

文章编号: 1671-251X(2025)07-0149-09

DOI: 10.13272/j.issn.1671-251x.2025050057

基于 CNN-LSTM 的透射槽波勘探走向断层预测研究

周官群¹, 薛凯文¹, 张维鑫¹, 高永新², 金学良^{3,4}, 王宗涛⁵, 任川⁵, 王亚飞¹

(1. 合肥工业大学 资源与环境工程学院, 安徽 合肥 230009; 2. 合肥工业大学 土木与水利工程学院, 安徽 合肥 230009; 3. 淮北矿业(集团)有限责任公司, 安徽 淮北 235000;
4. 中国矿业大学 资源与地球科学学院, 江苏 徐州 221116;
5. 安徽惠洲地质安全研究院股份有限公司, 安徽 合肥 231200)

摘要: 透射槽波地震勘探是探测工作面地质构造和灾害体的有效手段, 但存在探测深度浅、分辨率低、易受地形与环境噪声干扰等问题。针对该问题, 将深度学习技术引入透射槽波地震勘探, 用于实现工作面走向断层位置预测。建立工作面走向断层地质模型, 采用弹性波有限差分算法进行槽波正演模拟, 生成槽波模拟数据集。构建卷积神经网络-长短期记忆(CNN-LSTM)网络模型, 通过 CNN 提取槽波数据的局部特征, 由 LSTM 网络捕捉槽波数据的时序依赖关系, 实现槽波时空特征协同解析。采用槽波模拟数据集训练 CNN-LSTM 模型, 预测的均方根误差为 4.393 4 m, 平均绝对误差为 2.987 5 m, 决定系数为 0.988 3, 验证了该模型具有较高的预测精度和较好的泛化能力。采用内蒙古某矿 506 工作面透射槽波勘探数据对 CNN-LSTM 模型进行迁移训练和验证, 结果表明该模型预测的断层位置和走向与回采揭露的实际位置一致, 预测效果优于槽波能量衰减成像、无线电坑透探测技术。

关键词: 工作面地质勘探; 断层预测; 断层定位; 透射槽波; 卷积注意力长短期记忆网络; CNN-LSTM

中图分类号: TD178

文献标志码: A

Prediction of strike-slip fault using transmitted in-seam wave exploration based on CNN-LSTM

ZHOU Guanqun¹, XUE Kaiwen¹, ZHANG Weixin¹, GAO Yongxin², JIN Xueliang^{3,4},
WANG Zongtao⁵, REN Chuan⁵, WANG Yafei¹

(1. School of Resources and Environmental Engineering, Hefei University of Technology, Hefei 230009, China;
2. College of Civil Engineering, Hefei University of Technology, Hefei 230009, China;
3. Huaibei Mining Industry(Group) Co., Ltd., Huaibei 235000, China;
4. School of Resources and Geosciences, China University of Mining and Technology, Xuzhou 221116, China;
5. Anhui Huizhou Geology Security Institute Co., Ltd., Hefei 231200, China)

Abstract: Transmitted in-seam wave seismic exploration is an effective method for detecting geological structures and hazardous bodies in working faces, but it suffers from problems such as shallow exploration depth, low resolution, and susceptibility to terrain and environmental noise. To address these issues, deep learning technology was introduced into transmitted in-seam wave seismic exploration to predict the location of strike-slip faults in working faces. A geological model of the strike-slip fault in the working face was established, and the elastic wave finite difference algorithm was used to perform forward modeling of in-seam waves to generate a simulation dataset. A Convolutional Neural Network-Long Short-Term Memory (CNN-LSTM) model was constructed. CNN was used to extract local features of the in-seam wave data, and LSTM was used to capture the temporal dependencies in the in-seam wave data, thereby achieving collaborative analysis of spatiotemporal

收稿日期: 2025-05-17; 修回日期: 2025-07-20; 责任编辑: 李明。

基金项目: 国家自然科学基金面上资助项目 (42174084)。

作者简介: 周官群 (1980—), 男, 安徽合肥人, 教授, 博士研究生导师, 研究方向为矿井地球物理勘探, E-mail: guanqunzhou@126.com。通信作者: 王亚飞 (1995—), 男, 安徽六安人, 博士研究生, 研究方向为矿井地球物理勘探, E-mail: 2247475667@qq.com。

引用格式: 周官群, 薛凯文, 张维鑫, 等. 基于 CNN-LSTM 的透射槽波勘探走向断层预测研究[J]. 工矿自动化, 2025, 51(7): 149-157.
ZHOU Guanqun, XUE Kaiwen, ZHANG Weixin, et al. Prediction of strike-slip fault using transmitted in-seam wave exploration based on CNN-LSTM[J]. Journal of Mine Automation, 2025, 51(7): 149-157.



扫码移动阅读

features. The CNN-LSTM model was trained using the in-seam wave simulation dataset. The predicted root mean square error was 4.393 4 m, the mean absolute error was 2.987 5 m, and the coefficient of determination was 0.988 3, verifying the model's high prediction accuracy and good generalization capability. The CNN-LSTM model was then fine-tuned using transfer learning and validated using transmitted in-seam wave exploration data from the 506 working face of a mine in Inner Mongolia. The results showed that the predicted fault location and strike were consistent with the actual position revealed by mining, and the prediction performance was better than that of the in-seam wave energy attenuation imaging and radio borehole penetration detection technologies.

Key words: working face geological exploration; fault prediction; fault location; transmitted in-seam wave;; convolutional neural network-attention-long short-term memory; CNN-LSTM

0 引言

我国作为煤炭资源赋存大国,主要矿区普遍处于复杂地质构造带。在采掘作业中,隐伏断层、异常应力区等地质异变体频繁显现,严重制约安全生产效能。随着开采活动向深部持续延伸,工程地质条件日趋复杂化,煤层赋存环境呈现显著的非均质特征。为保障煤炭安全生产,迫切需要查明煤矿工作面的地质情况^[1]。

