mathcal{N}$ 分别为单位矩阵和高斯分布.在训练阶段,本文的训练目标是使得检测模型 $f_\theta$ 将 $t$ 时刻的噪声标签 $s_t$ 恢复到原始的零噪声标签 $s_0$ .因此,在推理阶段,测试数据的检测结果 $s_0$ 将基于服从高斯分布的噪声 $s_T$ 用模型 $f_\theta$ 以迭代的方式去噪获得,即 $s_T \rightarrow s_{T-\Delta} \rightarrow \dots \rightarrow s_0$ .

### 1.2 所提出方法概述

针对现有管道缺陷及组件检测中存在的精度低和模型泛化性差的问题,提出一种基于异构扩散模型的管道缺陷及组件检测方法.该方法将管道缺陷及组件的检测问题转换为基于扩散模型的去噪问题.检测对象包括缺陷和其他5类组件:焊缝、支管、三通、支撑和夹具,共计6类目标.整体框架如图1所示,主要由3个部分组成:完备样本获取、特征提取和异构扩散检测.

在完备样本获取阶段,首先对漏磁信号进行预处理,以减少噪声等负面因素对后续数据分析的影响.在特征提取阶段,设计基于稀疏注意力机制的特

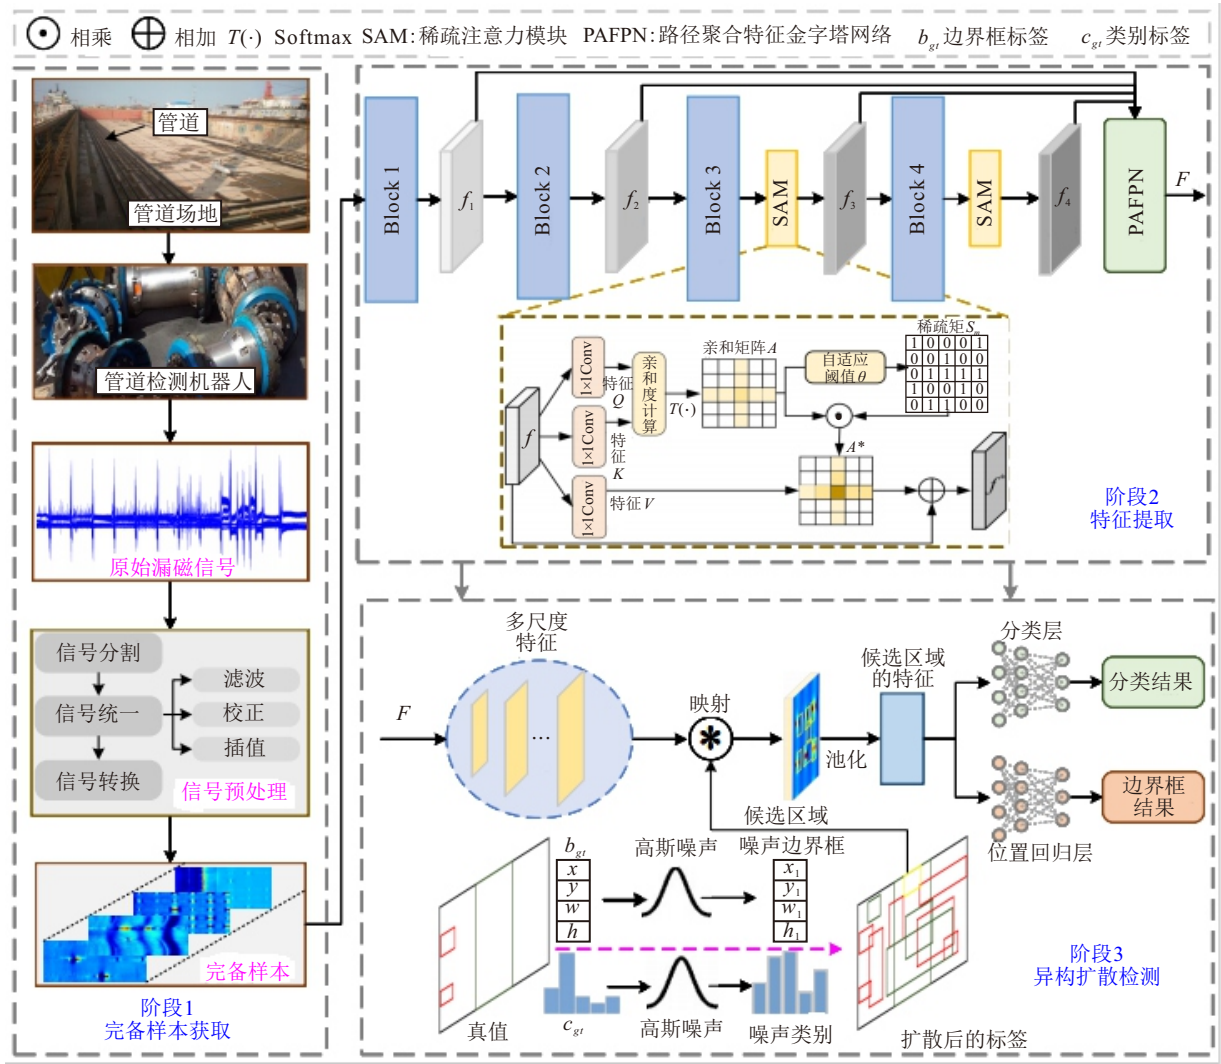


图1 基于异构扩散模型的缺陷及组件检测方法框架

征提取模块, 以确保网络能够自适应地关注缺陷和组件的关键信息. 此外, 将传统的特征金字塔网络替换为路径聚合金字塔网络, 充分确保模型对多尺寸缺陷和组件的特征提取的有效性. 在异构扩散检测阶段, 将缺陷和组件的检测视为从服从高斯分布的随机噪声到地面真值的去噪扩散过程, 削弱模型对固定锚点信息的依赖, 进而保证模型对多尺度目标的检测准确性和泛化性.

## 2 完备样本获取

为了减少信号获取过程中的噪声及传感器基值差异对模型训练的影响, 将原始的漏磁信号预处理以获取完备的训练样本. 所提出的完备样本获取主要包含 3 个部分: 信号分割、信号统一和信号转换.

### 2.1 信号分割

将内检测机器人获取的原始漏磁信号记作:  $\mathcal{H} \in \mathbb{R}^{P \times Q}$ , 其中  $P$  和  $Q$  分别为采样点的个数和采样通道数. 为了获取可训练的有效样本, 基于固定大小  $K$  和固定步长  $V$  的滑动窗口, 将  $\mathcal{H}$  分割为多个子

块  $\mathcal{H} = \{\mathcal{H}^1, \mathcal{H}^2, \dots, \mathcal{H}^M\}$ . 其中:  $\mathcal{H}^M \in \mathbb{R}^{K \times Q}$ ,  $M$  为分割后的样本个数. 分割完成后, 人为去除不含缺陷和组件的无效样本进而得到完备的样本库.

### 2.2 信号统一

进一步地, 考虑到分割样本之间的差异性以及信号采集过程中的噪声和基值差异等影响, 统一处理分割样本以保障后续特征提取的有效性. 具体而言, 应用高斯滤波和三次样条插值来确保样本的有效性和完整性. 此外, 考虑到传感器基值的差异, 基于下式, 将每个分割后的样本  $\mathcal{H}^n$  校正为统一的样本  $X^n \in \mathbb{R}^{K \times Q}$ :

