

• 机械工程 •

DOI:10.12454/j.jsuese.202400743



本刊网刊

基于深度学习的掘锚机 3 维可视化健康状态监测方法

杨学琦^{1,2}, 高新勤^{1*}, 郑海洋¹, 杨 军²

(1. 西安理工大学 机械与精密仪器工程学院, 西安 710048; 2. 北京东方国信科技股份有限公司, 北京 100025)

摘要:在复杂且恶劣的煤矿开采环境中,掘锚机承受着高强度载荷,故障频发,如何有效监测其健康状态并确保其正常运行已成为日益凸显的问题。本文集成深度学习与 3 维可视化技术,提出一种掘锚机健康状态监测方法。基于深度学习方法构建融合堆叠降噪自编码器(SDAE)的双时间长度 Transformer(DT)剩余寿命预测模型(SDAE-DT Net),将数据中不同序列长度的特征有效结合,通过 SDAE 抑制噪声干扰,使用粒子群算法(PSO)获得最优超参数,利用煤矿实际生产数据集和 IMS 数据集验证所提模型的预测效果。实验结果表明,该模型在复杂工况下具有较强的泛化能力与鲁棒性,能够为掘锚机部件提供精准的健康评估与剩余寿命预测结果。在此基础上,采用 3 维建模技术构建掘锚机的 3 维模型,提出数据交互的掘锚机 3 维可视化健康状态监测方法,结合实例开发掘锚机 3 维可视化健康状态监测系统,实现综合采煤工作面与 3 维可视化模型的数据映射,验证所提方法的正确性和可行性。该系统具备良好的可视交互性和工程实用价值,可为煤矿智能运维提供重要技术支撑。研究结果为煤矿掘进设备剩余寿命预测与健康状态监测提供了理论基础。

关键词:掘锚机;3 维可视化;健康状态监测;剩余寿命预测;Transformer 模型

中图分类号:TD407;TH17

文献标志码:A

文章编号:2096-3246(2025)04-0326-16

煤炭是中国的主要能源和重要工业原料,掘进工作是煤矿开采过程的重要环节。随着供给侧结构性改革的深化推进,煤炭工业已经由高速增长阶段转向高质量发展阶段,但其在智能化开采方面仍存在改进空间^[1]。《“十四五”国家安全生产规划》提出,将“数字矿井”构建、透明地质、煤矿智能监测预警等矿山智能化建设内容列入“十四五”安全生产科技创新优先领域^[2]。安全是煤矿开采的核心要素,煤矿开采的智能化转型能够为降低事故发生概率、减少事故人员伤亡提供保障,因此,要推动矿山自动化、智能化的升级改造^[3]。

煤矿智能化改造是通过物联网(IoT)、人工智能(AI)、3 维可视化(3D visualization)等技术改进矿井采掘,实现智能化作业^[4]。掘锚机作为一种重要的地下工程设备,具有掘锚一体的多种功能,在矿山开采中扮演着关键角色。然而,掘锚机运行过程中承受高强度

负载,其高频率的故障和健康管理难的问题日益凸显。此外,受高粉尘、低照度等恶劣环境的影响,综合采煤工作面的物理空间全息感知受限,掘锚机通常处于“盲采”状态,严重影响煤矿生产效率,并且存在安全隐患^[5]。因此,构建掘锚机健康状态监测体系框架,可视化监测其运行状态并准确预测其关键部件剩余寿命(RUL),通过智能化技术改变传统开采模式已成为亟需解决的问题。

在传统的 RUL 预测方法中,失效机理模型被广泛采用,包括:Paris 模型、Forman 模型及二者的改进和扩展模型^[6]。然而,这些方法往往依赖于人工特征提取,对于掘锚机这类结构复杂的设备,无法捕捉复杂的非线性关系和时变性^[7]。不同于失效机理模型,统计数据驱动的方法直接对海量数据进行建模分析,从数据中挖掘设备潜在的退化规律,从而预测 RUL^[8],如 Wiener 过程模型^[9-10]、逆高斯过程模型^[11]及伽马过程模型^[12],

收稿日期:2024-09-13 修回日期:2025-01-21 网络出版日期:2025-03-24

基金项目:国家自然科学基金项目(51575443);陕西省教育厅重点科学研究计划项目(20JY047);陕西省重点研发计划项目(2023-YBGY-328)

作者简介:杨学琦(1996—),男,博士生。研究方向:机械装备可靠性;故障监测与剩余寿命预测。E-mail:yangxueqi0301@163.com

*通信作者:高新勤,教授,E-mail:xaut66gqxq@163.com

但该方法对设备退化趋势有一定假设,但难以得到保证,从而限制了其在实际应用中的可靠性。深度学习作为一种典型的数据驱动型RUL预测技术,凭借其强大的特征提取能力,能够显著提升预测精度,目前已被广泛应用于设备故障预测与健康管理的(PHM)领域。裴洪^[13]和Khan^[14]等分别综述了机器学习和深度学习在PHM领域的研究现状。RUL预测中最常用的是卷积神经网络(CNN)和循环神经网络(RNN),如:Li等^[15]提出的深度CNN采用时间维度的卷积操作,实现了RUL预测;长短期记忆网络(LSTM)和门控循环单元(GRU)作为RNN的变体解决了梯度消失和梯度爆炸的问题;周玉等^[16]使用LSTM结合改进麻雀搜索算法实现了滚动轴承故障诊断。然而,CNN与RNN分别存在无法处理时序特征与并行计算效率低的问题。注意力机制和Transformer模型的提出实现了在提高并行计算效率的同时有效处理数据的时间依赖关系^[17]。如:李国瑞等^[18]使用注意力机制实现了对工业物联网设备RUL的高精度预测;邓飞跃等^[19]将多尺度时间卷积网络与Transformer进行融合,用于滚动轴承RUL预测。

3维可视化技术能够将设备运行数据以可视化形式展示,帮助用户快速监测设备,从而做出更准确的决策。3维可视化与数字孪生相似亦有区别。3维可视化是利用计算机图形技术将数据以3维的形式展示,侧重于数据的可视化呈现。数字孪生则是在虚拟环境中创建与物理实体信息交互的数字模型^[20],更侧重于建模与模拟^[21-22]。目前,3维可视化与数字孪生技术均已被应用于煤矿开采与运输过程,但尚处于初级阶段^[23]。如迟焕磊等^[24]提出了一种多元信息驱动智能化工作面的可视化监控方法,解决了综合采煤工作面设备运行数据监控存在的不足;丁华等^[25]将采煤机进行高逼真仿真,并结合智能算法实现了其关键零件的健康状态预测;杨春雨等^[26]针对长距离带式输送机的运行问题,构建由数字孪生模型与控制策略组成的优化框架,实现了带式输送机的安全与节能运输;葛世荣等^[27]建立了数字孪生智能采煤工作面(DTSMW),实现孪生模型与物理实体双向信息通信,为无人化煤矿开采提供了新的监控系统架构。

综合以上研究,设备RUL预测与3维可视化技术已经取得一定成果。然而,对于掘锚机健康状态监测问题,仍存在以下瓶颈:1)故障预测和健康管理的迫切需要一种准确和自动化的方法实现掘锚机关键零部件RUL预测;2)掘锚机数据存在大量噪声干扰,构建的RUL预测模型需充分抑制噪声并提取有效特征;3)恶劣的运行环境使得掘锚机运行状态监测困难,需

借助3维可视化技术,实现其运行状态与关键零部件RUL预测结果的可视化。因此,构建融合深度学习退化建模能力与3维可视化交互能力的健康状态监测方法,已成为提升掘锚机智能运维水平的重要技术路径。