透射槽波地震勘探是专为矿井设计的高分辨率勘探技术。其采用透射观测方式,一侧激发,对侧接收,通过分析穿透目标区的槽波信号,如走时延迟、振幅衰减、频率吸收等变化,实现对煤层内及顶底板附近地质构造和灾害体的有效探测与成像^[2]。国内外学者针对传统透射槽波地震勘探开展了大量研究。姬广忠等^[3-4]将构造影响等效于介质吸收作用,求解介质衰减系数,并进行槽波衰减系数成像,在探测断层、煤层厚度变化的实际应用中取得了良好效果。胡泽安等^[5]提出拟 2.5 维的槽波地震速度层析技术方案,在地震波速度层析成像中加入高程参数,使射线追踪的旅行路径更准确,速度计算结果更符合实际。田瀚等^[6]创新性地提出利用槽波质心频率变化特征进行反演成像的方法,避免了震源差异性和震源质心频率人为选择不当对成像结果造成的影响。Han Jianguang 等^[7]通过对不同倾角和断距的 3 维煤层断层模型进行高斯光束求和(Gaussian Beam Summation, GBS)偏移试验,验证了所提煤层反射波成像方法的可行性和有效性,并对该方法进行了实际应用。Wu Yanhui 等^[8]提出了波谱视差特征和速度成像方法,可有效提高塌陷柱边界定位的准确度和精度。

上述研究对传统透射槽波地震勘探方法进行改进并取得了一定效果,但仍存在探测深度浅、分辨率低、易受地形与环境噪声干扰等缺点^[9]。对此,本文将深度学习技术引入透射槽波地震勘探中,利用其在特征提取、模式识别及非线性建模方面的优势,以期实现对地下结构更高效、更精准的探测。目前深度学习在透射槽波地震勘探中的应用尚属空白,但在地表塌陷预测、微震识别等勘探技术领域已得到

应用并取得良好的效果,如:高墨通等^[10]采用卷积注意力长短期记忆(Convolutional Neural Network-Attention-Long Short-Term Memory, CNN-Attention-LSTM)网络,有效解决了采空区地表塌陷区域时序预测中存在的监测点空间特征难以提取的问题;Peng Ping'an 等^[11]采用遗传算法优化的特征选择方法,从 35 个时频域特征中筛选出 11 个关键特征,将其构建为特征矩阵输入卷积神经网络(Convolutional Neural Network, CNN),提升了微震事件的识别精度;Li Kewen 等^[12]提出了基于同步压缩变换的断层识别(Fault Segmentation Synchrosqueezed Transform, Fault-Seg-SST)模型,通过地震反射波构建的地震剖面图像数据进行断层识别,可实现细粒度的断层分割。

本文基于已有研究成果,采用深度学习技术预测透射槽波地震勘探的工作面走向断层位置,通过 CNN 提取槽波数据的局部特征,由 LSTM 网络捕捉槽波数据的时序依赖关系,实现对槽波激发点前方断层位置的准确预测。

1 模拟数据集建立

1.1 透射槽波模拟

为了获得训练深度学习算法所需要的数据集,构建岩-煤-岩 3 层地质构造数值模型(图 1),进行透射槽波正演模拟。模型尺寸为 300 m×200 m×100 m(长×宽×高)。煤层位于高度方向(z 方向)正中位置,煤层厚度为 10 m,顶底板岩性相同。

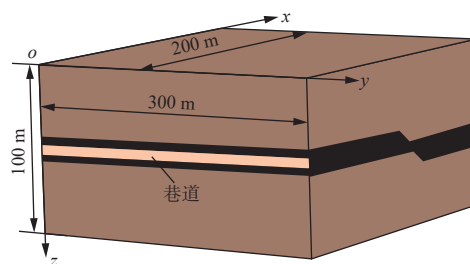


图 1 3 层地质构造数值模型

Fig. 1 Numerical model of a three-layer geological structure

模型中设置断层位于宽度方向(x 方向)30, 60, 90, 120, 150, 180 m 处。每种断层位置的模型中,分

别设置断层断距为 3, 5, 8 m, 断层倾角均为 45° 。在此基础上, 设置 2 种断层走向: ① 平行于模型长度方向(y 方向); ② 与 y 方向夹角为 10° 。由此构建 36 个断层模型^[13-14]。

透射槽波采用单发多收方式, 双巷布置激发点和接收点, 如图 2 所示。每个模型设置 10 个激发点, 间距为 30 m, 依次发射主频 120 Hz 的 Ricker 子波, 时间间隔为 2 s; 设置 30 个接收点, 沿煤层布置, 间距为 10 m。采用完美匹配层(Perfectly Matched Layer, PML)作为模型吸收边界^[15-16]。

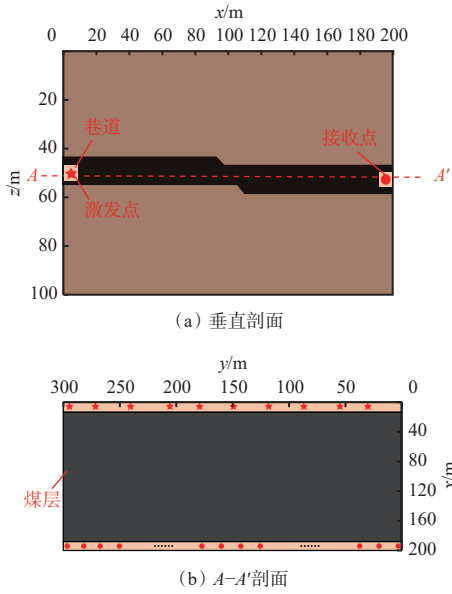


图 2 槽波激发点和接收点布置
Fig. 2 Arrangement of excitation and receiving points of in-seam wave

采用弹性波有限差分算法进行槽波正演模拟。三维各向同性介质中一阶速度-应力弹性波方程为^[17]

$$\begin{cases} \frac{\partial V_x}{\partial t} = \frac{1}{\rho} \left(\frac{\partial \sigma_{xx}}{\partial x} + \frac{\partial \sigma_{xy}}{\partial y} + \frac{\partial \sigma_{xz}}{\partial z} \right) \\ \frac{\partial V_y}{\partial t} = \frac{1}{\rho} \left(\frac{\partial \sigma_{yx}}{\partial x} + \frac{\partial \sigma_{yy}}{\partial y} + \frac{\partial \sigma_{yz}}{\partial z} \right) \\ \frac{\partial V_z}{\partial t} = \frac{1}{\rho} \left(\frac{\partial \sigma_{zx}}{\partial x} + \frac{\partial \sigma_{zy}}{\partial y} + \frac{\partial \sigma_{zz}}{\partial z} \right) \\ \frac{\partial \sigma_{xx}}{\partial t} = (\lambda + 2\mu) \frac{\partial V_x}{\partial x} + \lambda \frac{\partial V_y}{\partial y} + \lambda \frac{\partial V_z}{\partial z} \\ \frac{\partial \sigma_{yy}}{\partial t} = \lambda \frac{\partial V_x}{\partial x} + (\lambda + 2\mu) \frac{\partial V_y}{\partial y} + \lambda \frac{\partial V_z}{\partial z} \\ \frac{\partial \sigma_{zz}}{\partial t} = \lambda \frac{\partial V_x}{\partial x} + \lambda \frac{\partial V_y}{\partial y} + (\lambda + 2\mu) \frac{\partial V_z}{\partial z} \\ \frac{\partial \sigma_{xy}}{\partial t} = \mu \left(\frac{\partial V_x}{\partial y} + \frac{\partial V_y}{\partial x} \right) \\ \frac{\partial \sigma_{yz}}{\partial t} = \mu \left(\frac{\partial V_y}{\partial z} + \frac{\partial V_z}{\partial y} \right) \\ \frac{\partial \sigma_{xz}}{\partial t} = \mu \left(\frac{\partial V_x}{\partial z} + \frac{\partial V_z}{\partial x} \right) \end{cases} \quad (1)$$