$$X_{v,z}^n = \mathcal{H}_{v,z}^n - \frac{1}{K} \sum_{v=1}^K \mathcal{H}_{v,z}^n + \frac{1}{KQ} \sum_{v=1}^K \sum_{z=1}^Q \mathcal{H}_{v,z}^n, \quad (2)$$

其中  $X_{v,z}^n$  为第  $z$  个通道的第  $v$  个采样点.

### 2.3 信号转换

本节将经过统一后的单通道漏磁信号  $X^n$  转换为三通道的伪彩色图  $G^n \in \mathbb{R}^{K \times Q \times 3}$ . 相比于单通道

的漏磁信号,伪彩色图能够更好地突出缺陷和组件的关键特征,这为神经网络的深层抽象特征的提取奠定了基础,保障了后续多目标检测的精度.首先,基于jet颜色表,构建一个颜色矩阵 $C \in \mathbb{R}^{1024 \times 3}$ ;然后,基于下式得到每个单通道漏磁信号在颜色矩阵 $C$ 中的行索引:

$$R_i = \left\lfloor \frac{X^n - \min(X^n)}{\max(X^n) - \min(X^n)} \times \gamma \right\rfloor. \quad (3)$$

其中: $\max(\cdot)$ 和 $\min(\cdot)$ 分别为最大值函数和最小值函数; $\gamma$ 为映射分辨率,其值与颜色矩阵的行相同,设置为1024.基于行索引和颜色矩阵 $C$ ,获得三通道的伪彩色图 $G^n = C(R_i)$ ,将管道内检测机器人获得的原始漏磁信号转换为网络训练所需的伪彩色图样本.

### 3 特征提取

本节将完备的训练样本送入特征提取器以获取多尺度深层特征.如图1所示,设计的特征提取器主要包含3个部分:编码模块 $\mathbb{F}_e(\cdot)$ 、稀疏注意力模块 $\mathbb{F}_c(\cdot)$ (sparse attention module, SAM)和路径聚合特征金字塔网络 $\mathbb{F}_p(\cdot)$ (path aggregation feature pyramid network, PAFPN).

#### 3.1 编码模块

编码模块由在ImageNet数据集预训练的ResNet-50的4个区块(Block)组成.为了防止训练过拟合,冻结ResNet-50前两个区块(Block 1和Block 2)并微调后两个区块(Block 3和Block 4).基于下式得到漏磁信号的编码特征 $\{f_1, f_2, f_3, f_4\}$ :

$$\{f_1, f_2, f_3, f_4\} = \mathbb{F}_e(X, \kappa), \quad (4)$$

其中 $\kappa$ 为编码模块的网络参数.

