

基于 WOA 动态复合模型的管道螺旋焊缝检测研究^{*}张俊红¹ 曲 鹤¹ 潘惊涛¹ 杨 松² 李凌宇¹

(1. 北京建筑大学智能科学与技术学院 北京 102616; 2. 北京自由博创科技发展有限公司 北京 100083)

摘 要: 针对复杂工况下管道螺旋焊缝检测数据中时间和空间特征提取不能兼顾和模型参数优化效率低的问题,提出一种基于深度学习的动态复合优化检测模型。通过传感器采集管道的超声导波信号,利用卷积神经网络提取空间特征和长短期记忆网络对时间序列数据进行处理。采用鲸鱼优化算法对时空融合模型的卷积层滤波器数量、LSTM 层的单元数量、学习率和 Dropout 率四个关键超参数进行优化,提高模型的鲁棒性。基于高噪声、低噪声和正常数据集上进行对比试验,结果表明,所提检测模型在不同工况下的准确率分别达到了 98.88%、99.7% 和 100%,均方误差分别降至 0.195 5、0.177 和 0.095。验证了其在高噪声、多干扰复杂环境下的检测性能优势,为基于超声波的螺旋焊缝管道检测提供理论依据。

关键词: 管道螺旋焊缝;深度学习;优化检测模型;识别与定位

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 510.80;520.20

Research on spiral weld pipe inspection based on WOA
dynamic composite modelZhang Junhong¹ Qu He¹ Pan Jingtao¹ Yang Song² Li Lingyu¹(1. School of Intelligent Science and Technology, Beijing University of Civil Engineering and Architecture, Beijing 102616, China;
2. Beijing DTCCM Electronics & Control Technology Co., Ltd., Beijing 100083, China)

Abstract: In the inspection of spiral-welded pipelines, conventional methods often struggle to balance the extraction of temporal and spatial features while maintaining efficient model parameter optimization. To address these challenges, this study proposes a dynamic composite optimization detection model based on deep learning. Ultrasonic guided wave signals are acquired through sensors, where spatial features are extracted using a convolutional neural network and temporal dependencies are modeled via a long short-term memory network. To enhance model robustness, the whale optimization algorithm is employed to optimize four critical hyperparameters: the number of CNN filters, LSTM units, learning rate and Dropout rate. Comparative experiments were conducted on high-noise, low-noise and normal datasets. The results show that the accuracy rates of the proposed detection model have reached 98.88%, 99.7% and 100% respectively, and the average absolute errors have decreased to 0.195 5, 0.177 and 0.095 respectively. It verifies the detection performance advantages in the complex environment of high noise and multiple interference, and provides a theoretical basis for the spiral weld pipeline detection based on ultrasonic.

Keywords: spiral weld seam of pipeline; deep learning; optimize the detection model; identification and location

0 引 言

供水管道作为城市基础设施的重要组成部分,在城市供暖供水中发挥着至关重要的作用^[1]。由于管道长期面临腐蚀、磨损、泄漏等风险产生各种缺陷,从而容易引发重大安全事故^[2]。高效准确的管道缺陷检测方法是保障管网安

全运行和降低维修成本的重要手段。

管道检测方法主要分为传统方法、机器学习方法和深度学习模型。传统方法以超声成像^[3]、导波模态分析^[4]为主,通过信号阈值分割或频域分析定位缺陷。这些方法大都依赖专家经验且对噪声敏感,存在效率低、实时性差等问题,难以应对复杂工况下的动态监测需求。机器学习方法

收稿日期:2025-05-29

^{*} 基金项目:教育部人文社会科学规划基金(22YJA630111)、建筑大数据智能处理方法研究北京市重点实验室和北京建筑大学硕士生创新项目(PG2025110)资助

利用数学模型,通过人工设计特征对管道检测数据进行分类和回归分析,如支持向量机^[5]、随机森林^[6]等。这些方法能够在一定程度上提高检测的自动化程度和准确度^[7],但需要标注大量数据进行训练,并且在特征提取方面仍不能捕捉信号的时序动态特性,难以充分利用数据中的深层次信息。深度学习模型则进一步利用神经网络的强大功能,可以自动提取数据中的特征^[8],如卷积神经网络^[9](convolutional neural networks, CNN)、循环神经网络(recurrent neural network, RNN)及其变体长短时记忆网络^[10](long short-term memory network, LSTM)等。CNN能够通过卷积层自动学习数据中的局部特征,有效捕捉信号的空间信息和局部模式,在处理具有空间相关性的数据时表现优异。孙洁娣等^[11]提出一种轻量化神经网络用于管道泄漏孔径识别,改善了实时响应能力。Yang 等^[12]利用 CNN 进行特征提取和分类,实现了对小尺寸泄漏的精确识别。然而, CNN 的核心设计使其在处理本质上具有强时间依赖性的连续信号时面临挑战^[13],它难以有效建模信号点之间的长期动态依赖关系和上下文时序演变,限制了其在需要理解信号完整时间演化过程的复杂工况中的应用。