式中: V_x, V_y, V_z 分别为槽波沿 x, y, z 方向的传播速度; t 为槽波的传播时间; ρ 为煤层密度; $\sigma_{xx}, \sigma_{yy}, \sigma_{zz}$ 分别为 x, y, z 方向的正应力; $\sigma_{xy}, \sigma_{xz}, \sigma_{yx}, \sigma_{yz}, \sigma_{zx}, \sigma_{zy}$ 为剪应力; λ, μ 为拉梅参数。

正演模拟过程中设计 3 组速度, 见表 1。设置时间采样间隔为 1 ms, 采样时长为 0.8 s^[18]。

表 1 煤层和围岩波速设置

编号	煤层波速		围岩波速	
	纵波	横波	纵波	横波
1	2 300	1 300	3 800	2 300
2	2 100	1 200	3 400	1 200
3	1 900	1 100	3 300	2 000

1.2 模拟数据处理

为确保输入槽波数据的多样性和一致性, 提高模型预测的鲁棒性和准确性, 对获取的模拟数据进行以下处理。

1) 加入随机噪声。在模拟槽波数据中加入高斯噪声, 信噪比控制在 25 dB。一方面使模拟数据更接近真实值, 另一方面实现模拟数据增强。由此构成一个包含模拟数据和加噪数据的模拟数据集, 其有 66 942 列波形数据^[19]。

2) 数据归一化。在大规模数据分析中, 由于数据来源不同, 导致维度与量纲存在差异, 需通过标准化方法消除量纲差异造成的偏差。经标准化处理后, 各指标数值被规范至相同量级范围, 方便进行全方面评估^[20]。本文采用最小-最大归一化方法, 将输入数据映射到 $[-1, 1]$ 范围内, 并通过线性变换方式对数据进行缩放。

2 断层预测模型

CNN 的核心为卷积层。每个卷积核的独立参数矩阵通过局部感受野的滑动计算, 实现空间特征的定位提取。本文中卷积操作是在 1 维槽波数据上滑动^[21], 因此, 采用宽卷积核表达式:

$$Y_{l+1}(n) = w_{lm} X_l(n) + b_{lm} \quad (2)$$

式中: $Y_{l+1}(n)$ 为第 $l+1$ 层卷积层的第 n 个输出值; w_{lm} 为第 l 层卷积层第 m 个卷积核的权重向量; $X_l(n)$ 为第 l 层卷积层第 n 个输入值; b_{lm} 为卷积层的偏置项。

LSTM 网络是循环神经网络 (Recurrent Neural Network, RNN) 的改进型架构, 采用门控时序反馈机制解决传统 RNN 在序列建模中的梯度消失/爆炸问

题,通过参数化调控信息流实现跨时间步的特征保留与更新^[22]。在地质构造预测中,波形数据通常包含长时间的复杂依赖关系。LSTM网络通过门控机制,可有效保留有用特征,并自适应处理可变长度的输入序列,更好地完成槽波数据的识别预测任务^[23]。

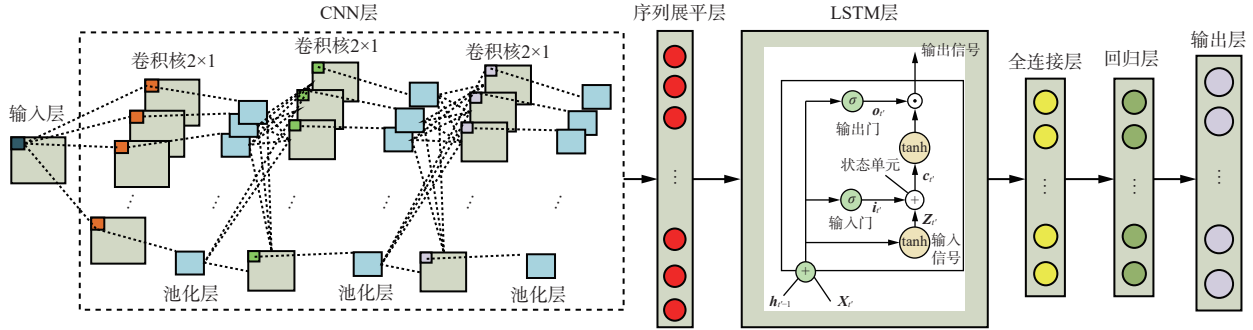


图3 CNN-LSTM 模型结构

Fig. 3 Architecture of CNN-LSTM model

设输入槽波数据 $\mathbf{X} = [X_1 \ X_2 \ \cdots \ X_T]$, T 为总采样时间, X_t 为 t ($t = 1, 2, \dots, T$) 时刻槽波数据。对槽波数据进行卷积操作(式(2)),以提取其局部空间特征和时间变化模式,为后续序列建模与预测任务提供高质量的特征表示。

将 CNN 输出的特征向量输入序列展平层,将多维特征图展开为 1 维向量,作为 LSTM 网络输入 $\mathbf{Z} = [\mathbf{Z}_1 \ \mathbf{Z}_2 \ \cdots \ \mathbf{Z}_T]$, T' 为输入序列的时间长度, $\mathbf{Z}_{t'}$ 为 t' ($t' = 1, 2, \dots, T'$) 时刻输入向量。LSTM 网络状态更新公式为

$$\begin{cases} f_{t'} = \sigma(\mathbf{W}_f \mathbf{Z}_{t'} + \mathbf{U}_f \mathbf{h}_{t'-1} + b_f) \\ i_{t'} = \sigma(\mathbf{W}_i \mathbf{Z}_{t'} + \mathbf{U}_i \mathbf{h}_{t'-1} + b_i) \\ o_{t'} = \sigma(\mathbf{W}_o \mathbf{Z}_{t'} + \mathbf{U}_o \mathbf{h}_{t'-1} + b_o) \\ \tilde{c}_{t'} = \tanh(\mathbf{W}_{\tilde{c}} \mathbf{Z}_{t'} + \mathbf{U}_{\tilde{c}} \mathbf{h}_{t'-1} + b_{\tilde{c}}) \\ \mathbf{c}_{t'} = f_{t'} \odot \mathbf{c}_{t'-1} + i_{t'} \odot \tilde{c}_{t'} \\ \mathbf{h}_{t'} = o_{t'} \odot \tanh(\mathbf{c}_{t'}) \end{cases} \quad (3)$$

