

基于 3D-CNN 与 Transformer 的 钢丝绳槽衬垫磨损检测方法

姜占东¹, 王 鹏¹, 贾正涛¹, 白星振², 隋树浩³

(1. 国家能源集团宁夏煤业公司石槽村煤矿, 宁夏 灵武 750409;

2. 山东科技大学, 山东 青岛 266500;

3. 中国联合网络通信有限公司青岛市分公司, 山东 青岛 266000)

摘 要 在复杂工况下, 激光扫描获取的三维数据易受噪声干扰, 导致钢丝绳槽衬垫磨损检测精度下降。本文提出一种融合 3D-CNN 与 Transformer 的深度学习方

关键词 钢丝绳槽衬垫磨损检测; 3D-CNN; Transformer; 噪声干扰; 预测性维护

中图分类号: TH117.1

文献标志码: A

DOI: 10.3969/j.issn.2097-3365.2026.18.005

0 引言

钢丝绳槽衬垫在煤矿提升系统中长期承受摩擦与冲击, 易产生磨损, 严重时可能引发打滑或断绳事故。因此, 对其磨损状态进行精准检测具有重要意义。目前, 石槽村煤矿副立井传统人工测量方法需停机作业, 效率低且仅能获取局部数据, 难以反映整体三维形貌。激光扫描虽可获取三维数据, 但在井下环境中易受粉尘、光照及设备因素影响, 产生噪声。红外与超声方法分别受环境温度与表面状态限制。传统机器学习依赖人工特征提取, 难以处理高维数据^[1]; 深度学习方法虽在二维或时序数据中表现良好, 但对三维离散数据的空间建模能力有限^[2]。针对上述问题, 本文提出一种 3D-CNN 与 Transformer 融合模型, 通过多模态去噪提升数据质量, 并结合局部特征提取与全局建模, 实现高精度磨损检测。

1 基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损检测模型设计

1.1 数据预处理

1.1.1 数据去噪和滤波

在数据采集环节, 本研究采用主从式激光扫描系统^[3]。该系统由 4 组线激光位移传感器构建成阵列式测量平台, 可在提升机设备运行状态下, 完成对钢丝绳槽衬垫全周向的点云采集。

本研究采用一种创新的多模态融合去噪算法。该算法首先运用形态学滤波对数据进行初步处理^[4]。首先设计三维结构元素, 对体素网格实施腐蚀和膨胀操作。腐蚀操作能够有效去除那些孤立的噪声点, 而膨胀操作则可以恢复因腐蚀而可能丢失的衬垫表面关键几何特征, 确保在去噪的同时最大程度地保留数据的原始特征信息。引入基于双边滤波的局部邻域优化策略。该策略充分结合点云的法向量信息, 构建出自适应权重^[5]。

经实验验证, 相较于传统的非线性阈值法, 该多模态融合去噪算法的噪声抑制率提升了 23%, 特征保持度提高了 18%, 在复杂工况下展现出卓越的去噪性能。

1.1.2 归一化处理

在为消除不同样本数据在尺度和范围上的差异, 提升神经网络训练效果, 对去噪后的三维离散数据进行归一化处理:

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

式(1)中, x_{min} 和 x_{max} 分别是三维离散数据在 x 方向上的最小值和最大值, y 和 z 同理, 通过遍历数据集统计获得。

1.1.3 体素化处理

为适应 3D-CNN 模型的规则化输入要求, 将归一化后的三维离散数据转换为三维体素网格。首先根据点

作者简介: 姜占东 (1978-), 男, 本科, 高级工程师, 研究方向: 煤矿机电运输技术管理。

云空间范围与分辨率需求确定体素边长 v ，并计算各维度体素数量，计算公式如下：

$$N_x = \frac{x_{\max} - x_{\min}}{v} \quad (2)$$

统计每个体素内点云的点密度与重心坐标，重心坐标能够更精确地描述体素内点云的空间位置信息。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3)$$