LSTM 通过门控结构解决了传统 RNN 的梯度消失或爆炸问题,使其在捕捉时间序列数据的长期依赖关系方面具有独特优势,在时间序列预测和分类任务中得到了广泛应用^[14-15]。然而, LSTM 在处理具有显著空间结构信息如图像和空间分布的传感器阵列信号的数据时,其空间特征提取能力通常弱于 CNN。现有研究多侧重于利用 LSTM 处理单一维度的时序信号如某点的压力或者流量变化,对于需要同时精细解析空间结构并理解其时序演化过程的复杂任务,单一 LSTM 模型往往难以兼顾。

深度学习模型能够自动提取数据特征^[16],但在模型训练过程中,超参数(如卷积核数量、学习率)的设置对模型性能影响显著^[17],目前超参数的优化大多依赖经验或简单的搜索策略,导致模型在跨工况场景下的稳定性下降。采用智能优化算法^[18-19],如麻雀搜索算法^[20](sparrow search algorithm, SSA)和改进粒子群优化^[21](improved particle swarm optimization, IPSO)算法对超参数进行优化成为解决这类问题的有效途径,但仍存在易陷入局部最优解的问题。

现有检测方法主要集中于供水管道本身缺陷,而忽略了由于螺旋焊接工艺在管道上形成的焊缝为后续检测带来的挑战。本文构建了一种基于深度学习的动态复合优化检测模型,用于螺旋焊缝管道缺陷的识别与定位。

1 方法研究

1.1 鲸鱼优化算法

鲸鱼优化算法^[22](whale optimization algorithm, WOA)是一种模拟座头鲸捕猎行为的优化算法,其流程如

图 1 所示,通过模仿座头鲸在海洋中的捕食行为,对鲸鱼群体的搜索、包围和攻击过程进行模拟,以寻找最优解。




图 1 WOA 算法主要流程

Fig. 1 Main process of the WOA

WOA 算法的主要步骤如下:

1) 收缩包围

假设当前种群的最优个体是猎物,种群中其他鲸鱼个体均向最优鲸鱼位置包围来更新其自身位置。设 $\mathbf{X}^*$ 是目标鲸鱼的位置, $\mathbf{X}$ 是当前鲸鱼的位置, $\mathbf{X}(t+1)$ 为下一时刻输出位置:

$$\mathbf{D} = |\mathbf{C}\mathbf{X}^*(t) - \mathbf{X}(t)| \quad (1)$$

$$\mathbf{X}(t+1) = \mathbf{X}(t) - \mathbf{A} \cdot \mathbf{D} \quad (2)$$

式中: $\mathbf{D}$ 是鲸鱼与猎物之间的距离向量, $\mathbf{A}$ 和 $\mathbf{C}$ 是系数向量。系数 $\mathbf{A}$ 和 $\mathbf{C}$ 的计算公式为:

$$\mathbf{A} = 2\mathbf{a} \cdot \mathbf{r} - \mathbf{a} \quad (3)$$

$$\mathbf{C} = 2 \cdot \mathbf{r} \quad (4)$$

式中: $\mathbf{a}$ 是一个从 2 线性递减到 0 的向量, $\mathbf{r}$ 是 (0, 1) 范围内的随机向量。

2) 螺旋上升捕食

座头鲸会以螺旋运动的轨迹捕猎,鲸鱼个体更新位置为:

$$\mathbf{X}(t+1) = \mathbf{D}' \cdot e^{bl} \cdot \cos(2\pi l) + \mathbf{X}^*(t) \quad (5)$$

式中: $\mathbf{D}' = |\mathbf{X}^*(t) - \mathbf{X}(t)|$ 是鲸鱼与猎物之间的距离, b 是螺旋的形状参数, l 是 $[-1, 1]$ 范围内的随机数。

3) 随机搜索

为了避免陷入局部最优,WOA 还模拟了座头鲸的随机搜索行为,在更大的解空间中进行搜索。当 $|\mathbf{A}| \geq 1$ 时,鲸鱼会随机选择一个个体作为目标进行搜索,位置更新为:

$$\mathbf{X}(t+1) = \mathbf{X}_{rand}(t) - \mathbf{A} \cdot \mathbf{D} \quad (6)$$