鉴于此,为了能够实时监测掘锚机运行状态,本文提出一种基于深度学习的3维可视化健康状态监测方法。所提方法主要创新点为:1)构建融合堆叠降噪自编码器的双时间长度Transformer剩余寿命预测模型(stacked denoising auto encoder-dual time-length Transformer, SDAE-DT Net),保留长时间序列特征的同时有效处理的短序列数据,并充分抑制掘锚机实际生产数据的噪声干扰,准确预测RUL,定量地描述其健康状态;2)基于云端数据存储与处理方法,构建动态数据交互的掘锚机的3维可视化模型,实现采煤过程的高逼真实时仿真;结合实例与深度学习的RUL预测方法开发3维可视化健康状态监测系统,回溯掘锚机关键运行时刻与预测潜在故障趋势,定性分析其运行状态,使监测结果更具实用性。该方法结合了深度学习模型和3维可视化技术,旨在通过数据驱动和智能化的方式,实现掘锚机健康状态的可视化监测。

1 数据驱动的掘锚机RUL预测方法

1.1 掘锚机健康状态监测体系框架

构建的掘锚机健康状态监测体系框架划分为物理层、数据层、知识层及业务层,如图1所示。图1中, N 为编、解码器的层数。物理层包括掘锚机与智能传感器等设备,是健康状态监测的主要研究对象和数据采集基础,为数据层提供运行状态数据、环境参数等信息。数据层的作用是将掘锚机运行数据进行接入、储存和预处理,通常采用云服务平台进行处理,该层更重要的功能是将数据传输至信息世界,从而将物理与信息世界联系起来。知识层将预处理得到的海量历史数据输入智能算法,深度挖掘传感信息,实现掘锚机RUL的实时预测。业务层开发掘锚机3维可视化健康状态监测系统,根据数据驱动的深度学习模型实时预测RUL,结合物理行为的高仿真映射,综合分析实时运行状态,实现可视化运行状态监测。在掘锚机运行状态监测中,业务层发挥着中枢媒介的作用,利用人机交互界面,将复杂的监测数据转化为直观的视觉信息,增强维护决策的准确性与及时性。物理层为业务层的实现不断提供数据支撑,而业务层则为物理层反馈维护策略的参考信息。

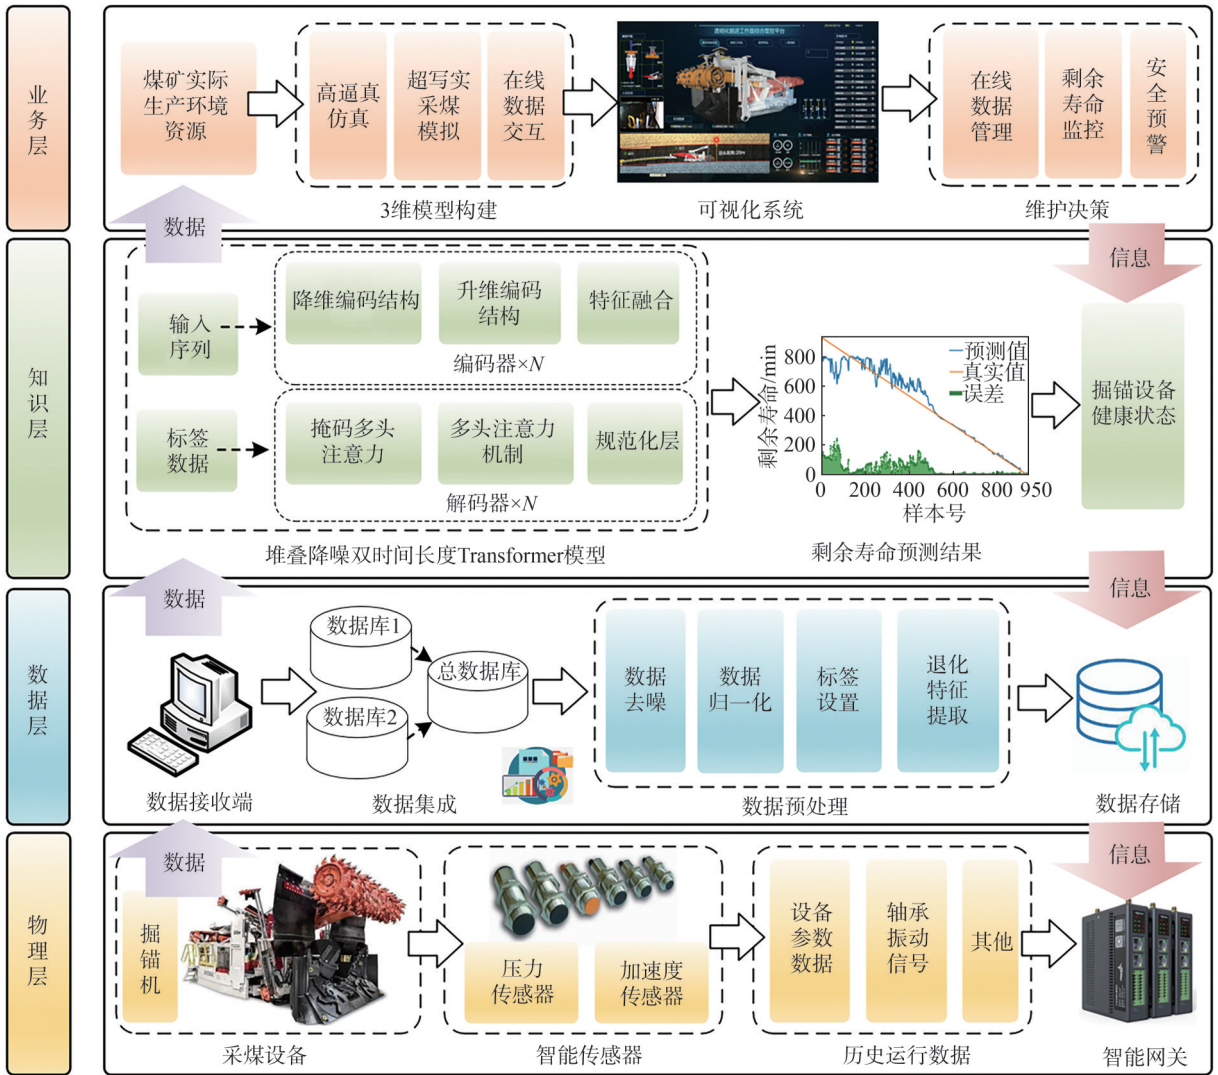


图1 掘锚机健康状态监测体系框架

Fig. 1 Health condition monitoring framework of anchor digging machines

1.2 掘锚机RUL预测模型搭建

对于掘锚机剩余寿命预测问题,构建的深度学习模型既需要有充分抑制数据噪声的能力,又要能够深度捕捉数据的长序列依赖特性,提取有效特征。然而,传统的深度学习模型并不同时具备这两种能力,且预测精度和运行速度也不能满足要求。因此,本文改进Transformer模型为双编码器结构,并借鉴堆叠降噪自编码器(SDAE),提出了一种在噪声环境下能够准确预测掘锚机关键零部件RUL的SDAE-DT Net模型。通过粒子群算法(PSO)调优模型超参数,进一步提高预测的精度。SDAE-DT Net模型的具体结构如图2所示。

图2中,DAE为降噪自编码器结构; L_{RMSE} 为均方损失; L_{rec} 为特征维度转换产生的重构误差; n 为数据样本数。Transformer是一种采用注意力机制的神经网络结构,由4个主要部分组成:位置编码、编码器、解码

器和全连接神经网络。由图2可知,SDAE-DT Net模型的编码器包含两个时间长度编码器层,同时对不同时间长度的输入数据进行特征提取,且每个编码器都融合了降噪自编码器的特征升降维结构进行数据去噪。不同编码器层的输出通过特征融合层进行融合,然后作为解码器层的输入。最后,通过全连接神经网络,输出RUL预测结果。

1.2.1 双时间长度编码结构

编码器作为Transformer模型的主要结构,负责将输入数据的特征序列进行编码,映射为包含输入特征信息的中间向量^[18]。在掘锚机时间序列数据中,RUL由当前和过去时间点传感信号共同决定,时间长度太长会导致远离当前时间点的信息成为无用信息,太短则造成信息丢失,因此,时间长度的选择至关重要。SDAE-DT Net模型双时间长度编码结构的特点是包含两个不同的时间长度编码器,并由若干