#### 3.2 稀疏注意力模块

设计一种稀疏注意力模块以稀疏化的方式实现模型对缺陷和组件重要信息的聚焦.所提出的稀疏注意力模块在水平和垂直方向上收集上下文信息,以增强像素级的表示能力.如图1所示,给定特征图 $f \in \mathbb{R}^{C \times H \times W}$ ,其中 $C$ , $H$ 和 $W$ 分别为特征图的通道数、高度和宽度.首先,两个卷积核大小为 $1 \times 1$ 的卷积网络被应用到 $f$ 以生成两个特征图 $Q$ 和 $V$ ,其中 $\{Q, K\} \in \mathbb{R}^{\frac{C}{4} \times H \times W}$ .为了获得衡量特征图不同位置之间依赖关系的亲和矩阵 $A$ ,区别于自注意力机制,本方法希望在特征图 $Q$ 的空间维度每个位置 $l$ 上,计算与 $l$ 在同一行、同一列的元素之间的相关性,而不是计算所有元素.具体而言,在 $Q$ 的空间维度的每个位置 $l$ ,可以得到一个向量 $Q_l \in \mathbb{R}^{1 \times \frac{C}{4}}$ .同样地,从特征图 $K$ 中提取与位置 $l$ 同一行或同一列

的特征向量,得到集合 $\Gamma_l \in \mathbb{R}^{(H+W-1) \times \frac{C}{4}}$ .基于矩阵 $Q$ 和集合 $\Gamma_l$ 得到亲和矩阵 $A \in \mathbb{R}^{(H \times W) \times (H+W-1)}$ ,有

$$A = T(\zeta(Q) \otimes \Gamma_l^T) = \frac{\exp(\zeta(Q) \otimes (\Gamma_l^T)_i)}{\sum_{i=1}^{H+W-1} \exp(\zeta(Q) \otimes (\Gamma_l^T)_i)}. \quad (5)$$

其中: $T(\cdot)$ 和 $\zeta(\cdot)$ 分别为softmax和reshape的操作, $\exp(\cdot)$ 和 $\otimes$ 分别为指数函数和矩阵相乘的操作.进一步地,为了降低弱相关性因素带来的影响,希望尽可能保留较高相关性因素过滤掉低相关性因素.因此,得到稀疏矩阵 $S_m \in \mathbb{R}^{(H \times W) \times (H+W-1)}$ 为

$$S_m(i, j) = \begin{cases} 1, & A(i, j) \geq \theta; \\ 0, & A(i, j) < \theta. \end{cases} \quad (6)$$

其中 $\theta$ 是自适应阈值,由卷积核大小为 $1 \times 1$ 的卷积神经网络训练而来.基于亲和矩阵 $A$ 和稀疏矩阵 $S_m$ ,更新后的亲和矩阵 $A^*$ 计算如下:

$$A^* = S_m \odot A, \quad (7)$$

其中 $\odot$ 为哈达玛乘积.同时,在 $f$ 上应用卷积核大小为 $1 \times 1$ 的卷积神经网络生成特征表示 $V \in \mathbb{R}^{C \times H \times W}$ .最终,基于下式得到增强后的特征表示 $F^* \in \mathbb{R}^{C \times H \times W}$ :

$$F^* = \mathbb{C}_{l=1}^{H \times W} \left( \sum_{i=0}^{H+W-1} A_{i,l}^* V_{i,l} + F_l \right). \quad (8)$$

其中: $V_{i,l}$ 为特征图 $V$ 中位置 $l$ 的第 $i$ 个相邻特征向量, $\mathbb{C}(\cdot)$ 为拼接操作.所提出的稀疏注意力模块以稀疏化的方式降低了低相关性因素带来的影响,并迫使模型能够更好地聚焦于缺陷和组件的关键信息,这确保了高质量特征提取的有效性.

#### 3.3 路径聚合特征金字塔网络

考虑到管道缺陷和组件的尺寸变化差异较大的特点,为了充分获取深层抽象特征表示,本方法将传统的特征金字塔网络替换为路径聚合特征金字塔网络,在特征金字塔网络的融合特征基础上,每个构建块通过横向连接,基于一个更高分辨率的特征图 $F_i$ 和相邻上层的低分辨率特征图 $p_{i+1}$ 生成新的特征图 $F_{i+1}$ .最终,基于融合后的多尺度特征 $F = \{F_1, F_2, F_3, F_4\}$ 实现后续的检测.总体而言,相比于传统特征金字塔网络,路径聚合特征金字塔网络可以同时实现自顶向下和自低向上的特征聚合,这充分利用了漏磁信号的多尺度特征并保障了模型的定位和分类准确性.