式(3)中， n 是该体素内点的数量， x_i 是第 i 个点的坐标， y 和 z 同理。

1.2 3D-CNN 与 Transformer 网络算法

3D-CNN 通过三维卷积操作提取三维离散数据的局部空间特征，擅长捕捉物体的几何结构与细微形变；Transformer 则基于多头注意力机制建模全局依赖关

系，突破传统 CNN 的局部感知局限，能有效挖掘跨区域特征关联。二者结合后，在煤矿钢丝绳槽衬垫磨损检测中实现了局部细节与全局趋势的协同分析，网络架构如图 1 所示。

1.2.1 3D-CNN 网络模型

3D-CNN 模块从三维点云数据中提取多层次空间特征。该模块采用三层卷积与两层最大池化堆叠结构，并在末端接全局平均池化层。特征提取流程依次为：体素数据经第一层卷积生成 32 通道特征图，池化后进入第二层提取更高级特征，再次池化后通过第三层提取全局特征。卷积核共享与池化操作在减少计算量的同时保持特征丰富性，ReLU 激活缓解梯度消失，池化操作增强对局部形变的容忍度，提升复杂工况下的鲁棒性。




图 1 3D-CNN 与 Transformer 结构图

1.2.2 Transformer 网络模型

3D-CNN 完成空间特征提取后，输出的特征向量缺乏位置信息。Transformer 特征增强模块首先对特征向量进行位置编码。采用三角函数计算位置编码，公式为：

$$PE_{(pos, 2i)} = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (4)$$

$$PE_{(pos, 2i+1)} = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right) \quad (5)$$

式(4)、(5)中， pos 表示特征向量的位置， i 为编码维度， d_{model} 是特征向量的维度。

基于注意力机制的基本原理，通过计算查询(Query, Q)，键(Key, K)和值(Value, V)之间的相关性来为每个值分配权重，公式为：

$$Attention(Q, K, V) = \text{soft max}\left(\frac{QK^T}{\sqrt{d_k}}\right) \quad (6)$$

式(6)中， d_k 是查询向量 Q 的维度。

将输入的特征向量划分为多个头（假设为 h 个头），每个头独立执行注意力计算操作。每个头的查询、键和

值分别通过可学习的权重矩阵进行线性变换得到，即：

$$head_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V) \quad (7)$$

最终将 h 个头的输出结果拼接起来，并通过权重矩阵进行线性变换，得到多头注意力机制的输出：

$$\text{MultiHead}(Q, K, V) = \text{Concat}(head_1, \dots, head_h) W^O \quad (8)$$

多头注意力机制（见图 2）之后，引入两层前馈神经网络（FFN）对输出进行进一步处理：

$$FFN(x) = \max(0, xW_1 + b_1)W_2 + b_2 \quad (9)$$

式(9)中， W_1 、 W_2 是权重矩阵， b_1 、 b_2 是偏置向量。

1.3 基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损检测算法

在基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损检测网络中，磨损检测模块通过全连接层将 Transformer 输出的高维特征向量映射到 K 维磨损类别空间，其中每个维度对应一种磨损程度类别。映射后的输出为线性变换结果，需通过 Softmax 函数转换为概率分布，从而实现样本在各磨损类别上的量化预测，转换过程如下：