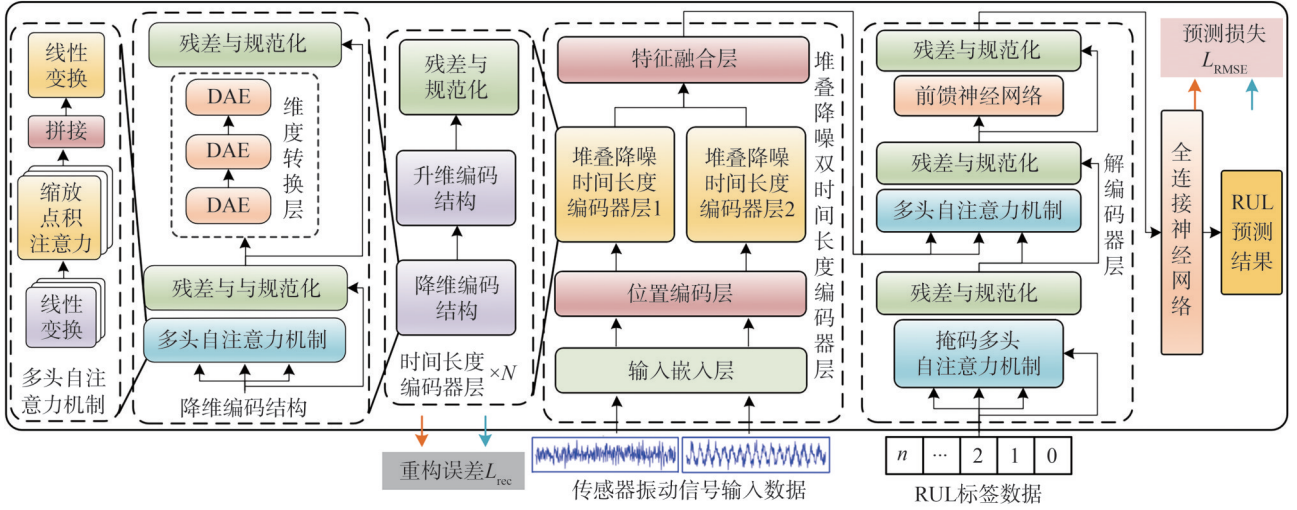


图2 SDAE-DT Net模型总体架构

Fig. 2 General architecture of the SDAE-DT Net model

结构类似的子编码器叠加组成,子编码器包括残差与规范化、维度转换层和多头自注意力机制。掘锚机的关键零部件RUL预测采用两个不同长度的滑动时间窗口,分别对原始时间序列数据集滑动处理进行分割,然后输入双编码器,滑动采样过程如图3所示。图3中, l 为样本采集的时间长度。

算过程如式(1)~(4):

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (1)$$

$$\mathbf{Q} = \mathbf{X}_f \mathbf{W}^Q \quad (2)$$

$$\mathbf{K} = \mathbf{X}_f \mathbf{W}^K \quad (3)$$

$$\mathbf{V} = \mathbf{X}_f \mathbf{W}^V \quad (4)$$

式(1)~(4)中: $\text{Softmax}(\cdot)$ 为激活函数,用于计算每个位置的权重系数; $\text{Attention}(\cdot)$ 为自注意力机制,作用是计算输入序列中不同位置之间的相关性; \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别为查询矩阵、键矩阵、值矩阵, \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 分别由输入的特征矩阵 \mathbf{X}_f 与对应权重矩阵 \mathbf{W}^Q 、 \mathbf{W}^K 、 \mathbf{W}^V 相乘得到; d 为 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 的维数。

SDAE-DT Net模型使用的多头自注意力机制可综合输入数据序列中包含的重要信息,并学习不同表现子空间的信息,即计算出多个 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 组合,并将所得到的多个注意力结果拼接,再进行线性变换得到最终输出,缓解依赖单一注意力机制可能带来的偏差^[18],如式(5)和(6)所示:

$$\text{Multihead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\mathbf{h}_1, \mathbf{h}_2, \dots, \mathbf{h}_m)\mathbf{W} \quad (5)$$

$$\mathbf{h}_k = \text{Attention}(\mathbf{X}_f \mathbf{W}_k^Q, \mathbf{X}_f \mathbf{W}_k^K, \mathbf{X}_f \mathbf{W}_k^V) \quad (6)$$

式(5)~(6)中: \mathbf{W}_k^Q 、 \mathbf{W}_k^K 和 \mathbf{W}_k^V 分别为第 k 注意力头 \mathbf{Q} 、 \mathbf{K} 、 \mathbf{V} 的权重矩阵; m 为注意力头数; \mathbf{W} 为多头注意力的权重矩阵; \mathbf{h}_k 为第 k 个自注意力的输出结果; $\text{Multihead}(\cdot)$ 为多头自注意力机制,用于捕获数据中不同子空间的特征; $\text{Concat}(\cdot)$ 为对注意力头的拼接函数。

掘锚机RUL预测数据具有时序性,而注意力机制无法直接学习序列位置信息。因此,在模型中加入位置编码层,将位置信息整合到输入序列中^[19],常用的正余弦位置编码如下:

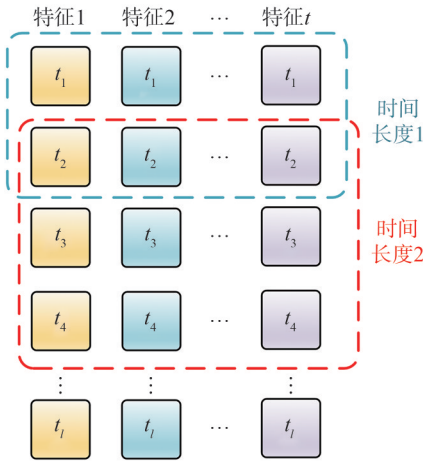


图3 双时间长度滑动采样过程

Fig. 3 Process of DT sliding sampling

双时间长度编码结构通过两个不同长度的窗口分别对原始数据进行处理。该结构既能保留数据长时间序列的依赖,也能紧密联系的短时间序列特征,充分发挥Transformer模型并行计算的优势,在牺牲训练过程中图形处理器(GPU)内存的情况下,换取更准确的预测结果。

自注意力机制通过重要信息的权重表示与特征向量的相似度计算,将模型聚焦于关键特征并捕捉长距离依赖。自注意力机制是注意力机制的变体,其包含线性变换、缩放点积注意力以及拼接^[17]。具体计

$$P_{(p,2h)} = \sin(p/10\,000^{2h/d_{\text{model}}}) \quad (7)$$

$$P_{(p,2h+1)} = \cos(p/10\,000^{2h/d_{\text{model}}}) \quad (8)$$

式(7)~(8)中, $P_{(p,2h)}$ 为位置编码矩阵中第 p 个位置、第 h 个维度的值, d_{model} 为特征向量的维度。不同特征向量的位置编码由不同频率的正余弦函数组成, 波长由 2π 逐渐增加至 $20\,000\pi$ 。

1.2.2 堆叠降噪自编码器构建

煤矿实际生产数据存在大量噪声, 严重限制了模型泛化能力。为了能够有效抑制噪声干扰, SDAE-DT Net 模型借鉴降噪自编码器 (DAE) 结构加入维度变换思想^[28], 对模型的编码器进行改进, 重构输入数据。模型训练过程中, 在输入数据中加入一定的噪声 (例如高斯噪声), 生成损坏的输入数据。DAE 在噪声数据的基础上, 学习如何恢复原始未损坏的输入。通过这种方式, 模型不仅能学到压缩数据的低维表示, 还能够有效滤除噪声。改进后的编码器包含升、降维编码结构, 用包含 3 个 DAE 的维度转换层替换原编码器中的前馈神经网络 (FNN), 并堆叠该结构对原始数据进行充分降噪。