### 4 异构扩散检测

针对现有检测方法因过度依赖预先设定的锚窗

信息而导致的模型泛化性差的问题, 提出一种基于扩散机制的检测方法. 首先, 基于多尺度特征  $F = \{F_1, F_2, F_3, F_4\}$  和候选框获取候选区域的特征. 然后, 将候选区域的特征送入检测网络预测分类结果和边界框检测结果. 值得注意的是, 在训练阶段, 候选框基于真值标签的扩散过程得到, 本方法的训练目标是逆转这一扩散过程. 将基于类别和边界框两个异构层次同时构建从真值到噪声标签的扩散过程. 一方面, 从类别层次进行扩散, 从而在随机噪声中生成目标类别信息, 增强模型对同类目标特征的聚焦能力, 使得模型在面对不同场景和目标变化时具有更好的鲁棒性; 另一方面, 提出基于边界框的去噪扩散过程, 直接从一组随机框中检测目标, 本质上将检测边界框的位置和大小视为对象检测框架中的生成任务. 通过模拟边界框的扩散过程, 不仅减少了对先验锚点的依赖, 同时更好地捕捉了目标的形状和位置变化, 从而能够提高检测精度和模型的泛化性. 其训练和推理过程主要包含 4 个部分: 地面真值填充、地面真值扩散、模型优化和模型推理.

**step 1: 地面真值填充.** 在实际的目标检测任务中, 感兴趣的实例数量通常随图像的变化而变化, 为了保障训练的一致性, 现有的方法往往固定参与训练的候选框数量. 因此, 本文将一些额外的随机噪声框填充到原始的地面真值中构建一个固定长度的候选区域集合  $\Theta$ , 填充后的地面真值的实例数量由原来的  $N$  个变为  $N_{\text{train}}$  个.

**step 2: 地面真值扩散.** 定义管道数据集的真值标签为  $s_0$ . 在这一步骤中, 本方法主要通过向填充后的地面真值  $\Theta$  中增加高斯噪声来实现真值的扩散. 具体而言, 将不同程度的高斯噪声增加到真值中以生成噪声类别  $c_i^*$  和噪声边界框  $b_i^*$ , 进而得到扩散后的候选区域集合  $\Theta^* = \{c_i^*, b_i^*\}_{i=1}^{N_{\text{train}}}$ , 其中噪声的强度由式 (1) 中的  $\alpha_t$  控制. 此外, 信噪比对扩散模型的性能有重要影响<sup>[17]</sup>. 因此, 在真值扩散前, 首先依据下式将地面真值进行缩放以提升其信噪比:

$$\Theta = (\Theta \times 2 - 1) \times \eta, \quad (9)$$

其中  $\eta$  为缩放因子.

**step 3: 模型优化.** 基于 step 2 扩散后的候选框集合  $\Theta^*$  和多尺度特征  $F$ , 得到长度为  $N_{\text{train}}$  的候选区域特征集合. 进一步地, 将候选区域特征集合送入图 1 所示的分类网络  $\text{Net}_{\text{cls}}(\cdot)$  和位置回归网络  $\text{Net}_{\text{reg}}(\cdot)$  以得到类别预测  $c$  和边界框预测  $b$ , 有

$$c = \text{Net}_{\text{cls}}(F, b^*) + c^*, \quad b = \text{Net}_{\text{reg}}(F, b^*). \quad (10)$$

此外, 应用最优传输分配方法从集合  $\Theta^*$  中选择

代价最小的前  $m$  个预测为每个真值分配对应的正样本. 将模型优化的分类损失  $\mathcal{L}_{\text{cls}}$  和位置回归损失  $\mathcal{L}_{\text{reg}}$  分别定义如下:

$$\mathcal{L}_{\text{cls}} = (1 - c_{\text{gt}}) \log c - c_{\text{gt}} \log(1 - c), \quad (11)$$

$$\mathcal{L}_{\text{reg}} = 1 - \frac{|b \cap b_{\text{gt}}|}{|b \cup b_{\text{gt}}|} - \frac{\rho^2(b, b_{\text{gt}})}{d^2}. \quad (12)$$

其中:  $c_{\text{gt}}$  和  $b_{\text{gt}}$  分别为类别真值和边界框真值,  $\rho(\cdot)$  为计算两个矩形框中心点的欧氏距离,  $d$  为能同时包含  $b$  和  $b_{\text{gt}}$  的最小矩形外接框的对角线长度. 定义模型优化的整体损失为  $\mathcal{L} = \mathcal{L}_{\text{cls}} + \mathcal{L}_{\text{reg}}$ .