式中: $\mathbf{X}_{rand}$ 是随机选择的鲸鱼个体的位置。

本文采用 WOA 优化算法实现关键超参数的自适应寻优,以卷积层滤波器数量、LSTM 层的单元数、学习率和 Dropout 率四维参数空间为优化变量,通过模拟鲸鱼种群围捕猎物的 3 个阶段,动态平衡参数空间的全局探索与局部开发能力,利用随机概率平衡开发与探索强度,使超参数组合逐步逼近最优解集。经迭代优化,算法输出的最优参数组不仅可以通过 Dropout 提升模型抗噪能力,而且同步提升 CNN 空间特征提取能力与 LSTM 时序建模精度,为复杂工况下的焊缝检测建立了动态参数自适应体系。

1.2 卷积神经网络

CNN 是一种基于深度学习的特征自动提取方法,其核心结构由卷积层、池化层和全连接层构成,通过局部连接与权值共享机制显著降低了网络参数规模,具有强大的特征表征能力,结构如图 2 所示。在管道缺陷检测中,传感器采集的超声导波信号具有局部相关性和多尺度特性。CNN 通过卷积核在输入信号上的滑动运算,利用局部感受野即每个卷积核仅连接输入数据的一个小区域逐点捕获信号中的局部空间模式。卷积层采用 ReLU 激活函数增强非线性表达能力,池化层通过最大池化或平均池化操作实现特征降维与平移不变性,有效抑制噪声干扰。每一层卷积操作中,滤波器的数量决定了该层能够学习并提取的不同类型空间特征也就是特征图的数量。滤波器数量越多,网络捕获信号中多样、复杂空间模式的潜力就越大。CNN 通过端到端学习机制自动优化特征提取过程,避免手动设计特征的主观性与局限性。CNN 的多维卷积运算可有效融合不同传感器通道间的空间关联信息,为时序建模提供高判别性的特征输入。




图 2 CNN 网络结构

Fig. 2 Structure of CNN

CNN 作为动态复合优化检测模型的核心组件,可以完成超声导波信号空间特征的深度挖掘。针对管道螺旋焊缝检测数据中局部相关性和多尺度特性,本文构建了由双层一维卷积与最大池化构成的层级特征提取架构:双层卷积可以融合传感器通道间的空间关联信息;最大池化层在保留显著特征的同时可以实现噪声抑制。通过 WOA 动态调整卷积层滤波器数量,使网络自适应不同工况下的特征复杂度,使网络能够根据输入数据的特征复杂度自适应地增减其表征能力,最终输出高判别性的空间特征向量,与 LSTM 提取的时序依赖特征进行深度融合,用于复杂噪声

环境下的螺旋焊缝管道检测。

1.3 长短期记忆网络

LSTM 是一种专为解决传统 RNN 缺陷而设计的深度学习模型,擅长处理时间序列。核心结构包含 3 个关键门控单元和一个细胞元状态;遗忘门(f_t)通过 Sigmoid 函数决定细胞状态中需要保留或丢弃的信息;输入门(i_t)筛选当前输入的重要特征并与候选记忆细胞状态进行结合,更新细胞状态;输出门(o_t)则基于当前状态和输入生成最终输出,结构如图 3 所示。




图 3 LSTM 单元结构

Fig. 3 Structure of LSTM unit

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \\ C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \\ h_t = o_t * \tanh(C_t) \end{cases} \quad (7)$$

其中, W 和 b 代表权重矩阵和偏置向量, h 代表隐藏层

状态, $\tilde{C}_t$ 代表候选细胞状态, C_t 代表当前细胞状态, x_t 代表当前输入。

LSTM 擅长处理时间序列数据,能够学习时间步之间的长期依赖关系,捕捉信号在时间维度上的动态变化模式。针对管道螺旋焊缝缺陷检测场景中信号的非平稳性和噪声干扰问题,LSTM 可以捕捉缺陷位置变化的时序模式,与 CNN 提取的空间特征形成互补,解决传统单分支模型难以兼顾时空特征的问题。再通过优化算法动态搜索 LSTM 单元数、Dropout 率等超参数,模型在复杂工况下仍能保持稳定的时序特征提取能力。

2 动态复合优化模型构建

本文提出基于深度学习框架的动态复合优化检测模型,通过融合 CNN、LSTM 与 WOA,构建一种面向复杂工况的管道螺旋焊缝超声导波信号分析模型,结构如图 4 所示。