传统的 DAE 在模型训练过程中会对输入数据进行随机丢弃, 在一定程度上影响模型预测效果, 而本文设计的 SDAE 只有在训练过程中才会进行丢弃操作。图 2 中, 输入的振动信号数据经过位置编码层后, 作为降维编码器的输入。通过多头注意力机制计算全局特征, 在残差与规范化处理后, 经过第 1 个维度转换层随机丢弃数据并加入噪声, 再利用编码函数 $f_{\theta}(\cdot)$ 进行降噪编码得到编码特征矩阵 \mathbf{Y} , 最后再进行残差与规范化处理实现数据降维。计算过程如下:

$$\mathbf{X}_0 = \mathbf{X}\mathbf{E} + \mathbf{E}_{\text{position}} \quad (9)$$

$$\mathbf{O}_i = \text{RLT}(\text{MultiHead}(\mathbf{X}_{i-1}) + \mathbf{X}_{i-1}) \quad (10)$$

$$\mathbf{Y}_i = f_{\theta}(\mathbf{X}'_i) = \text{sigmoid}(\mathbf{w}_i \mathbf{X}'_i + \mathbf{b}_i) \quad (11)$$

$$\mathbf{O}_i^* = \text{RLT}(\mathbf{Y}_i) \quad (12)$$

式(9)~(12)中: \mathbf{X} 为数据集序列; \mathbf{X}_0 为编码器输入; \mathbf{E} 、 $\mathbf{E}_{\text{position}}$ 分别为线性映射与位置编码; \mathbf{O}_i 为第 i 个降维编码器经多头注意力机制与规范化的输出; \mathbf{X}_i 为降维编码层第 i 个降维编码器的输出特征; \mathbf{X}'_i 为第 i 个降维编码器随机丢弃与加入噪声后的损坏数据; θ 为降维编码层的参数集合, $\theta = \{\mathbf{w}, \mathbf{b}\}$, \mathbf{w} 为连接权重; \mathbf{b} 为偏置向量; \mathbf{O}_i^* 为第 i 个降维编码结构的输出序列; $\text{RLT}(\cdot)$ 为残差与规范化; $\text{sigmoid}(\cdot)$ 为激活函数。

降维编码器的最终输出为 \mathbf{O}^* , 该输出经过升维编码器的多头注意力机制和残差与规范化处理, 再经过第 2 个维度转换层的解码函数 $g_{\theta}(\cdot)$ 恢复原始未

损坏的输入, 还原初始维度并规范化, 重构后得到解码输出 \mathbf{Z}_j , 最后规范化处理得到还原数据。具体计算过程如下:

$$\mathbf{O}_j' = \text{RLT}(\text{MultiHead}(\mathbf{O}_i^*) + \mathbf{O}_i^*) \quad (13)$$

$$\mathbf{Z}_j = g_{\theta'}(\mathbf{O}_j') = \text{sigmoid}(\mathbf{w}'_j \mathbf{O}_j' + \mathbf{b}'_j) \quad (14)$$

$$\mathbf{S}_j = \text{RLT}(\mathbf{Z}_j + \mathbf{X}_0) \quad (15)$$

式(13)~(15)中: \mathbf{O}_j' 为第 j 层升维编码器经多头注意力机制与规范化的输出; θ' 为升维编码器的参数集合, $\theta' = \{\mathbf{w}', \mathbf{b}'\}$, \mathbf{w}' 、 \mathbf{b}' 分别为升维编码器连接权重和偏置向量; \mathbf{S}_j 为第 j 层升维编码结构的输出序列。升降维度产生的重构误差 L_{rec} 最小化为:

$$L_{\text{rec}} = \min(|\mathbf{S} - \mathbf{X}_0|) \quad (16)$$

式中, $|\cdot|$ 为绝对值, \mathbf{S} 为最后一个升维编码器的输出。堆叠多层 DAE 是将前一层 DAE 经编码函数 f_{θ} 得到的输出作为后一层的输入, 后一层经过类似前一层的方式再次重构数据。维度转换层堆叠 3 层 DAE 同时训练, 参数集合 θ 与 θ' 使用梯度下降法调整所有连接权重和偏置向量。选择梯度下降法的原因是其能够高效处理高维参数空间, 且适用于 DAE 的非线性特征学习需求, 从而保证模型在复杂特征表示上的训练效果。在重构误差最小时训练完成, 此时得到经过降噪处理的特征数据。模型优化的目标共包含预测误差、重构误差两部分。预测误差通常选择平均绝对误差 (MAE) 作为损失值, 总优化目标 L_{Total} 为:

$$L_{\text{Total}} = \min(L_{\text{rec}} + L_{\text{pre}}) = \min(|\mathbf{S} - \mathbf{X}_0| + L_{\text{RMSE}}) \quad (17)$$

式中, L_{rec} 为重构误差, L_{pre} 为模型预测误差, L_{RMSE} 为均方根预测误差。

所提模型训练时以式(17)为优化目标, 以 Transformer 和 SDAE 相关参数为自变量不断迭代学习, 各参数不断更新直至损失达到最小时预测误差最小, 此时参数集最优。

2.1.3 模型超参数调优

SDAE-DT Net 模型的性能受到超参数的影响, 本文采用 PSO 对模型的迭代次数、编码器与解码器层数、训练的样本数与输出层隐藏神经元数进行优化以寻找一组更优的参数, 优化流程如图 4 所示。选择 PSO 的原因在于其具有良好的全局搜索能力和优化效率, 能够适应超参数优化的复杂搜索空间。PSO 的基本思想是, 用无质量的粒子来模仿鸟类, 粒子有速度 V_q^s 和位置 X_q^s 两个属性, 在搜索空间中搜寻最优解。PSO 初始化为一群随机粒子, 然后通过迭代找到最优解。迭代过程中粒子通过跟踪个体最优 P_{best} , 全局最优 G_{best} 两个最优值进行更新。PSO 的标准更新形式为^[29]:

$$V_q^{g+1} = wV_q^g + c_1 S_{rand} (P_{best}^g - X_q^g) + c_2 S_{rand} (G_{best}^g - X_q^g) \quad (18)$$

$$X_q^{g+1} = X_q^g + V_q^{g+1} \quad (19)$$

式(18)~(19)中: V_q^g 为第 g 次迭代中第 q 个粒子运

动的速度, $q = 1, 2, \dots, R$, R 为粒子总数; X_q^g 为第 g 次迭代中第 q 个粒子当前的位置; c_1, c_2 为学习因子, 通常 $c_1 = c_2 = 2$; w 为惯性因子, 其值为非负; S_{rand} 为介于 $(0, 1)$ 之间的随机数。