式中: $f_{t'}$, $i_{t'}$, $o_{t'}$, $\tilde{c}_{t'}$, $\mathbf{c}_{t'}$ 分别为遗忘门、输入门、输出门、候选记忆单元、当前记忆单元的输出向量; $\sigma(\cdot)$ 为 sigmoid 函数; \mathbf{W}_f , \mathbf{W}_i , \mathbf{W}_o , $\mathbf{W}_{\tilde{c}}$ 分别为 t' 时刻输入向量 $\mathbf{Z}_{t'}$ 对遗忘门、输入门、输出门、候选记忆单元的权重向量; \mathbf{U}_f , \mathbf{U}_i , \mathbf{U}_o , $\mathbf{U}_{\tilde{c}}$ 分别为 $t'-1$ 时刻隐藏状态 $\mathbf{h}_{t'-1}$ 对遗忘门、输入门、输出门、候选记忆单元的权重向量; b_f , b_i , b_o , $b_{\tilde{c}}$ 分别为遗忘门、输入门、输出门、候选记忆单元的偏置项; \odot 为 Hadamard 积符号。

将 LSTM 提取的时间特征通过全连接层映射到回归层,得到输出:

$$\hat{Y} = \mathbf{W}^T \mathbf{h}_T + b \quad (4)$$

式中: \mathbf{W} 为全连接层的权重向量; \mathbf{h}_T 为 LSTM 在最后一个时间步的隐藏状态; b 为全连接层的偏置项。

本文设计的 CNN-LSTM 模型结构如图 3 所示。槽波数据经过 CNN 层的卷积和池化操作后,依次输入序列展平层、LSTM 层、全连接层,最后经回归层进行断层构造空间位置预测,并输出预测结果^[24]。

选择均方误差 (Mean-Square Error, MSE) 作为损失函数:

$$\mathcal{L} = \frac{1}{N} \sum_{n=1}^N (Y_n - \hat{Y}_n)^2 \quad (5)$$

式中: N 为样本总数; Y_n 为第 n 个样本数据的真实值; \hat{Y}_n 为第 n 个样本数据的预测值。

CNN-LSTM 模型实现了 CNN 的局部感受野特征提取与 LSTM 网络的动态时序建模优势协同,能够灵活、精准地应对波形预测中的复杂时序模式和长短期依赖问题^[25]。采用 CNN-LSTM 模型进行断层预测的流程如图 4 所示。

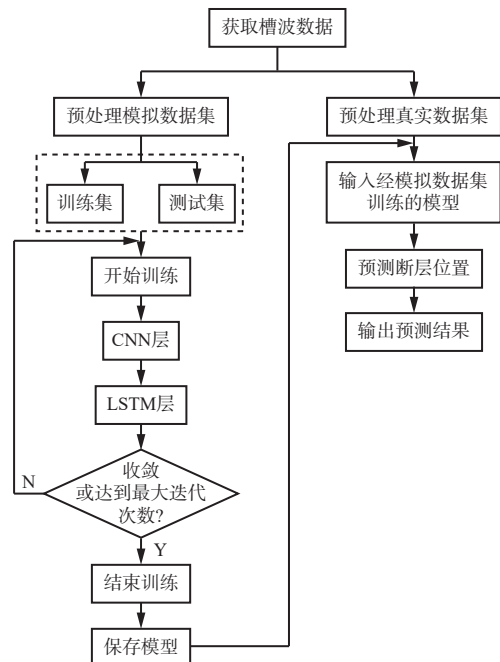


图4 基于 CNN-LSTM 模型的断层预测流程

Fig. 4 Workflow of fault prediction based on CNN-LSTM model

基于 CNN-LSTM 的透射槽波勘探走向断层预测流程整体分为训练与预测两部分。在训练阶段,将构建的模拟槽波数据集输入 CNN-LSTM 模型,提取波形的空间与时间特征,不断迭代直至满足收敛条件,完成模型训练并保存。在预测阶段,将采集的部分现场槽波数据输入模型进行迁移学习训练,使模型更好地适应真实数据,再将采集数据输入训练好的模型,得到断层构造位置(激发点距断层距离)预测结果。

3 实验验证

3.1 模拟数据验证

采用模拟数据集对 CNN-LSTM 模型进行训练和验证。实验平台所用编程语言为 Matlab 2023b,硬件配置见表 2。

表 2 实验平台硬件配置

Table 2 Hardware configurations of experimental platform	
名称	型号
CPU	Intel i7-9750H
GPU	NVIDIA 1660 Ti
内存	三星 8 GiB DDR4 2 667 MHz
磁盘	WDC PC SN720 (1 024 GiB)

模拟数据集按 9:1 的比例随机划分为训练集与测试集,采用向下取整法保证集合中样本数量为整数。模型训练共进行 500 轮,其训练与测试损失曲线如图 5 所示。可看出模型经过约 250 次迭代后收敛,训练集与测试集的损失值均趋近于 0,且二者曲线走势一致,未出现明显过拟合现象,说明模型具有良好的学习与泛化性能。

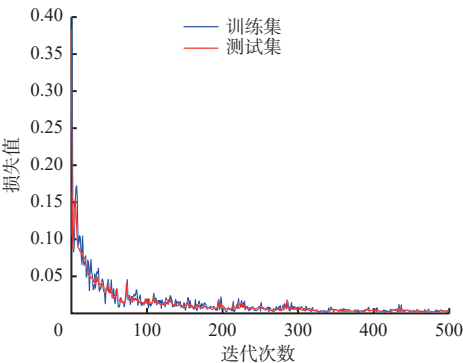


图 5 CNN-LSTM 模型训练曲线
Fig. 5 Training curve of CNN-LSTM model

将激发点设置在上巷,接收点设置在下巷,以断层位于 $x=90\text{ m}$ 处、断层宽度为 8 m 、断层走向平行于 y 轴为例,训练集预测结果如图 6 所示。根据预测值拟合断层位置曲线,结果如图 7 所示。可看出训