**step 4: 模型推理.** 基于上述优化过程得到完备的检测模型. 在测试推理阶段, 检测模型将对类别集合和边界框集合进行随机采样, 并通过逐步改进预测结果达到去噪的效果, 最终去噪结果将被作为真实的预测结果. 其中, 类别集合和边界框集合均服从高斯分布. 具体而言, 基于随机采样获得任意时刻  $t$  的候选框和随机标签, 将其送入到分类网络  $\text{Net}_{\text{cls}}(\cdot)$  和位置回归网络  $\text{Net}_{\text{reg}}(\cdot)$  以预测类别  $c_t$  和框坐标  $b_t$ . 在获得  $t$  时刻预测结果后, 去除置信度较低的框以减少这类无效框对后续预测的影响. 进一步地, 依据  $t$  时刻的采样结果和 DDIM<sup>[18]</sup> 策略实现  $t - 1$  时刻的估计, 以此迭代的方式获取最后一步采样的结果及对应的预测结果.

## 5 实验分析和讨论

### 5.1 实验设置

#### 5.1.1 数据集获取

本文应用的数据集来自如图 2 所示的中国北方管道平台. 管道由 X65 碳钢组成, 被测管道的壁厚和外径分别为 12.7 mm 和 426 mm. 实验数据由管道内检测机器人获得, 其安装了采集漏磁信号的霍尔传感器. 霍尔传感器的采样间隔为 0.002 m (即每两个采样点之间的间隔为 0.002 m), 传感器测量的信号范围为  $\pm 670$  高斯, 传感器灵敏度为  $3.125 \pm 0.125$  mV/G. 检测过程中, 内检测机器人由管道内液体推动匀速前行, 其运行速度为 1.5 m/s, 内部设备的供电电压为 22 V. 本文应用的数据集包含缺陷、三通、支撑、支管、卡箍、管道夹具共计 6 类. 数据集共计 3 087 张图像, 每张图像的大小为  $450 \times 180$ , 其中包含多个缺陷及组件, 数据集依据 8 : 1 : 1 的比例划分出训练集、验证集和测试集.

#### 5.1.2 硬件设置和方法设置

实验应用的硬件配置如下: 操作系统: Ubuntu 18.04.5, CPU: 2 个 AMD EPYC 7601 2.7 GHz 32 核处理器, 内存: 128 GB, GPU: 2 个 NVIDIA GeForce



图2 中国北方管道实验场

RTX 3090, 硬盘: 1TB. 实验所有代码都在 Pytorch 框架下实现, 网络最大迭代次数为 50 epoch, 初始学习率为 0.02. 网络的优化器为随机梯度下降, 每次输入网络的图像批次大小为 32. 此外, 为验证所提出方法的有效性, 与文献 [16] 类似, 将精准率 (Precision)、召回率 (Recall) 和检测精度 (Accuracy) 作为评价指标来衡量模型的有效性.

### 5.2 实验结果分析

#### 5.2.1 模型整体性能分析

为了充分验证所提出方法的优越性, 在相同的实验条件下, 将本文方法与其他先进的检测方法包括: MSSD<sup>[15]</sup>、MMSM<sup>[16]</sup>、ConvNeXt-V2<sup>[19]</sup> 和 Sparse R-CNN<sup>[20]</sup> 进行对比. 特别地, 本文方法统计了交并比 (intersection over union, IoU) 大于 0.5 (IoU@0.5)

的结果和交并比在 0.5 ~ 0.95 (IoU@0.5:0.95) 的平均实验结果. 其中: IoU 大于 0.5 时的检测结果能够更好地比较不同方法的检测精度, 而 IoU 在 0.5 ~ 0.95 时的实验结果能够更好地比较不同方法的定位精度. 具体实验结果如表 1 和表 2 所示. 从实验结果可知, 所提出方法的整体性能优于其他对比方法. 具体而言, 当 IoU 大于 0.5 时, 所提出方法的平均精准率和平均召回率分别达到 99.0 % 和 99.4 %, 高于对比方法 4.1 % 和 4.0 %, 这表明所提出方法更不容易误诊和漏诊. 此外, 当 IoU 在 0.5 ~ 0.95 时, 所提出方法仍然具备较高的精准率和召回率, 这表明所提出方法的定位框更加逼近真值框, 具备更高的定位精度. 所提出方法取得优异性能的原因总结如下: 1) 提出的稀疏注意力模块能够迫使模型关注缺陷和组件的核心信息, 充分确保了特征提取的有效性. 此外, 传统的特征金字塔网络被替换为路径聚合特征金字塔网络, 使得底层位置信息和顶层的语义信息得到充分利用, 并增强了多尺度特征的完备性. 2) 所提出的异构扩散机制减少了模型对锚点信息的依赖, 进一步提升了模型对多尺度目标检测的自适应能力, 进而确保了模型的检测精度.