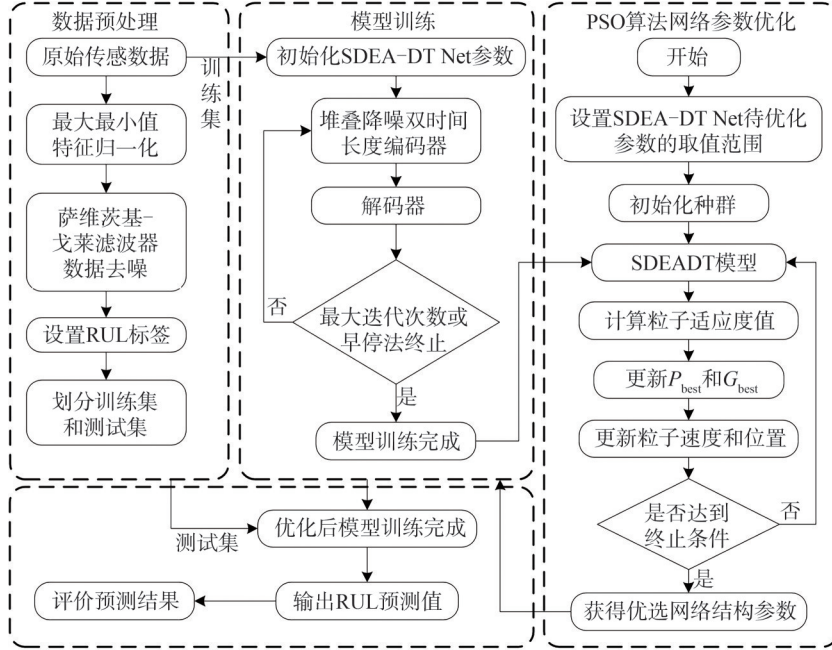


图4 PSO模型超参数优化流程


Fig. 4 Process of PSO hyperparameter optimisation for model

PSO超参数优化的流程:确定粒子数和搜索范围,并初始化粒子的位置和速度;将待优化参数转换为粒子个体,其中每个个体对应一组模型参数;以模型损失函数作为粒子适应度函数进行训练;将训练过程中得到的最优解作为下一轮搜索的起点,直达到达预设的停止条件。在此基础上,对个体与整体的最优位置进行更新,并利用最优位置更新每个粒子的速度和位置,得到模型最优超参数。

1.3 模型性能验证

1.3.1 数据集与数据预处理

截割大臂是掘锚机的关键部件,其与进刀滑靴相连并承载着截割齿轮箱。采煤过程中,截割大臂带动截割滚筒上下往复移动进行采煤操作,其结构如图5所示。



- 1. 掏槽滑架; 2. 截割大臂轴承; 3. 掏槽油缸轴承; 4. 割油箱轴承;
- 5. 输送机滑动导轨; 6. 导杆滑动轴承; 7. 平台润滑油点。

图5 截割大臂结构

Fig. 5 Structure of the cutter boom

截割大臂轴承作为易损部件,控制着截割滚筒的位置同时也进行动力传输,其健康状态能够直接反应截割大臂的运行状态。因此,选择MB670掘锚机的截割大臂轴承作为实例研究对象,利用所提模型对截割大臂轴承进行RUL预测。本文使用的是煤矿实际生产数据集,该数据为采煤过程中掘锚机截割大臂轴承的全生命周期振动加速度数据,共收集到20个轴承样本数据。

数据采集过程中在掘锚机截割大臂轴承处安装加速度传感器,并在地面终端设备进行测试,如图6所示。




图6 数据采集与测试

Fig. 6 Data collection and testing

信号采集传感器型号为CX-230,频响范围为0~40 kHz,采集设备为DH522型动态信息测试分析系统。数据采集频率为1 kHz,每10 min采集1次,每次采

集 1 s, 即每次采集 1 000 条数据, 共收集了 20 个轴承的数据。每个轴承的数据均为按照时间顺序采集的从开始运行至失效的完整数据, 故每个轴承不同时间节点的 RUL 值已知, 且不同轴承的 RUL 值不同。

复杂工况环境中采煤设备轴承的振动信号数据通常表现出非线性、非稳定的特点, 并且带有噪声干扰。因此, 对收集到的振动信号数据首先使用萨维茨基-戈莱滤波器 (Savitzky-Golay) 去噪处理^[30]。为避免数据范围不一致对模型性能产生影响, 对各特征进行归一化处理, 常用的方法有标准差归一化 (SDN)、最

小最大归一化 (MinMax) 和 Z-Score 归一化。考虑本文使用的数据集变化差异不大, 故使用 MinMax 归一化使数据特征范围均在 [0, 1] 之间, T_u^{norm} 表达式为:

$$T_u^{\text{norm}} = \frac{T_u - T_{\min}}{T_{\max} - T_{\min}} \quad (20)$$

式中, T_u 、 T_{\max} 、 T_{\min} 分别为第 u 个时间点的特征值、特征最大值、特征最小值。数据去噪与归一化后, 提取反应轴承健康状态的特征指标作为模型输入。时域和频域特征提取是信号处理最主要的两种方式, 如快速傅里叶变换 (FFT) 等。表 1 为常用的时频域特征参数及表达式。

表 1 时频域特征表达式

Tab. 1 Expressions for time-domain features

特征	表达式	特征	表达式
均值 \bar{X}	$\bar{X} = \frac{1}{n'} \sum_{v=1}^{n'} x_v$	标准差 S_D	$S_D = \sqrt{\frac{1}{n'-1} \sum_{v=1}^{n'} (x_v - \bar{X})^2}$
峭度 β	$\beta = \frac{1}{n'} \sum_{v=1}^{n'} x_v^4$	方根幅值 X_r	$X_r = \left(\frac{1}{n'} \sum_{i=1}^{n'} \sqrt{ x_v } \right)^2$
峰峰值 X_{p-p}	$X_{p-p} = \max(x_v) - \min(x_v)$	绝对均值 $ \bar{X} $	$ \bar{X} = \frac{1}{n'} \sum_{v=1}^{n'} x_v $
最大值 X_{\max}	$X_{\max} = \max(x_v)$	最小值 X_{\min}	$X_{\min} = \min(x_v)$
方差 σ^2	$\sigma^2 = \frac{1}{n'-1} \sum_{v=1}^{n'} (x_v - \bar{X})^2$	均方根值 X_{rms}	$X_{\text{rms}} = \sqrt{\frac{1}{n'} \sum_{v=1}^{n'} x_v^2}$
频谱均值 p_1	$p_1 = \frac{\sum_{k_p=1}^{K_p} X(k_p)}{K_p}$	均方根频率 p_3	$p_3 = \left(\frac{\sum_{k_p=1}^{K_p} (X(k_p) - p_1)^2}{K_p - 1} \right)^{1/2}$
频谱标准差 p_2	$p_2 = \sqrt{\frac{\sum_{k_p=1}^{K_p} f^2(k_p) X(k_p)}{\sum_{k_p=1}^{K_p} X(k_p)}}$	中心频率 p_4	$p_4 = \left(\frac{\sum_{k_p=1}^{K_p} f(k_p) X(k_p)}{\sum_{k_p=1}^{K_p} X(k_p)} \right)$

表 1 中, x_v ($v=1, 2, \dots, n'$, n' 为样本序列长度) 为轴承振动信号序列, $X(k_p)$ ($k_p=1, 2, \dots, K_p$, K_p 为频谱信号长度) 为经 FFT 变换后的振动信号的频率幅值, $f(k_p)$ 为第 k_p 个信号的频率值。为明确数据各时间点的 RUL, 需设置轴承训练标签 L_a 。标签的计算方式为:

$$L_a = \frac{T_a}{T_R} \times 100\% \quad (21)$$

式中, T_a 为第 a 个样本的已运行时间, T_R 为开始运行至失效的全寿命时间。最后, 将提取的 14 种时频域特征信息数据作为 SDAE-DT Net 模型的输入, 进行 RUL 预测。训练过程中, 划分数据集的 80% 作为训练集和验证集, 剩下的 20% 则用于测试。

选择均方根误差 (RMSE, 记为 E_{RMSE}) 作为预测损失函数, 并在训练过程中加入早停机制防止模型过拟合和训练时间过长。分别选用平均绝对误差 (MAE, 记为 E_{MAE})、决定系数 (R^2)、平均绝对百分比误差 (MAPE, 记为 E_{MAPE})、 E_{RMSE} 作为模型评价指标^[31], 其

表达式如下:

$$E_{\text{MAE}} = \frac{1}{m} \sum_{a=1}^m |\hat{y}_a - y_a| \quad (22)$$

$$E_{\text{RMSE}} = \sqrt{\frac{1}{m} \sum_{a=1}^m (y_a - \hat{y}_a)^2} \quad (23)$$

$$E_{\text{MAPE}} = \frac{1}{m} \sum_{a=1}^m \left| \frac{\hat{y}_a - y_a}{y_a} \right| \quad (24)$$

$$R^2 = 1 - \frac{\sum_{a=1}^m (y_a - \hat{y}_a)^2}{\sum_{a=1}^m (y_a - \bar{y})^2} \quad (25)$$