练集上大部分样本数据的预测值与实际值误差较小,拟合的断层位置与实际位置基本吻合,验证了所建模型在训练过程中可充分学习波形特征与断层位置之间的非线性映射关系,具有良好的回归性能和空间分辨能力。

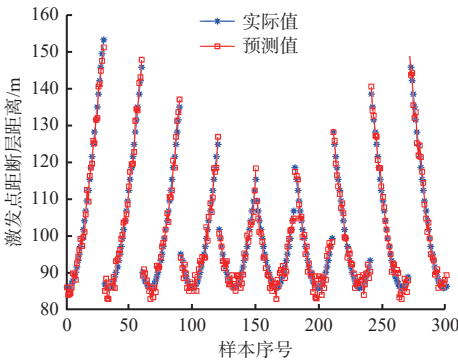


图 6 训练集预测结果
Fig. 6 Comparison of prediction results on training dataset

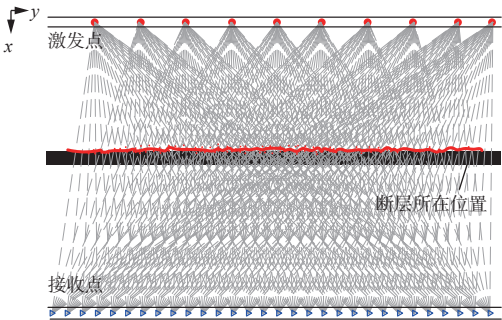


图 7 训练集预测结果拟合曲线
Fig. 7 Fitting curve of prediction results on training dataset

将激发点设置在下巷,接收点设置在上巷,以断层位于 $x=120\text{ m}$ 处、断层宽度为 8 m 、断层走向平行于 y 轴为例,测试集预测结果及其拟合曲线分别如图 8、图 9 所示。可看出测试集中大部分样本的预测误差控制在较小范围内,且拟合的断层位置与实际位置基本吻合。

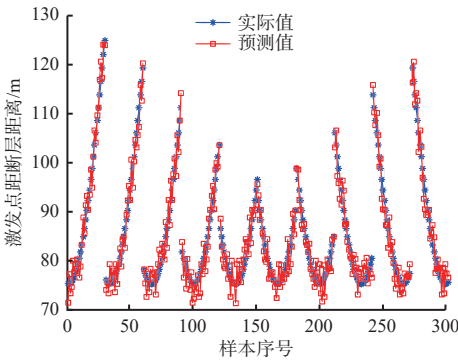


图 8 测试集预测结果
Fig. 8 Prediction results on testing dataset
以均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)、决定系

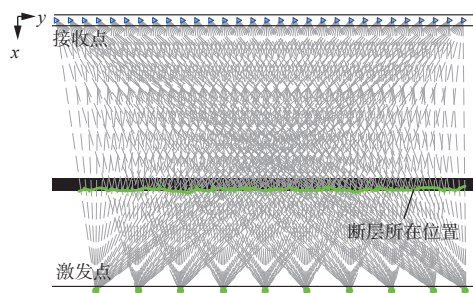


图 9 测试集预测结果拟合曲线

Fig. 9 Fitting curve of prediction results on testing set

数 R^2 作为模型预测结果的评价指标^[26], 结果见表 3。可看出 CNN-LSTM 模型在训练集上的 RMSE 为 4.393 4 m, MAE 为 2.987 5 m, 在测试集上分别为 5.732 2, 3.840 6 m, 表明模型在 2 个数据集上的预测误差均较小; 模型对训练集和测试集的 R^2 分别为 0.988 3 和 0.986 5, 均接近 1, 表明模型能有效学习训练数据的规律, 且具备较强的泛化能力。

表 3 模型评价结果

Table 3 Model evaluation results

数据集	RMSE/m	MAE/m	R^2
训练集	4.393 4	2.987 5	0.988 3
测试集	5.732 2	3.840 6	0.986 5

3.2 真实数据验证

3.2.1 数据来源

真实数据来源于内蒙古某矿 506 工作面。该工作面切眼长度约为 187 m, 掘进 5 号煤层, 煤厚 3.65~5.04 m, 平均厚度为 4.41 m, 煤厚变化较大, 变化规律性较明显, 煤层结构较简单, 含夹矸 1~2 层。在 506 工作面进行透射槽波地震勘探。第 1 次将激发点布置在 506 回风巷, 接收点布置在 506 胶带运输巷; 第 2 次将激发点布置在 506 胶带运输巷, 接收点布置在 506 回风巷。激发点平均间距为 20 m, 接收点平均间距为 10 m。以第 1 次布置为例, 具体如图 10 所示。激发点编号为 P1-1—P1-9, 接收点编号为 J1-1—J1-16。

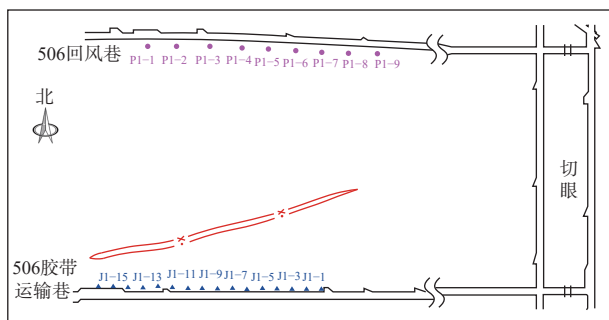


图 10 506 工作面槽波地震勘探现场布置

Fig. 10 Site layout of in-seam wave seismic exploration in 506 working face

勘探共采集 306 个槽波数据, 本文使用其中 256 个数据进行实验。实际采集的槽波数据因受到各种随机因素的干扰, 通常包含许多未知的噪声, 影响模型预测的准确度。因此, 采用小波降噪方法对采集数据进行预处理^[27]。槽波数据降噪前后波形如图 11 所示。可看出降噪后槽波数据的信噪比明显提升。

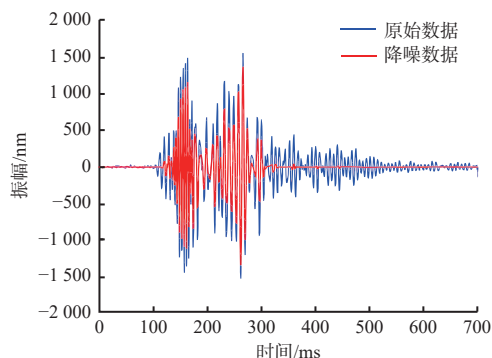


图 11 槽波信号降噪前后波形对比

Fig. 11 Comparison of waveform of in-seam wave data before and after noise reduction