表1 IoU 为 0.5 时不同方法的实验结果

%

方法	Precision						Recall					
	缺陷	焊缝	支管	三通	支撑	夹具	缺陷	焊缝	支管	三通	支撑	夹具
MSSD	94.3	88.5	96.4	94.8	91.8	92.1	95.1	96.1	96.4	95.2	92.2	93.2
ConvNeXt-V2	96.2	91.2	97.3	95.7	98.2	95.6	96.3	95.3	96.1	95.8	96.4	96.7
Sparse R-CNN	95.2	92.7	93.9	96.3	95.8	96.7	94.6	93.1	94.2	96.4	96.1	95.9
MMSM	93.5	93.1	96.9	97.3	97.1	96.2	93.9	94.3	95.3	97.6	97.2	96.5
<b>Proposed</b>	<b>98.6</b>	<b>96.5</b>	<b>99.6</b>	<b>99.8</b>	<b>99.8</b>	<b>99.2</b>	<b>99.4</b>	<b>99.1</b>	<b>99.6</b>	<b>99.7</b>	<b>99.4</b>	<b>99.2</b>

表2 IoU 为 0.5 ~ 0.9 时不同方法的实验结果

%

方法	Precision						Recall					
	缺陷	焊缝	支管	三通	支撑	夹具	缺陷	焊缝	支管	三通	支撑	夹具
MSSD	58.8	85.0	66.7	78.5	90.0	90.2	66.9	90.5	71.1	81.2	91.7	93.1
ConvNeXt-V2	56.5	77.8	60.8	65.2	72.1	86.8	72.0	89.1	70.0	80.4	82.9	88.9
Sparse R-CNN	62.5	85.2	65.4	79.8	94.3	93.0	71.4	91.8	72.0	82.6	93.8	93.2
MMSM	62.2	86.7	64.3	78.6	95.1	93.6	70.1	92.6	<b>72.6</b>	81.9	95.2	93.3
<b>Proposed</b>	<b>67.1</b>	<b>89.7</b>	<b>66.8</b>	<b>81.4</b>	<b>97.9</b>	<b>95.0</b>	<b>73.6</b>	<b>94.4</b>	72.2	<b>83.6</b>	<b>98.2</b>	<b>95.0</b>

#### 5.2.2 工程应用精度分析

在实际工程应用中, 为了确保模型检测结果的可靠性, 工程师通常定义 IoU 和置信度均大于 0.5

时的预测结果为最终检测结果. 本文实验统计了不同检测方法在实际工程应用中的检测结果. 如图 3 所示, 所提出方法对于组件和缺陷的检测精度优于

其他对比方法. 具体而言, 所提出方法的平均检测精度达到 97.4 %, 高于次优检测方法 MMSM 的检测精度约 3.5 %. 值得注意的是, 本文方法已经被嵌入项目组自主研发的管道智能数据分析系统, 目前已顺利完成多条管道的检测. 基于本文方法对某实际管道的内检测数据展开分析, 共检测出缺陷 1 411 个, 最后对 48 个重度缺陷进行开挖验证. 图 4 分别展示了自主研发软件的数据分析结果和对应的管道开挖验证结果, 通过开挖验证可知, 本文方法能够在小于 0.1 m 的定位误差范围内实现精准的缺陷及组件检测, 符合油气管道内检测技术规范标准, 进一步验证了其在实际应用中的有效性.

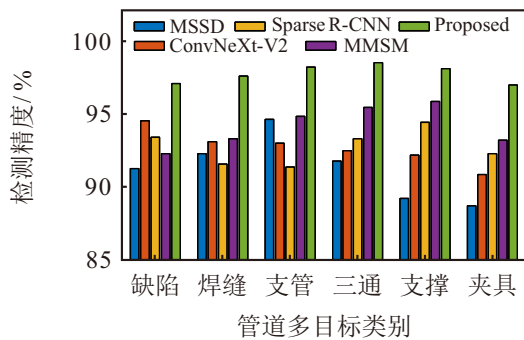


图3 不同检测方法的工程应用检测精度对比结果




图4 管道智能数据分析系统分析结果及开挖验证

### 5.3 消融实验分析

为了验证所提出方法各个组件的有效性, 在相同实验设置的前提下开展消融实验. 评价指标方面, 计算  $IoU@0.5 : 0.95$  时的全类平均精准率 (mean average precision, mAP) 和全类平均召回率 (mean average recall, mAR). 在复杂度方面使用网络参数和浮点运算数 (floating point operations, FLOPs) 作为

指标, 实验结果如表 3~表 5 所示.

表3  $IoU@0.5 : 0.95$  时不同注意力模块的消融实验结果

方法	$IoU @ 0.5 : 0.95$			
	mAP/%	mAR/%	参数量/M	FLOPs/G
自注意力	81.1	84.1	224.6	53.2
稀疏注意力	<b>83.0</b>	<b>86.2</b>	<b>172.2</b>	<b>45.6</b>

表4  $IoU@0.5 : 0.95$  时不同融合网络的消融实验结果 I


方法	$IoU @ 0.5 : 0.95$	
	mAP/%	mAR/%
无特征金字塔网络	78.1	79.6
传统的特征金字塔网络	80.8	83.8
路径聚合特征金字塔网络	<b>83.0</b>	<b>86.2</b>