式 (22)~(25) 中, y_a 、 \hat{y}_a 和 \bar{y} 分别为样本标签的真实值、预测值和均值, m 为测试集样本个数。

1.3.2 实验结果比较与分析

1) 模型超参数优化方法比较

为了探索不同超参数优化方法对模型预测效果的影响, 设置实验对比 PSO、遗传算法 (GA)、麻雀搜索算法 (SSA)、鲸鱼算法 (WOA) 优化效果。经过初步实

验对比,选择时间长度分别为20和30,步长均为1的两种时间窗口对时频域数据进行滑动处理,并作为双时间长度编码器的输入。学习率优化算法选择Adam,激活函数选择ReLU,学习率为0.001。待优化超参数范围设置为:迭代次数[100, 400]、编码器与解码器层数[3, 6]、训练样本数[50, 300]、隐藏神经元数[100, 200]。综合考虑搜索空间的复杂性,PSO参数设置的依据为:初始粒子位置在超参数的搜索空间内均匀随机分布以确保覆盖主要区域;学习因子为 c_1 、 c_2 均为2,以兼顾个体经验和群体协作的影响;初始种群规模 b 影响搜索的多样性,惯性因子 λ 可平衡全局与局部搜索能力,为保证两者组合最优,使用动态调整策略, b 和 λ 范围分别为[10, 50]和[0.4, 0.9]。为了验证PSO参数设置的合理性,对 b 和 λ 的变化进行灵敏度分析,结果如图7所示。




图7 灵敏度分析

Fig. 7 Sensitivity analysis

图7的结果表明,当种群规模为40、惯性因子为0.5时,PSO的性能最佳。不同方法优化后的超参数如表2所示。每组实验的评价指标均取5次实验的平均值,结果如表3所示。

表2 预测模型评价指标

Tab. 2 Evaluation index of the model

预测模型	迭代次数	编、解码器层数	训练样本数	隐藏神经元数
PSO	239	4,4	153	107
GA	278	3,6	176	89
SSA	251	5,3	134	116
WAO	232	3,4	158	102

观察表3可知,未进行超参数优化的SDAE-DT Net模型在训练集的各指标最优值为0.211、0.782、0.356、0.221,无法达到预期的预测效果。加入超参数优化方法后,模型在训练集、验证集与测试集的预测效果明显提升,其中采用PSO优化后的SDAE-DT Net模型各指标均为最优,在训练集的各指标值为0.157、0.899、0.192、0.087。WOA的优化效果稍次于PSO,其次是SSA,GA的

优化效果最差但也优于未优化超参数前的模型。

表3 不同超参数优化方法性能比较

Tab. 3 Comparison of different hyperparameter optimization methods

数据集	优化方法	E_{MAE}	R^2	E_{MAPE}	E_{RMSE}
训练集	未优化	0.211	0.782	0.356	0.221
	PSO	0.157	0.899	0.192	0.087
	GA	0.183	0.822	0.314	0.197
	SSA	0.178	0.839	0.302	0.208
	WOA	0.169	0.847	0.235	0.124
验证集	未优化	0.224	0.771	0.349	0.233
	PSO	0.162	0.882	0.212	0.095
	GA	0.189	0.831	0.329	0.206
	SSA	0.186	0.824	0.312	0.193
	WOA	0.172	0.849	0.247	0.131
测试集	未优化	0.230	0.797	0.378	0.247
	PSO	0.159	0.867	0.208	0.091
	GA	0.188	0.805	0.331	0.217
	SSA	0.185	0.811	0.320	0.214
	WOA	0.177	0.836	0.251	0.129

2) 消融实验

为了验证经过SDAE和双时间长度编码结构改进后模型的预测效果的变化情况,设置4组实验进行对比。4组实验分别为:M1,Transformer模型;M2,双时间长度编码结构的Transformer模型;M3,SDAE改进的Transformer模型;M4,SDAE-DT Net模型。为保证实验过程中其他变量不变,4组实验均使用前16个轴承的数据作为训练数据集,且均将PSO优化后的最优超参数输入模型。训练过程中,观察4组实验模型训练集与验证集损失函数的下降趋势,结果如图8所示。

由图8(a)可知,未改进时,模型训练迭代到140次左右触发早停机机制,损失值最终下降至0.179。图8(b)、(c)中,改进后收敛过程波动更小,两组实验损失值分别下降至0.113和0.101,由于模型结构的复杂化,迭代次数相对图8(a)增加。图8(d)的SDAE-DT Net模型则因具备深度特征捕捉与抑制噪声的能力,训练过程明显比其他3组实验更加稳定,损失值低至0.087。未改进的模型虽能够粗略地估计RUL,但由于数据存在噪声,模型学习效果与损失下降程度均不理想,导致RUL预测准确度不够。

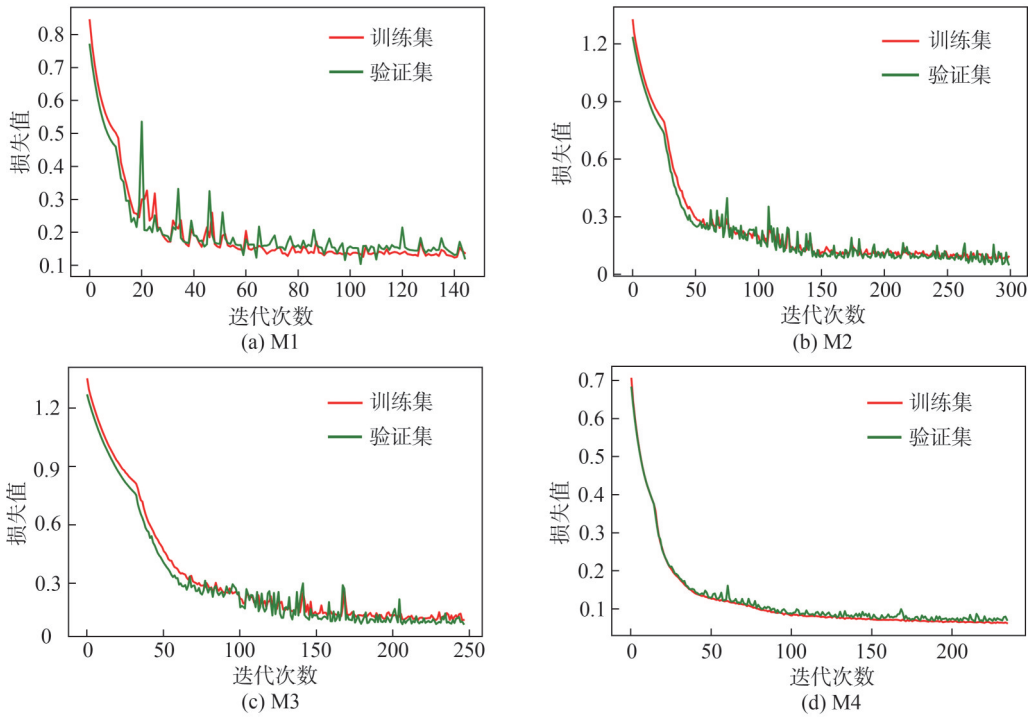


图8 模型损失函数对比

Fig. 8 Model loss function comparison

3) 常用模型预测结果对比

除 Transformer 模型外, 深度学习的其他常用模型也被广泛应用于 RUL 预测, 包括双向门控循环单元 (BiGRU)、LSTM 与双向长短时记忆网络 (BiLSTM) 等。为了对比 SDAE-DT Net 模型与 BiGRU、

BiLSTM、CNN-BiLSTM、CNN-BiGRU、Transformer 等常用模型的预测效果, 进行多次实验将各模型调整至最优。训练完成后在测试集上进行测试, 对比模型的拟合效果及预测误差, 测试结果如图 9 所示。