模型输入为归一化后的超声导波信号,采用双分支并行结构,分别提取超声导波信号的时空特征,利用 WOA 自适应优化模型关键超参数,融合时空特征并输出结果。CNN 处理模块包含两层一维卷积操作(Conv1D)与最大池(MaxPooling1D),经两次池化压缩后,通过 Flatten 层展开。LSTM 处理模块包含两层 LSTM,与 CNN 模块共享原始信号输入,建模导波传播过程中的衰减特性和周期性干扰的时变规律。WOA 优化模块输出全局最优参数组合,指导模型训练。特征融合模块将 CNN 输出的空间特征向量与 LSTM 输出的时间特征向量进行拼接,形成联合特征,综合缺陷的局部空间模式与全局时序演变规律。经 Dropout 层抑制过拟合后,由线性激活单元输出结果。



图 5 实验装置
Fig. 5 Experimental setup

练集与测试集比例为 8 : 2。

3.2 数据获取

在管道的一端安装 32 kHz 传感器,将此位置定义为原点。利用传感器激发和接收超声导波信号,超声导波信号以时间序列信号的形式呈现。采集无缺陷和位于不同位置有缺陷的超声导波数据,如表 1 所示。包含 254 个无缺陷数据和 1 398 个有缺陷数据,包括在管道距离原点 0.5、1.5、3、4、6、6.7、4、9、10.5 和 12 米处采集不同位置的缺陷数据。

表 1 数据集信息

Table 1 Dataset information

数据集	正常数据	低噪声数据	高噪声数据
时间序列长度	2 068	2 068	2 068
无缺陷数据	44	105	105
有缺陷数据	484	339	575
有缺陷位置	0.5~10.5 m	3~12 m	0.5~6 m

由于导波在管段两端的反射效应,信号序列的边界区域会出现明显的回波现象,如图 6 所示。在管道缺陷位置,序列信号会呈现显著异常特征。值得注意的是,由于管道支架、包裹层、温度、检测设备性能等因素,部分信号中存在噪声,如图 7 所示,实线框表示缺陷位置的导波信号,虚线框表示含有噪声的信号。采集包含高噪声干扰、低噪声干扰及正常工况 3 类数据集,原始数据存储为 CSV 格式。

3.3 评价指标

对每种数据集进行分类任务和回归任务。分类任务的目的是根据超声导波信号判断管道上是否存在缺陷,回归任务的主要目标是预测有缺陷管道上缺陷所在的位置。

1) 分类评价指标

使用准确率(ACC)、曲线下面积(AUC)和 F1 分数作为模型的任务评估指标。计算公式为:

$$ACC = \frac{TP + TN}{TP + FP + FN + TN} \tag{8}$$




图 4 模型结构
Fig. 4 Model structure

3 实验研究

3.1 实验平台

1) 实验装置

采用泰安市管道检测中心的设备 MsSR3030R 检测螺旋焊缝管道,获取管道内的超声导波信号。实验装置如图 5 所示,螺旋钢管材质为 Q235B,弹性模量为 210 GPa,泊松比为 0.33,密度为 7 850 kg/m³。钢管长度为 12 m,外径为 219 mm,壁厚为 5.5 mm,螺旋缝间距为 760 mm。管道缺陷裂纹一般为长为 2 cm,宽为 1 mm,深为 3 mm。实验中使用不同的圆弧形质量块,通过耦合剂粘贴在管道外壁来改变管道的结构,来模拟管道中的缺陷。设备可以激发 T(0,1)模态,选择 32 kHz 作为激励频率。

2) 实验环境

操作系统为 Windows11,编程语言采用 Python3.6.4 并在开发环境 PyCharm 2023.3.2 版本中实现代码编写。

参数设置:训练轮次为 100 轮,批量大小设定为 32,训




图 6 无缺陷管道的导波信号

Fig. 6 Guided wave signals of the defect-free pipeline




图 7 含有缺陷和噪声的导波信号

Fig. 7 Guided wave signals containing defects and noise

$$F_1 = 2 \times \frac{TP}{2TP + FP + FN} \tag{9}$$

其中,TP 为正确预测为正样本的数量,TN 为正确预测为负样本的数量,FP 为错误预测为正样本的负样本数量,FN 为错误预测为负样本的正样本数量。

2)回归评价指标

使用平均绝对误差(mean absolute error, MAE)、均方误差(mean squared error, MSE)和决定系数 R^2 作为模型的回归任务评价指标。计算公式为:

$$MAE(y, \hat{y}) = \frac{1}{m} \sum_{i=1}^n |y_i - \hat{y}_i| \tag{10}$$

$$MSE(y, \hat{y}) = \frac{1}{m} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \tag{11}$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{\sum_{i=1}^n (\bar{y} - y_i)^2} \tag{12}$$