3.2.2 模型迁移学习

采用迁移学习技术将经过模拟数据集训练的 CNN-LSTM 模型应用于真实数据上, 使用少量的真实数据训练模型, 使其适应去噪后的实际采集波形与模拟波形的细节差异。这样可以将从模拟数据中学到的特征迁移到真实数据, 并利用真实数据校正模型, 解决实测数据量不足的问题^[28]。

实验条件和模型参数与模拟实验一致。迁移学习训练流程如图 12 所示。加载经模拟数据集训练的 CNN-LSTM 模型, 将带有标签的数据(占比 50%)输入模型, 冻结 CNN 权重, 通过微调 LSTM 层适应真实数据的时间动态特性, 采用小的学习率(10^{-4})来避免对已有的权重进行大幅度改动。在进行 50 轮学习后, 解冻 CNN 最后 2 个卷积层的权重, 利用未标记标签的数据进行权重调整。结合模拟数据和真实数据训练的 CNN-LSTM 模型具有较高的识别精度和良好的适应性, 可更好地应对矿井地质构造预测任务。

3.2.3 实验结果

采用经迁移学习训练的 CNN-LSTM 模型进行断层构造位置预测。对于第 1 种激发点和接收点布置方式, 模型预测结果如图 13 所示。将预测结果拟合, 得到一条表示断层整体位置的曲线, 如图 14 所示, 其中紫色曲线为拟合结果, 红色圈出部分为断层实际位置(根据出露推断)。可看出预测的断层位置和走向与实际情况基本一致。

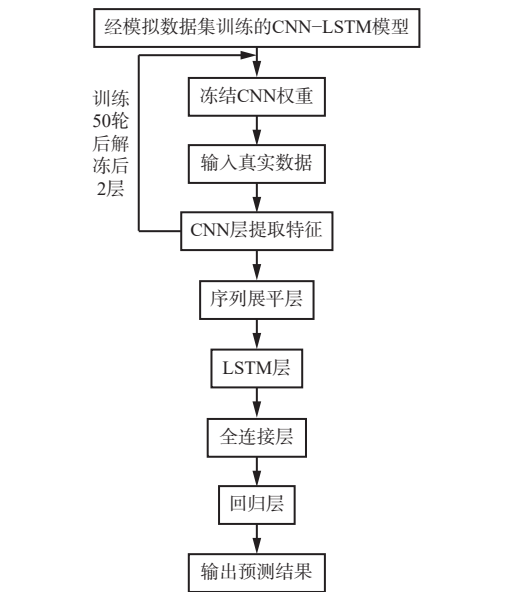


图 12 CNN-LSTM 模型迁移学习训练流程

Fig. 12 Transfer learning process of CNN-LSTM model

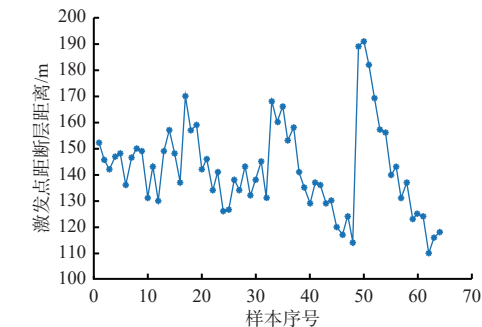


图 13 第 1 种槽波勘探布置方式的断层构造预测结果

Fig. 13 Tectonic fault prediction results for the 1st in-seam wave exploration arrangement

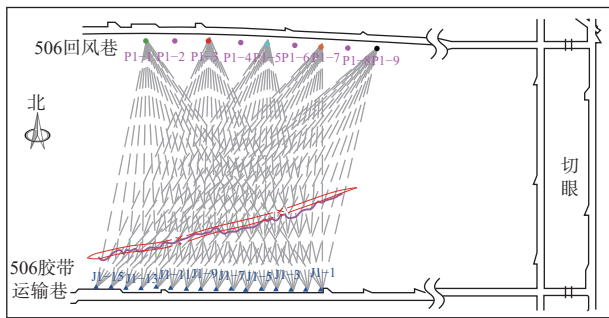


图 14 第 1 种槽波勘探布置方式的断层位置拟合结果

Fig. 14 Fault location fitting results for the 1st in-seam wave exploration arrangement

对于第 2 种激发点和接收点布置方式,模型预测结果如图 15 所示,数据拟合结果如图 16 所示,P2-1—P2-9 为激发点编号,J2-1—J2-18 为接收点编号。可看出模型预测结果与实际情况基本一致。

图 14、图 16 中预测位置拟合结果存在较多的曲线段,推测原因:① 实际地层为非均匀体,槽波在煤层中的传播并非直线,本文将传播路径按直线处理

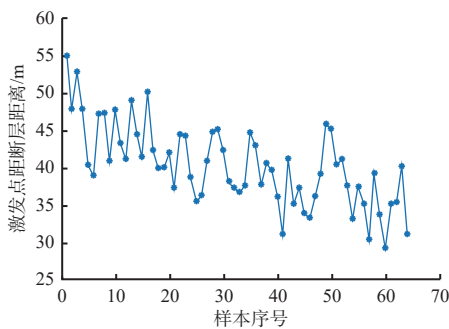


图 15 第 2 种槽波勘探布置方式的断层构造预测结果

Fig. 15 Tectonic fault prediction results for the 2nd in-seam wave exploration arrangement

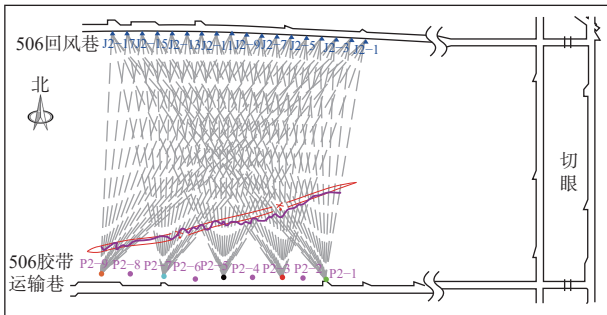


图 16 第 2 种槽波勘探布置方式的断层位置拟合结果

Fig. 16 Fault location fitting results for the 2nd in-seam wave exploration arrangement

会导致一定的误差。② 处理数据过程中,对模拟数据加入随机噪声,对实际数据进行降噪处理,但模拟数据与实际数据仍存在一定差别。在后续研究中,可通过收集其他关于断层构造位置的信息,如频率、相位等,更精确地进行地震正演模拟,提高预测的准确性。