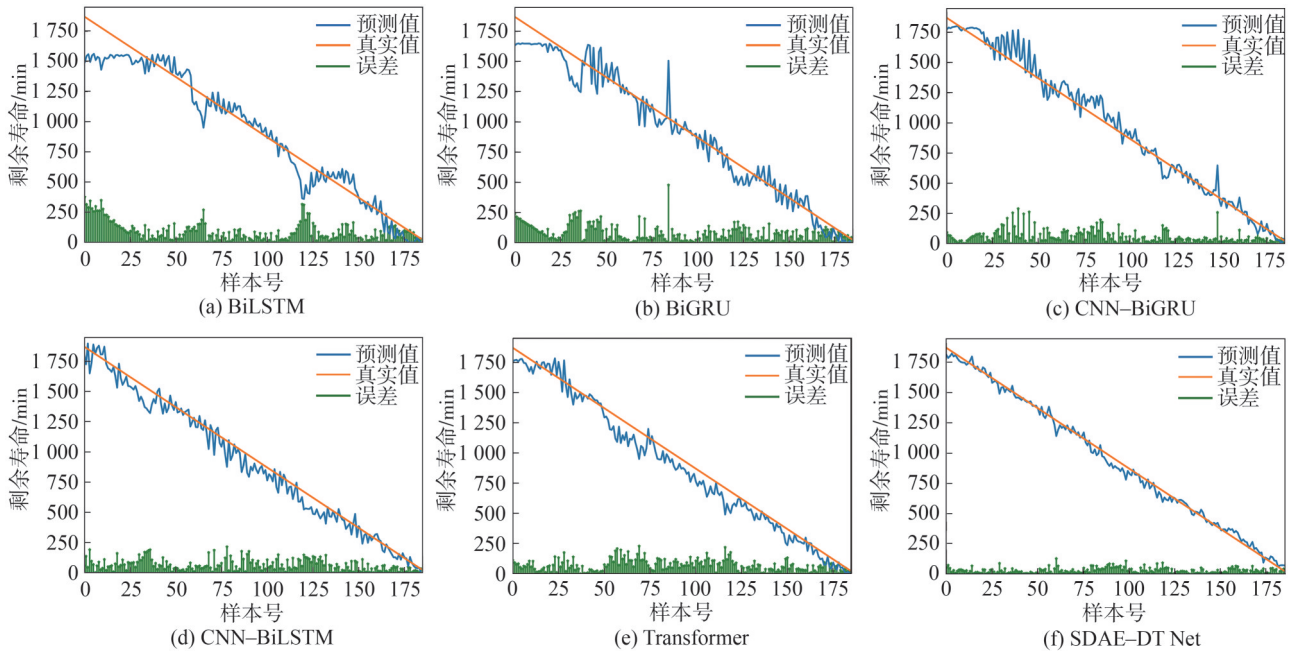


图9 各模型预测效果对比

Fig. 9 Comparison of model prediction effects

图9中可以看出, 实验比较的6种模型均有一定的预测效果。BiLSTM与BiGRU模型预测结果相近, 拟合效果相对较差, 误差也较大。组合CNN后的

CNN-BiGRU与CNN-BiLSTM模型性能有所提升, 但效果相差不大, 提升不够明显。本文模型相比Transformer模型, 由于加入了双编码器结构并且针对

数据噪声干扰通过 SDAE 进行了改进,所以预测效果更好。总体来说,其他 5 种模型相比 SDAE-DT Net 模型效果差一些,图 9(f)中模型的预测曲线波动与预测误差较小,与真实值已高度重合。实验说明,本文模型能够深度捕捉数据的长序列依赖特性,并有效抑制数据噪声,实现了 RUL 的准确预测。为了进一步对比,表 4 比较了各模型的评价指标与测试同一组数据所需的预测时间,每组实验结果均取 5 次实验的平均值。

表 4 预测模型评价指标
Tab. 4 Evaluation index of the model

预测模型	E_{MAE}	R^2	E_{MAPE}	E_{RMSE}	时间/s
BiLSTM	0.534	0.631	0.412	0.295	41
BiGRU	0.483	0.636	0.347	0.301	38
CNN-BiLSTM	0.334	0.735	0.306	0.253	50
CNN-BiGRU	0.199	0.858	0.247	0.182	46
Transformer	0.178	0.843	0.340	0.179	33
本文模型	0.157	0.899	0.192	0.087	35

表 4 中, BiGRU 和 BiLSTM 的 E_{RMSE} 值、 E_{MAE} 值以及 E_{MAPE} 值相比其他模型均较大, R^2 值较小, 说明其预测效果较差。相比之下, CNN-BiLSTM 和 CNN-BiGRU 模型预测效果得到一定程度的提升, 但由于模型需要估计的参数增加, 预测时间也相对增加, 总体效果仍不理想, 结论与图 9 分析结果一致。Transformer 模型由于单编码器结构的原因, 模型估计参数较少, 预测过程所需时间最少, 为 33 s, 与本文模型的 35 s 相差不大, 但各评价指标略差于本文模型。观察表 4 各指标的最优值, 发现除预测时间外, 各指标的最优值 0.157、0.899、0.192、0.087, 均来自本文模型, 故其预测效果与性能总体最好。为了更清晰地描述与分析所研究模型评价指标之间的差异, 从表 4 中选取了 3 个具有代表性的指标 E_{RMSE} 、 E_{MAPE} 和 R^2 , 绘制的直方图如图 10 所示。

观察图 10 可知, 本文模型的 3 个指标值明显最优, 且最接近理想值。综上所述, 与常用的 RUL 预测模型的比较, SDAE-DT Net 模型预测曲线波动范围最小, 损失值 E_{RMSE} 为 0.087, 预测寿命最接近实际寿命。因此, 该模型能够有效捕捉数据不同时间长度序列的特征, 并抑制数据中的噪声干扰, 在准确预测 RUL 方面存在一定优势。

1.3.3 现有方法性能比较

为了进一步验证所提出方法的预测与泛化能力, 使用美国辛辛那提大学的滚动轴承全生命周期实验

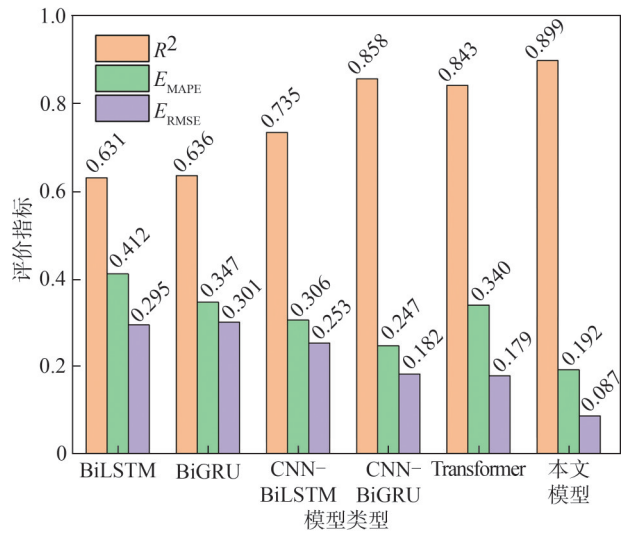


图 10 模型的主要评价指标的直方图

Fig. 10 Main evaluation indexes of the model

数据(IMS)进行实验, 并将其与多种现有方法进行比较。表 5 为现有方法的 E_{RMSE} 值、预测误差实际值和测试同一组数据所需的预测时间, “—”表示未给出。

表 5 现有方法性能比较

Tab. 5 Comparison of existing methods

预测模型	E_{RMSE}	误差/min	时间/s
裂纹扩展模型 ^[32]	5.150	—	—
JADE+ELM ^[33]	8.227	—	—
比例危险率 ^[34]	—	189.07	31
威布尔+ANN ^[35]	—	220.00	—
SVM ^[36]	1.214	—	28
RNN-HI ^[37]	0.820	—	45
LSTM-MLGS ^[38]	0.061	—	55
Attention ^[39]	19.330	55.60	—
本文模型	0.056	48.36	32