图 2 多头注意力机制网络结构图

$$P(y=K)=\frac{e^{z_k}}{\sum e^{z_j}} \quad (10)$$

式(10)中, z_k 是全连接层第 k 个输出, 是样本属于第 k 类磨损程度的概率。

在基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损测量网络模型训练过程中, 模型采用了分类损失和预测损失相结合的方式, 并通过加权求和得到总损失。模型将输入的特征向量分类到 K 个不同的磨损程度类别中。

$$L_{cls} = -\sum_{i=1}^N \sum_{k=1}^K y_{ik} \log(p_{ik}) \quad (11)$$

式(11)中, N 是样本数量, 表示训练集中包含的样本总数。

磨损趋势预测采用均方误差损失函数来训练磨损趋势预测模型。均方误差损失函数的公式为:

$$L_{pred} = \frac{1}{N} \sum_{i=1}^N (y_i - y_0)^2 \quad (12)$$

式(12)中, y_i 是样本真实的磨损趋势值, y_0 是模型预测值, N 是样本数量。

为了综合考虑磨损程度分类和磨损趋势预测两个任务, 将分类损失和预测损失进行加权求和得到总损失。总损失的公式为:

$$L = \alpha L_{cls} + \beta L_{pred} \quad (13)$$

式(13)中, α 和 β 是平衡分类和预测损失的权重系数。

2 基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损检测实验

为验证基于 3D-CNN 与 Transformer 的钢丝绳槽衬垫磨损检测方法的有效性, 本节设计实验方案并进行结果分析。实验数据来自石槽村煤矿摩擦式提升机实测, 共 5 000 个样本, 每个样本由 $32 \times 32 \times 32$ 体素网

格表示, 覆盖不同磨损程度。数据按 7:2:1 划分为训练、验证和测试集。

实验采用 PyTorch 框架, 采用 Adam 优化器, 初始学习率为 0.001, 并结合学习率衰减策略。训练批量 (batch size) 为 32, 迭代 (epoch) 为 100 轮。为防止过拟合, 引入 L2 正则化和 Dropout 技术, Dropout 率设置为 0.5。模型性能采用 Acc 评估磨损分类准确度, F1 反映多分类精确率与召回率, 检测时间考察实时性及部署可行性。

在磨损程度分类任务中, 实验结果如表 1 所示, 3D-CNN 与 Transformer 混合模型的分类准确率为 95.6%, F1 分数为 94.8%。与传统的 CNN 模型 (准确率 89.2%) 和 LSTM 模型 (准确率 86.5%) 相比, 本文方法在分类性能上显著提升。

表 1 磨损程度分类准确率

模型	Acc (%)	F1 分数
LSTM 模型	89.2	87.6
CNN 模型	86.5	85.3
本文算法	95.6	94.8

3 结论

本文针对煤矿提升机绳槽衬垫磨损检测难题, 提出了一种基于 3D-CNN 与 Transformer 的深度学习模型, 以克服传统人工测量效率低、精度差及滞后性强的问题。该方法融合了 3D-CNN 的空间特征提取能力与 Transformer 的长程依赖建模能力, 在复杂工况下实现了 0.01 mm 级高精度检测, 显著提升了效率与准确性。实验结果表明, 该方法能有效抑制井下噪声干扰, 具备良好的鲁棒性与泛化能力, 为衬垫的实时监测与预测性维护提供了可靠支持。

参考文献:

- [1] 饶毅, 陆靖, 周靖. PointGLR: 一种无监督的三维点云结构表示学习方法 [J]. IEEE 模式分析与机器智能汇刊, 2022, 45(02):2193-2207.
- [2] 余欣, 唐磊, 饶毅, 等. Point-BERT: 基于掩码点建模的三维点云 Transformer 预训练方法 [C]//IEEE/CVF 计算机视觉与模式识别会议论文集. 2022.
- [3] 赵洪宝, 刘瑞, 刘一洪, 等. 基于深度学习方法的矿山微震信号分类识别研究 [J]. 矿业科学学报, 2022, 07(02):166-174.
- [4] 刘鹏, 魏卉子, 鹿晓龙, 等. 基于新型卷积神经网络构建矿山灾害事件检测模型 [J]. 中文信息学报, 2020, 34(10):59-68.
- [5] 丁恩杰, 俞啸, 廖玉波, 等. 基于物联网的矿山机械设备状态智能感知与诊断 [J]. 煤炭学报, 2020, 45(06):2308-2319.