表5  $IoU@0.5 : 0.95$  时不同融合网络的消融实验结果 II


方法	$IoU @ 0.5 : 0.95$	
	mAP/%	mAR/%
无类别扩散机制	81.5	84.9
无边界框扩散机制	80.7	83.6
异构扩散机制	<b>83.0</b>	<b>86.2</b>

#### 5.3.1 稀疏注意力的消融研究

基于表 3 可知, 当稀疏注意力模块被替换为自注意力模块<sup>[21]</sup>时, 所提出方法的平均精准率和平均召回率分别下降 1.9 % 和 2.1 %. 与此同时, 其参数量少于传统的自注意力模块. 特别地, 图 5 展示了不同注意力方法的特征可视化热图. 基于图 5 可知, 所提出的稀疏注意力能够有效聚焦于管道缺陷和组件的关键特征. 此外, 相比于自注意力模块, 所提出的稀疏注意力模块减少了对低相关性区域的关注.



(a) 自注意力



(b) 稀疏注意力

图5 不同注意力模块的特征可视化热图

#### 5.3.2 路径聚合特征金字塔网络的消融研究

基于表 4 可知, 当不应用特征金字塔网络, 即直接将来自 ResNet-50 最后阶段的特征输入至检测网

络时,所提出方法的 mAP 和 mAR 分别下降了 4.9% 和 6.6%。这主要归因于特征金字塔网络能够有效利用多尺度信息和上下文信息,确保多尺度缺陷和组件的准确检测。进一步地,将传统的特征金字塔网络与路径聚合特征金字塔网络进行对比,当应用路径聚合特征金字塔网络时,模型的平均精准率和平均召回率分别提升 2.2% 和 2.4%,这主要是因为相比于传统的特征金字塔网络,路径聚合金字塔网络增加了自底向上的特征融合阶段,充分确保了多尺度特征的完备性,保障了模型的检测精度。

### 5.3.3 异构扩散机制的消融研究

本文的异构扩散机制包含两个方面:类别扩散和边界框扩散,分别对此开展消融研究,实验结果如表 5 所示。当不应用类别扩散和边界框扩散时,所提出方法的性能均有所下降。具体而言,未使用类别扩散机制时,模型的类别输出完全依赖候选区域特征和预测网络,导致 mAP 和 mAR 分别下降 1.5% 和 1.3%。这是因为类别噪声及其去噪过程增强了模型对特征差异较大的同类目标的识别鲁棒性,从而提升了整体检测精度。此外,未使用边界框扩散机制时, mAP 和 mAR 分别下降了 2.3% 和 2.6%。这主要是因为边界框加噪最大化了候选框的多样性,有助于捕捉多尺度目标的形状和位置变化,从而提升了检测精度。

## 6 结论

本文设计了一种基于异构扩散模型的新型管道多目标检测方法,所提出方法能够更好地提取缺陷和组件的多尺度信息,并减少对固定锚点信息的依赖,这充分保障了该方法的检测准确性和泛化性。首先,原始的漏磁信号经过预处理以获取完备的训练样本,减少信号采集中负面因素对后续数据分析的影响;其次,设计了一种稀疏注意力模块,以少量的参数实现缺陷和组件核心信息的聚焦;同时,特征金字塔网络被替换为路径聚合特征金字塔网络,充分保障多尺度特征提取的有效性;最后,设计了一种基于类别和边界框的异构扩散检测机制,将目标检测问题转换为去噪过程,显著削弱了模型对固定锚点信息的依赖,提升了模型对多尺度目标检测的自适应能力。在实验场管道中对所提出方法进行验证,实验结果表明其性能优于对比方法,能够精准地实现缺陷和组件的检测。

### 参考文献 (References)

[1] 马大中,王天彪,胡旭光,等.基于数据驱动的管道云边协同泄漏检测方法[J].控制与决策,2023,38(8):

2415-2424.

(Ma D Z, Wang T B, Hu X G, et al. Data-driven pipeline leak detection method based on cloud-edge collaboration[J]. Control and Decision, 2023, 38(8): 2415-2424.)

[2] 彭道刚,陈晨,王丹豪,等.基于改进 YOLOv7 的火电厂管道及阀门泄漏分割与检测[J].控制与决策,2024,39(9):2977-2986.

(Peng D G, Chen C, Wang D H, et al. Leakage segmentation and detection of pipelines and valves in thermal power plants based on improved YOLOv7[J]. Control and Decision, 2024, 39(9): 2977-2986.)

[3] 王鹏,赵春晖,周华良,等.基于多时相巡检图像的变电设备抗干扰缺陷检测[J].控制与决策,2024,39(3):885-892.

(Wang P, Zhao C H, Zhou H L, et al. Anti-interference defect detection of substation equipment based on multitemporal inspection images[J]. Control and Decision, 2024, 39(3): 885-892.)

[4] 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. Self-supervised defect detection method based on magnetic flux leakage internal detection[J]. Chinese Journal of Scientific Instrument, 2020, 41(9): 180-187.)