将 CNN-LSTM 模型预测结果与槽波能量衰减成像结果、无线电坑透探测结果、回采揭露的断层实际位置进行比较,结果如图 17 所示。可看出槽波能量衰减成像的探测范围偏大,无线电坑透探测对于断层走向和位置的探测误差较大,CNN-LSTM 模型预测的断层位置与实际位置基本一致,进一步验证了该模型具备良好的断层构造定位能力,以及在复杂地下环境中的适用性和可靠性。

4 结论

- 1) 针对传统地震勘探方法在异常区定位精度不足的技术瓶颈,构建了 CNN-LSTM 模型用于透射槽波勘探中的走向断层预测。该模型融合了 CNN 的局部特征提取与 LSTM 的时序处理优势,实现槽波时空特征协同解析,显著提升了断层构造位置预测精度。
- 2) 建立了断层构造数值模型,采用弹性波有限

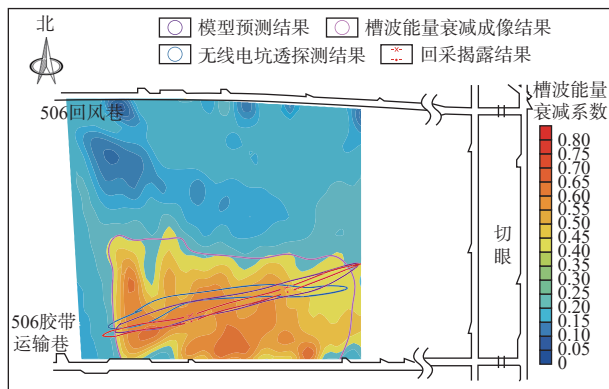


图 17 506 工作面断层探测结果

Fig. 17 Fault detection results in 506 working face

差分法进行地震槽波正演模拟,利用模拟数据集对 CNN-LSTM 模型进行训练和测试。该模型在训练集上的 RMSE, MAE, R^2 分别为 4.393 4 m, 2.987 5 m, 0.988 3, 在测试集上为 5.732 2 m, 3.840 6 m, 0.986 5, 验证了模型具有较高的预测精度和较强的泛化能力。

3) 将 CNN-LSTM 模型应用于内蒙古某矿 506 工作面实际槽波勘探数据预测,经对比分析发现预测结果与实际情况一致,验证了该模型可实现断层构造空间位置的准确预测,为矿井隐蔽致灾地质体的精准探测提供了新的解决方案。

4) 受条件限制,仅构建了针对走向断层的预测模型。未来将针对其他构造或多构造联合预测问题开展进一步研究。

参考文献(References):

- [1] 胡泽安,张平松,许光泉.煤层工作面地震波层析成像技术研究进展[J].地球物理学进展,2017,32(6):2451-2459.
HU Zean, ZHANG Pingsong, XU Guangquan. Research advances of seismic tomography technology in coal seam[J]. Progress in Geophysics, 2017, 32(6): 2451-2459.
- [2] 董守华,黄亚平,金学良,等.煤田高密度三维地震勘探技术的发展现状及趋势[J].煤田地质与勘探,2023,51(2):273-282.
DONG Shouhua, HUANG Yaping, JIN Xueliang, et al. Development status and trend of high-density 3D seismic exploration technology for coal fields[J]. Coal Geology & Exploration, 2023, 51(2): 273-282.
- [3] 姬广忠,程建远,胡继武,等.槽波衰减系数成像方法及其应用[J].煤炭学报,2014,39(增刊2):471-475.
JI Guangzhong, CHENG Jianyuan, HU Jiwu, et al. Imaging method of slot wave attenuation coefficient and its application[J]. Journal of China Coal Society, 2014, 39(S2): 471-475.
- [4] 姬广忠,杨建华,张广学,等.槽波振幅衰减系数 CT 成像技术应用[J].中国煤炭地质,2015,27(9):75-78.
JI Guangzhong, YANG Jianhua, ZHANG Guangxue, et al. Application of in-seam wave amplitude attenuation coefficient CT imaging technology[J]. Coal Geology of China, 2015, 27(9): 75-78.
- [5] 胡泽安,张平松,许光泉.采煤工作面拟 2.5 维地震速度层析成像方法[J].煤炭学报,2018,43(9):2579-2586.
HU Zean, ZHANG Pingsong, XU Guangquan. Pseudo 2.5 dimensional seismic velocity tomography in coal mining face[J]. Journal of China Coal Society, 2018, 43(9): 2579-2586.
- [6] 田瀚,吴荣新,胡泽安,等.透射槽波相邻道质心频率的层析成像方法[J].煤田地质与勘探,2022,50(11):187-194.
TIAN Han, WU Rongxin, HU Zean, et al. Tomography method for adjacent channel frequency shift of transmitted in-seam waves[J]. Coal Geology & Exploration, 2022, 50(11): 187-194.
- [7] HAN Jianguang, LYU Qingtian, ZHANG Zhiheng, et al. Application of Gaussian beam summation migration in reflected in-seam wave imaging[J]. Acta Geologica Sinica (English Edition), 2024, 98(1): 276-284.
- [8] WU Yanhui, ZHU Guowei, WANG Wei. Precise prediction of the collapse column based on channel wave spectral disparity characteristics and velocity tomography imaging[J]. Journal of Geophysics and Engineering, 2022, 19(3): 326-335.
- [9] 郭银景,巨媛媛,范晓静,等.槽波地震勘探研究进展[J].煤田地质与勘探,2020,48(2):216-227.
GUO Yinjing, JU Yuanyuan, FAN Xiaojing, et al. Progress in research of in-seam seismic exploration[J]. Coal Geology & Exploration, 2020, 48(2): 216-227.
- [10] 高墨通,杨维芳,刘祖昱,等.结合卷积神经网络和注意力机制的 LSTM 采空区地表沉降预测方法[J].测绘通报,2024(6):53-58,170.
GAO Motong, YANG Weifang, LIU Zuyu, et al. LSTM goaf surface subsidence prediction method combining convolutional neural network and attention mechanism[J]. Bulletin of Surveying and Mapping, 2024(6): 53-58, 170.
- [11] PENG Ping'an, HE Zhengxiang, WANG Liguan, et al. Automatic classification of microseismic records in underground mining: a deep learning approach[J]. IEEE Access, 2020, 8: 17863-17876.
- [12] LI Kewen, LI Xiao, YIN Ruonan, et al. A method for seismic fault identification based on self-training with high-stability pseudo-labels[J]. Applied Soft Computing, 2024, 163. DOI: 10.1016/J.ASOC.2024.111894.
- [13] 姬广忠,吴荣新,张平松,等.黏弹 TI 煤层介质 3 层模型 Love 槽波频散与衰减特征[J].煤炭学报,2021,46(2):566-577.
JI Guangzhong, WU Rongxin, ZHANG Pingsong, et al.