其中, m 是样本数量, y_i 是真实值, $\hat{y}_i$ 是预测值, $\bar{y}$ 为样本均值。

3.4 分类实验

依据采集的数据集特征,分别进行动态复合优化模型高噪声、低噪声和正常数据分类任务实验。

1)高噪声数据分类任务

在高噪声数据条件下,动态复合优化模型的分类任务 ACC 和 AUC 曲线如图 8 所示,包括训练和验证过程的变化情况。从 AUC 曲线可以看出,模型在训练初期便展现出了良好的区分能力,AUC 值迅速攀升并趋于稳定,同时,ACC 曲线呈现逐渐上升的趋势,当迭代次数达到 60 轮后,模型的 ACC 曲线平稳,表明模型在高噪声复杂工况下具有出色的分类性能。值得注意的是,模型在高噪声环境

下的表现并未出现明显的过拟合现象,训练曲线和验证曲线始终保持接近的走势,这得益于在模型中引入的 Dropout 机制以及 WOA 优化算法对超参数的合理调整,使得模型能够在噪声干扰下提取到更具判别力的时空特征。




图 8 ACC 和 AUC 曲线图

Fig. 8 ACC and AUC graphs

为验证模型的有效性,基于高噪声数据集将动态复合优化模型与 LSTM、CNN-LSTM、Transformer 和 SSA-CNN-LSTM 模型进行对比实验,评价指标如表 2 所示。与 LSTM 相比,CNN-LSTM 模型 ACC 提高了 11.58%,AUC 提高了 20.86%,说明引入 CNN 能增强模型捕捉数据中的空间关系,SSA-CNN-LSTM 模型的 ACC 相比于 CNN-LSTM 模型提高了 5.08%,但略逊于新兴的 Transformer 模型,说明优化算法能有效帮助模型选取超参数,但仍有提升空间。动态复合优化模型相较于采用 SSA 算法进行参数优化的模型 ACC 提高了 6.12%,说明 WOA 算法能避免陷入局部最优,提高模型检测精度。

表 2 高噪声数据不同模型分类结果对比

Table 2 Comparison of classification results of different models for high-noise data

模型	ACC	AUC	F1
LSTM	0.794	0.791	0.885
CNN-LSTM	0.886	0.956	0.939
Transformer	0.953	0.908	0.975
SSA-CNN-LSTM	0.931	0.980	0.984
动态复合优化模型	0.988	0.997	0.982

2)低噪声和正常数据分类任务

在低噪声和正常数据分类任务中,不同模型的分类结果如表 3 所示。从低噪声数据集的分类结果来看,传统 LSTM 模型的 ACC 仅为 68.4%,其分类性能明显不足,CNN-LSTM 模型的 ACC 达到了 95.2%,相较 LSTM 模型性能有显著提升,Transformer 和 SSA-CNN-LSTM 模型的 ACC 进一步提升,动态复合优化模型的 ACC 达 99.7%,在低噪声数据集上展现出了卓越的分类性能。在正常数据集上,大部分模型的分类性能有所提高但仍存在

较大提升空间,而所提动态复合优化模型的各项指标均达到了满分。

这些结果表明,在低噪声和正常工况下,所提模型能够精准地对管道螺旋焊缝进行检测,有效提升了检测的准确性和可靠性,相较于其他模型展现出了显著的优势。

表 3 低噪声和正常数据不同模型分类结果对比

Table 3 Comparison of classification results of different models with low-noise and normal noise data

模型	数据集	ACC	AUC	F1
LSTM	低噪声数据	0.684	0.784	0.813
	正常数据	0.886	0.711	0.940
CNN-LSTM	低噪声数据	0.952	0.994	0.971
	正常数据	0.964	0.976	0.968
Transformer	低噪声数据	0.977	0.936	0.984
	正常数据	0.983	0.872	0.992
SSA-CNN-LSTM	低噪声数据	0.986	0.996	0.985
	正常数据	0.982	1.000	0.997
动态复合优化模型	低噪声数据	0.997	1.000	0.994
	正常数据	1.000	1.000	1.000