[5] 卢森骧,神祥凯,张俊楠,等.基于三轴融合的漏磁内检测数据缺陷反演方法研究[J].仪器仪表学报,2021,42(12):245-253.

(Lu S X, Shen X K, Zhang J N, et al. Research on defect inversion method of magnetic flux leakage internal inspection data based on triaxial fusion[J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 245-253.)

[6] 俞进,唐建华,神祥凯,等.基于 Faster R-CNN 的海底管道智能检测方法[J].中国安全科学学报,2023,33(6):80-87.

(Yu J, Tang J H, Shen X K, et al. Intelligent detection method for submarine pipelines based on Faster R-CNN[J]. China Safety Science Journal, 2023, 33(6): 80-87.)

[7] 郝永梅,杜璋昊,杨文斌,等.基于改进 ELMD 和多尺度熵的管道泄漏信号识别[J].中国安全科学学报,2019,29(8):105-111.

(Hao Y M, Du Z H, Yang W B, et al. Pipeline leakage signal identification based on improved ELMD and multi-scale entropy[J]. China Safety Science Journal, 2019, 29(8): 105-111.)

[8] Slesarev D. Defect identification based on wavelet decomposition for MFL non-destructive inspection of steel plates[J]. Insight — Non-Destructive Testing and Condition Monitoring, 2021, 63(3): 146-150.

[9] 刘金海,付明芮,唐建华.基于漏磁内检测的缺陷识别方法[J].仪器仪表学报,2016,37(11):2572-2581.

(Liu J H, Fu M R, Tang J H. MFL inner detection based defect recognition method[J]. Chinese Journal of Scientific Instrument, 2016, 37(11): 2572-2581.)

[10] Wang H, Yajima A, Liang R Y, et al. A clustering

- approach for assessing external corrosion in a buried pipeline based on hidden Markov random field model[J]. *Structural Safety*, 2015, 56: 18-29.
- [11] 叶卓勋, 刘妹琴, 张森林. 基于轻量化深度学习网络的工业环境小目标缺陷检测[J]. *控制与决策*, 2023, 38(5): 1231-1238.  
(Ye Z X, Liu M Q, Zhang S L. Small-scale defect detection in industrial environment based on lightweight deep learning network[J]. *Control and Decision*, 2023, 38(5): 1231-1238.)
- [12] 赵亮, 刘世鹏. 全局与局部图像特征自适应融合的小目标检测算法[J]. *控制与决策*, 2023, 38(4): 935-943.  
(Zhao L, Liu S P. Small object detection algorithm based on adaptive fusion of global and local image features[J]. *Control and Decision*, 2023, 38(4): 935-943.)
- [13] 梁浩鹏, 曹洁, 赵小强. 基于 GADF 和 PAM-Resnet 的旋转机械小样本故障诊断方法[J]. *控制与决策*, 2023, 38(12): 3465-3472.  
(Liang H P, Cao J, Zhao X Q. Small sample fault diagnosis method for rotating machinery based on GADF and PAM-Resnet[J]. *Control and Decision*, 2023, 38(12): 3465-3472.)
- [14] 王宏安, 陈国明. 基于深度学习的漏磁检测缺陷识别方法[J]. *石油机械*, 2020, 48(5): 127-132.  
(Wang H A, Chen G M. Magnetic flux leakage defect detection based on deep learning[J]. *China Petroleum Machinery*, 2020, 48(5): 127-132.)
- [15] Yang L J, Wang Z J, Gao S W. Pipeline magnetic flux leakage image detection algorithm based on multiscale SSD network[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 501-509.
- [16] Zhao H, Liu J H, Tang J H, et al. A MFL mechanism-based self-supervised method for defect detection with limited labeled samples[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-10.
- [17] Jonathan H, Ajay J, Pieter A. Denoising diffusion probabilistic models[J]. *Advances in Neural Information Processing Systems*. Piscataway: IEEE, 2020, 33: 6840-6851.
- [18] Song J, Meng C, Ermon S. Denoising diffusion implicit models[C]. *International Conference on Learning Representations*. Piscataway: IEEE, 2021.
- [19] Woo S, Debnath S, Hu R H, et al. ConvNeXt V2: Co-designing and scaling ConvNets with masked autoencoders[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver, 2023: 16133-16142.
- [20] Sun P Z, Zhang R F, Jiang Y, et al. Sparse R-CNN: End-to-end object detection with learnable proposals[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville, 2021: 14449-14458.
- [21] Wang X L, Girshick R, Gupta A, et al. Non-local neural networks[C]. *IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, 2018: 7794-7803.

### 作者简介

神祥凯 (1996-), 男, 博士生, 主要研究方向为深度学习、数据驱动的故障诊断, E-mail: [sxiangkai@163.com](mailto:sxiangkai@163.com);

刘金海 (1979-), 男, 教授, 博士生导师, 主要研究方向为智能故障诊断、长距离输油管道安全检测, E-mail: [liujinhai@mail.neu.edu.cn](mailto:liujinhai@mail.neu.edu.cn).