- Dispersion and attenuation characteristics of Love channel waves in the three-layer model of viscoelastic TI coal seam media[J]. *Journal of China Coal Society*, 2021, 46(2): 566-577.
- [14] 姬广忠, 魏久传, 杨思通, 等. HTI 煤层介质槽波波场与频散特征初步研究[J]. *地球物理学报*, 2019, 62(2): 789-801.
JI Guangzhong, WEI Jiuchuan, YANG Sitong, et al. Preliminary study on wave field and dispersion characteristics of channel waves in HTI coal seam medium[J]. *Chinese Journal of Geophysics*, 2019, 62(2): 789-801.
- [15] 姬广忠, 程建远, 朱培民, 等. 煤矿井下槽波三维数值模拟及频散分析[J]. *地球物理学报*, 2012, 55(2): 645-654.
JI Guangzhong, CHENG Jianyuan, ZHU Peimin, et al. 3-D numerical simulation and dispersion analysis of in-seam wave in underground coal mine[J]. *Chinese Journal of Geophysics*, 2012, 55(2): 645-654.
- [16] 王保利, 金丹, 张唤兰, 等. 煤层中断层的透射槽波定量响应特征[J]. *煤炭学报*, 2022, 47(8): 2985-2991.
WANG Baoli, JIN Dan, ZHANG Huanlan, et al. Quantitative response characteristics of transmitted in-seam channel wave in coal seam with faults[J]. *Journal of China Coal Society*, 2022, 47(8): 2985-2991.
- [17] 呼邦兵, 朱国维, 刘金锁, 等. 掘进煤巷采空区 Rayleigh 型槽波超前探测三维数值模拟研究[J]. *煤炭工程*, 2020, 52(2): 121-125.
HU Bangbing, ZHU Guowei, LIU Jinsuo, et al. Three-dimensional numerical simulation of the Rayleigh channel wave advance detection in the goaf of coal roadway[J]. *Coal Engineering*, 2020, 52(2): 121-125.
- [18] 韩建光, 谷丙洛, 王硕, 等. 煤层反射槽波三维正演模拟[J]. *地质学报*, 2024, 98(7): 2258-2268.
HAN Jianguang, GU Bingluo, WANG Shuo, et al. Study on 3D forward modeling of reflected in-seam wave in coal seam[J]. *Acta Geologica Sinica*, 2024, 98(7): 2258-2268.
- [19] LIU Bin, YANG Senlin, REN Yuxiao, et al. Deep-learning seismic full-waveform inversion for realistic structural models[J]. *Geophysics*, 2021, 86(1). DOI: 10.1190/geo2019-0435.1.
- [20] ZHU Sen, WANG Yulin, XU Yunfan, et al. Asymmetric fiber grating overlapping spectrum demodulation technology based on convolutional network and wavelet transform noise reduction[J]. *Optical Fiber Technology*, 2025, 90. DOI: 10.1016/j.yofte.2025.104132.
- [21] 董绍江, 李洋, 梁天, 等. 基于 CNN-BiLSTM 的滚动轴承变工况故障诊断方法[J]. *振动. 测试与诊断*, 2022, 42(5): 1009-1016, 1040.
DONG Shaojiang, LI Yang, LIANG Tian, et al. Fault diagnosis method of rolling bearing based on CNN-BiLSTM under variable working conditions[J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(5): 1009-1016, 1040.
- [22] 洪宇超, 钱建固, 叶源新, 等. 基于时空关联特征的 CNN-LSTM 模型在基坑工程变形预测中的应用[J]. *岩土工程学报*, 2021, 43(增刊 2): 108-111.
HONG Yuchao, QIAN Jiangu, YE Yuanxin, et al. Application of CNN-LSTM model based on spatio-temporal correlation characteristics in deformation prediction of foundation pit engineering[J]. *Chinese Journal of Geotechnical Engineering*, 2021, 43(S2): 108-111.
- [23] 尹刚, 朱淼, 全鹏程, 等. 基于 PID 搜索优化的 CNN-LSTM-Attention 铝电解槽电解温度预测方法研究[J]. *仪器仪表学报*, 2025, 46(1): 324-337.
YIN Gang, ZHU Miao, QUAN Pengcheng, et al. Research on CNN-LSTM-Attention aluminum electrolyzer electrolysis temperature prediction method based on PID search optimization[J]. *Chinese Journal of Scientific Instrument*, 2025, 46(1): 324-337.
- [24] 张晗筱, 王瑞琪, 张亚婷. 基于 CNN-LSTM 的换热器污垢因子预测研究[J]. *化工学报*, 2025, 76(4): 1671-1679.
ZHANG Hanxiao, WANG Ruiqi, ZHANG Yating. Prediction of scale factor of heat exchangers based on CNN-LSTM neural network[J]. *CIESC Journal*, 2025, 76(4): 1671-1679.
- [25] 朱仔旭, 施成华, 陈海勇, 等. 考虑 IPSO 优化的 CNN-LSTM 盾构掘进参数混合预测模型[J]. *铁道科学与工程学报*, 2025, 22(6): 2690-2702.
ZHU Zixu, SHI Chenghua, CHEN Haiyong, et al. Hybrid CNN-LSTM shield tunneling parameter prediction model considering IPSO optimization[J]. *Journal of Railway Science and Engineering*, 2025, 22(6): 2690-2702.
- [26] GUAN Wenhui, LI Binbin, XUE Shijie, et al. Research on CNN-attention regression prediction method based on GOA optimization[M]//*Proceedings of the TEPEN International Workshop on Fault Diagnostic and Prognostic*. Cham: Springer Nature Switzerland, 2024: 209-219.
- [27] SU Ziyi, LIU Handong, QIAN Jinwu, et al. Hand gesture recognition based on sEMG signal and convolutional neural network[J]. *International Journal of Pattern Recognition and Artificial Intelligence*, 2021, 35(11). DOI: 10.1142/S0218001421510125.
- [28] HE He, WANG Junhan, KOJIMA S, et al. Regression CNN based fast fading channel tracking using decision feedback channel estimation[J]. *Journal of Signal Processing*, 2023, 27(3): 49-57.