3.5 回归实验

依据采集的数据集特征,分别对高噪声、低噪声和正常数据开展动态复合优化模型的回归实验。

1)高噪声数据回归任务

在高噪声数据条件下,动态复合优化模型的回归任务的 MSE 和 MAE 曲线如图 9 所示,涵盖了训练过程及验证过程中的动态变化趋势。在训练初期,模型的 MSE 和 MAE 值相对较高,这是由于模型需要先对高噪声数据中的复杂信息进行初步的感知与适应。但随着训练的推进,CNN 与 LSTM 的协同作用逐渐发挥出来,CNN 精准地提取数据的空间特征,LSTM 则深入挖掘时间序列信息,二者有机融合为模型提供了更全面、更高质量的特征表示。随着训练迭代的进行,训练曲线与验证曲线均呈现出稳定的下降态势,并逐渐稳定在较低的值附近,且曲线走势较为接近,没有出现明显的偏离或背离现象,验证了模型在处理高噪声数据时的稳健性,表明其不存在显著的过拟合或欠拟合问题,具备良好的泛化能力。

在高噪声数据回归任务中,通过对比不同模型的回归性能,可以清晰地看到所提动态复合优化模型的优势。如表 4 所示,传统的 LSTM 模型在 MSE 上表现为 1.481 9,当组合为 CNN-LSTM 模型时性能有所提升,MSE 降低了 17.59%, R^2 提高了 4.21%,进一步采用 SSA-CNN-LSTM 模型后,MSE 下降了 34.10%,MAE 下降了 16.72%。Transformer 尽管有较低的 MSE,但 R^2 仍表现不足。动态复合优化模型在各项指标上均展现了明显的优势,MSE




图 9 MSE 和 MAE 曲线图
Fig. 9 MSE and MAE graphs

仅为 0.195 5,MAE 降为 0.346 6, R^2 提升至 0.985 3。这表明动态复合优化模型在处理高噪声数据时,相比其他模型能够更精准地进行回归预测,有效降低了误差,并且对数据的拟合能力更强,充分证明了该模型在复杂噪声环境下的优越性和有效性。

表 4 高噪声数据不同模型回归结果对比

Table 4 Comparison of regression results of different models for high-noise data

模型	MSE	MAE	R^2
LSTM	1.481 9	0.969 3	0.805 6
CNN-LSTM	1.221 3	0.866 9	0.839 8
Transformer	0.432 6	0.578 3	0.879 5
SSA-CNN-LSTM	0.804 7	0.722 0	0.939 4
动态复合优化模型	0.195 5	0.346 6	0.985 3

2)低噪声和正常数据回归任务

在低噪声和正常数据回归任务中,不同模型的回归结果如表 5 所示。相较于其他模型,动态复合优化模型的 MSE 和 MAE 值显著降低,说明模型在对低噪声和正常数据进行回归预测时,预测值与真实值之间的偏差更小,数据拟合效果更为精准,预测结果更具可靠性。同时,较高的 R^2 分数表明模型能够更好地解释数据中的变异性,对数据的特征捕获和表达能力更强。值得注意的是,尽管所有模型在低噪声及正常数据上的性能均优于高噪声环境,但动态复合优化模型展现出的性能优势远高于其他模型,这验证了模型本身的有效性。得益于优化的深度时空融合架构,模型在低噪声和理想工况下,实现了对管道螺旋焊缝超声导波信号的高精度、高稳定性回归预测,各项评价指标均全面超越对比模型,证明了所提方法在复杂但非极端干扰环境下的优越性能。

3.6 消融实验

为验证模型各个部分的有效性,在高噪声数据条件下分别在相同的实验条件下改变模型,分为无 WOA 模块、无 CNN 模块、无 LSTM 模块和原模型,评价指标为 ACC、AUC、MSE 和 MAE,消融实验结果如表 6 所示。

表 5 低噪声和正常数据不同模型回归结果对比

Table 5 Comparison of regression results of different models with low-noise and normal noise data

模型	数据集	MSE	MAE	R ²
LSTM	低噪声数据	0.735	0.632	0.823
	正常数据	1.537	0.808	0.874
CNN-LSTM	低噪声数据	1.482	0.870	0.878
	正常数据	1.232	0.843	0.907
Transformer	低噪声数据	0.371	0.468	0.956
	正常数据	0.176	0.345	0.961
SSA-CNN-LSTM	低噪声数据	0.406	0.586	0.945
	正常数据	0.342	0.481	0.974
动态复合	低噪声数据	0.177	0.330	0.986
优化模型	正常数据	0.095	0.233	0.990

表 6 消融实验结果对比

Table 6 Comparison of ablation study results

模型	ACC	AUC	MSE	MAE
无 WOA 模块	0.904	0.968	1.550	0.846
无 CNN 模块	0.939	0.965	3.826	1.626
无 LSTM 模块	0.794	0.986	0.789	0.714
原模型	0.988	0.997	0.196	0.347

从表 6 中可以看出,原模型凭借完整的结构,在所有指标上均展现出最优性能,表明其对参数扰动与结构扰动具备强鲁棒性,移除任一模块均导致性能显著退化,凸显了整体设计的有效性。移除 CNN 模块对预测精度造成了最严重的损害,MSE 和 MAE 分别激增至 3.826 和 1.626,远高于原模型的 0.196 和 0.347,凸显其空间特征提取对性能鲁棒性的关键作用。移除 LSTM 模块则导致 ACC 大幅下降至 0.794,说明因无法捕捉长期依赖关系,破坏了时序特征的稳定鲁棒性。移除 WOA 模块虽然对 AUC 影响相对较小,但也使得 ACC 降至 0.904,并导致 MSE 和 MAE 上升,证实了其在优化模型参数和提升整体稳定性方面的价值。通过该表,可以看出不同模块在原模型中的高度协同性与互补性,三者共同构成了模型卓越性能的基础。

4 结 论

针对复杂工况下管道螺旋焊缝检测特征提取难、参数优化效率低的问题,本文结合了深度学习方法和智能优化策略,构建了动态复合优化检测模型实现对螺旋焊缝管道的识别与定位。采用双分支并行结构同步处理归一化超声导波信号,兼顾了信号的局部空间特征与长期时序依赖关系,引入优化算法实现关键超参数的自适应寻优,实现模型参数组合的动态优化,通过特征融合与噪声抑制,实现缺陷空间分布与时序传播特征的多维度联合诊断。对

比实验在高噪声、低噪声和正常数据集上的结果显示,模型在不同工况下的准确率均表现优异,均方误差显著降低,充分验证了其在复杂工况,尤其是高噪声、多干扰环境下的卓越检测性能。在螺旋焊缝管道检测领域目前相关研究较少的情况下,从理论上为基于超声波的螺旋焊缝管道检测提供了可靠的方法与依据,未来可考虑引入更多材质管道、极端温压环境等工业场景的超声导波信号,提升模型的适应性。

参考文献

[1] SUN Y SH, ZHONG W B, LI Y H, et al. A defect detection method of drainage pipe based on improved YOLOv5s [J]. Communications in Computer and Information Science, 2024: 144-155, DOI: 10. 1007/978-981-97-0827-7_13.

[2] 蒋仲安,郑登锋,曾发镔,等. 基于危险源理论的油气管道安全管理模型的研究[J]. 湖南大学学报(自然科学版),2021,48(4): 56-65.

JIANG ZH AN, ZHENG D F, ZENG F B, et al. Research on the safety management model of oil and gas pipelines based on hazard source theory [J]. Journal of Hunan University (Natural Science Edition),2021,48(4): 56-65.

[3] 刘 轩,吕 炎,边 策,等. 管道电磁超声传感器阵列检测技术研究[J]. 电子测量与仪器学报,2023,37(11): 24-32.

LIU X, LYU Y, BIAN C, et al. Research on pipeline electromagnetic ultrasonic sensor array detection technology[J]. Journal of Electronic Measurement and Instrumentation,2023,37(11):24-32.

[4] 胡晓谔,林霆威,张维焯,等. 水载压力对管道超声导波信号的影响研究[J]. 仪器仪表学报,2024,45(3): 206-213.

HU X D, LIN T W, ZHANG W X, et al. Research on the influence of water load pressure on ultrasonic guided wave signal of pipeline[J]. Chinese Journal of Scientific Instrument, 2024,45(3):206-213.

[5] ZHAO Q, LI L, ZHANG L H, et al. Recognition of corrosion state of water pipe inner wall based on SMA-SVM under RF feature selection[J]. Coatings, 2023, 13(1):26.

[6] 郑炎辉,张力澜,田兆伟,等. 基于随机森林和 RBF 人工神经网络模型的新丰江水库枯季入库径流中长期预报[J]. 人民珠江,2020,41(5):33-37.

ZHENG Y H, ZHANG L L, TIAN ZH W, et al. Medium and long-term forecast of dry season inflow runoff of xinfeng river reservoir based on random forest and RBF artificial neural network model [J] People's Pearl River,2020,41(5):33-37.

- [7] 符前坤,李强,冉文荣,等.基于图像处理和机器学习的PE管道缺陷检测[J].现代电子技术,2024,47(21):59-66.
FU Q K, LI Q, RAN W SH, et al. Defect detection of PE pipes based on image processing and machine learning[J]. Modern Electronics Technology, 2024,47(21):59-66.
- [8] 陆绮荣,丁昕,梁雅雯.基于改进YOLOX的地下排水管道缺陷识别算法[J].电子测量技术,2022,45(21):161-168.
LU Q R, DING X, LIANG Y W. Defect recognition algorithm for underground drainage pipes based on improved YOLOX [J]. Electronic Measurement Technology,2022,45(21):161-168.
- [9] TAYE M M. Theoretical understanding of convolutional neural network:Concepts, architectures, applications, future directions[J]. Computation,2023,11(3):52.
- [10] SHERSTINSKY A. Fundamentals of recurrent neural network(RNN) and long short-term memory(LSTM) network[J]. Physica D,2020,404:132306.
- [11] 孙洁娣,王利轩,温江涛,等.改进稠密块轻量化神经网络的管道泄漏孔径识别[J].仪器仪表学报,2022,43(3):98-108.
SUN J D, WANG L X, WEN J T, et al. Pipeline leakage aperture recognition based on improved dense block lightweight neural network[J]. Chinese Journal of Scientific Instrument,2022,43(3):98-108.
- [12] YANG D, XIONG M ZH, WANG T, et al. Percussion-based pipeline ponding detection using a convolutional neural network [J]. Applied Sciences, 2022, 12(4): 2127.
- [13] ZHANG J, LI H W, YANG X K, et al. A novel moisture damage detection method for asphalt pavement from GPR signal with CWT and CNN[J]. NDT & E International, 2024: 102935.
- [14] QI Y SH, WANG X H, YANG X Y, et al. Research on acoustic methods for buried PE pipeline detection based on LSTM neural networks [J]. Measurement Science and Technology, 2024,35(9):096001.
- [15] ZHAO L P, WU K Y. Mach number prediction for a wind tunnel based on the CNN-LSTM-attention method[J]. Instrumentation,2023,(4):64-82.
- [16] 梁海波,王怡.基于深度学习的天然气钢制管道缺陷检测方法研究[J].电子测量与仪器学报,2022,36(9):148-158.
LIANG H B, WANG Y. Research on defect detection method of natural gas steel pipelines based on deep learning[J]. Journal of Electronic Measurement and Instrumentation,2022,36(9): 148-158.
- [17] LI W X, LAW K L E. Deep learning models for time series forecasting: A review[J]. IEEE Access, 2024, 12:92306-92327.
- [18] 李珺,徐秦.面向特征选择任务的改进蜣螂优化算法[J].电子测量技术,2024,47(1):79-86.
LI J, XU Q. Improved dung beetle optimization algorithm for feature selection task [J]. Electronic Measurement Technology, 2024,47(1):79-86.
- [19] 方志,余粟.基于IGA-Optuna-LightGBM的民航潜在旅客预测[J].国外电子测量技术,2022,41(10):142-147.
FANG ZH, YU S. Civil aviation potential passenger prediction based on IGA-Optuna-LightGBM [J]. Foreign Electronic Measurement Technology, 2022, 41(10):142-147.
- [20] LI Q, SHI Y R, LIN R Q, et al. A novel oil pipeline leakage detection method based on the sparrow search algorithm and CNN [J]. Measurement, 2022, 202: 111802.
- [21] 邢海燕,王松弘泽,弋鸣,等.基于IPSO-GRU深度学习算法的海底管道缺陷尺寸磁记忆定量反演模型[J].工程科学学报,2022,44(5):911-919.
XING H Y, WANG S H Z, YI M, et al. Quantitative inversion model of submarine pipeline defect size magnetic memory based on IPSO-GRU deep learning algorithm[J]. Journal of Engineering Sciences, 2022, 44(5):911-919.
- [22] LEE CH Y, ZHUO G L. A hybrid whale optimization algorithm for global optimization[J]. Mathematics, 2021, 9(13): 1477.

作者简介

张俊红(通信作者),博士,副教授,硕士研究生导师,主要研究方向为控制理论与技术、电力电子技术。

E-mail:zhangjunhong@bucea.edu.cn

曲鹤,硕士研究生,主要研究方向为目标检测和深度学习。

E-mail:747746047@qq.com

潘惊涛,硕士研究生,主要研究方向为目标检测和深度学习。

E-mail:1012664169@qq.com

杨松,博士生,主要研究方向为无损检测。

E-mail:zybc_yangsong@163.com

李凌宇,硕士研究生,主要研究方向为图像识别。

E-mail:2108540624012@stu.bucea.edu.cn