由表 5 可知, SDAE-DT Net 模型的 E_{RMSE} 值为 0.056, 预测误差最佳为 48.36 min, 在所比较的各方方法中性能最优。本文模型的预测时间为 32 s 大于 SVM 模型的 28 s, 但因本文模型 E_{RMSE} 值小于 1.214, 故两种模型各有优势, 而本文模型预测误差最小, 所以预测准确率更高。综合上述实验, 本文模型在现有方法中同样有较好的 RUL 预测能力, 因此, 能够为数据交互的掘锚机 3 维可视化健康状态监测方法的实现提供定量的分析依据, 并且能够为保证掘锚机关键零部件维护的及时性提供理论基础。

2 数据交互的掘锚机健康状态监测方法

2.1 数据交互的掘锚机 3 维模型构建

3 维建模的研究对象选择的是 MB670 掘锚机,

是一种适用于长壁开采的多功能掘进设备,配备了类似于连续采煤机的大型截割滚筒,能够提升巷道的掘进速度,MB670 主要结构如图 11 所示。对掘锚机进行 3 维建模的本质是根据其采煤工作流程,运用建模软件将其本体和地质环境进行数字化,并构建智能采煤工作面的虚拟模型模拟采煤过程。



1.截割滚筒;2.截割齿油箱;3.截割大臂支架;4.装载机构;5.输送机;
6.主机架;7.电气系统;8.液压系统;9.润滑;10.供水系统;11.锚杆
装置;12.湿式除尘器;13.灭火器;14.截割张紧装置。

图 11 MB670 掘锚机主要结构

Fig. 11 Main structure of MB670 anchor digging machines

建模核心是掘锚机的截割滚筒、截割大臂/支架、装载机构、输送机、主支架等核心部件以及地质环境。首先,设定 3 维模型的基础参数,如结构、形状、材质和状态参数。其次,利用 SolidWorks (SW) 与 UG 软件创建各个部件的 3 维模型,并使用 3DMAX 软件进行模型渲染,再导入 Unity3D 中完成装配,同样创建 3 维采煤地质模型,并与掘锚机模型结合得到完整的可视化仿真模型。选择 UG 和 SW 构建掘锚机 3 维模型的原因是两者在复杂机械建模与动态仿真中的功能互补。UG 适用于复杂部件的精细化建模和参数化设计,而 SW 则在整机装配、动态仿真与模型轻量化处理方面表现优异。将两款软件结合,能够高效完成掘锚机复杂机械结构的建模与仿真,为掘锚机运行状态的精准监测和数字孪生化奠定基础。最后,编写 Unity3D 的 C# 接口程序实现数据传输与交互,完成采煤过程可视化展示,并分析模型的可行性。本文参考数字孪生的核心思想,将所建模型与物理空间的信息进行双向交流,即数据交互。图 12 为数据交互的掘锚机 3 维模型构建过程。




图 12 数据交互掘锚机 3 维模型构建过程

Fig. 12 Construction process of 3D model for data interaction anchor digging machines

图 12 中,物理空间对掘锚机的在线与离线数据进行采集,在以太网、第 5 代移动通信技术(5G)、短距离无线通信技术(Zigbee)、第 6 代无线网络技术(WiFi6)、无线载波通信技术(UWB)等有线及无线网络的支持下传输。虚拟空间建模掘

锚机的各个核心零部件,并最终装配成完整的模型,结合 3 维地质信息模型实现虚拟采煤过程仿真。物理空间与虚拟空间数据交互的实现依赖于 3 维模型的准确构建和高效的数据更新,创建的 3 维模型需要满足从静态到动态变化需求,并能够将多种数据集成

到3维模型中形成自动更新策略。为了满足数据交互的需求,采用云端数据存储与处理的方法,在云端进行数据分析与掘锚机关键零部件的RUL预测,再通过通信接口确保3维模型与物理实体状态的实时同步更新,最终实现可视化的健康状态监测。

2.2 云端数据存储与处理方法

云端数据存储与处理方法是支撑掘锚机3维可视化健康状态监测系统高效运作的基石。采用分布式数据库可保证大规模数据的存储与可靠性,能够支持高并发的数据写入与安全的数据管理,实现3维模型与物理实体的数据实时交互。此外,使用时间序列数据库来存储掘锚机的运行数据,其在处理时间序列数据(如振动信号等传感器数据)方面具有独特的优势。

1)数据处理:数据采集利用IoT传感器和5G通讯技术,实时捕获并转发数据到云端。数据处理依托于高效能的数据处理平台,如Apache Spark及Apache Flink,支持近乎实时的数据流处理,结合IoT平台实现掘锚机的数据自动化采集和连续传输,数据清洗则使用软件Spark或Flink的实时流处理。

2)数据分析与学习:云端部署深度学习模型,模型的训练依赖于云计算平台的强大运算能力。为支持TensorFlow、PyTorch深度学习框架,使用Kubernetes

容器编排技术在云平台上动态调配资源。通过SDAE-DT Net模型学习掘锚机的退化过程,以准确预测掘锚机关键零部件的RUL。

3)云-边缘协同:为了减少网络延迟并提升数据处理的实时性,实施云-边缘计算架构。初步的数据处理和分析将在离掘锚机更近的边缘节点进行,而更复杂的数据分析与模型训练则在云端完成。边缘节点只需将关键的特征数据传输至云端,可减少数据传输量,并能够快速响应突发事件。

2.3 3维可视化健康状态监测系统

依据动态数据交互的掘锚机3维模型构建方法构建掘锚机虚拟模型,通过数据驱动的掘锚机剩余寿命预测方法实现截割大臂轴承RUL预测,并结合云端数据存储与处理方法进行实时的可视化健康状态监测。使用VUE前端开发框架与Django后端深度学习模型集成训练框架,通过Visual Studio Code软件开发基于B/S架构的掘锚机3维可视化健康状态监测系统,如图13所示。系统采用3维模型展示的形式,对掘锚机的位置、运行环境、航偏角度以及报警信息等数据可视化展示,并实时监控其关键零部件的RUL值。通过点击3维模型的方式,即可获得实时剩余寿命预测曲线,并对处于寿命末期的设备进行告警。




图 13 掘锚机3维可视化健康状态监测系统

Fig. 13 3D visualization health monitoring system of anchor digging machines

该系统对掘锚机的辅运顺槽迎头一氧化碳、甲烷以及粉尘浓度等环境数据进行监控。对掘进工作的生产计划推进尺量、班进尺量、日进尺量等生产数据以及设备的运行状态、开/停机率、故障报警等信息进行展示。查阅MB670掘锚机说明书可知,采煤过程对掘锚机截割操作机身最大倾角、航偏角以及超额定电压值等

运行指标均有正常范围规定,若各指标超过正常范围则判定为异常运行。通过系统选取某一时刻掘锚机运行状态,实时监控的各项数据如表6所示,对比运行指标正常值与实际值,可知各指标均在正常范围内。因此,掘锚机3维可视化健康状态监测系统的开发通过可视化的方式,实现了掘锚机运行状态监测的可视化

监测,为其健康状态管理提供了定性的分析依据。

表 6 MB670 掘锚机运行指标

Tab. 6 Operation indexes of MB670

运行指标	范围	实际值	结论
机身最大前倾角/(°)	[-15, +15]	3.24	正常
机身最大侧倾角/(°)	[-4, +4]	2.15	正常
航偏角/(°)	—	1.43	正常
超额定电压值/%	[-10, +10]	0	正常
最大截割高度/mm	3 800	3 700	正常

为了验证 SDAE-DT Net 模型的实时 RUL 预测效果,在线采集截割大臂轴承振动信号。机器运行大约 52 h,共累积 311 组数据,每组数据均按照时间顺序采集。将这些数据进行 14 种时频域退化特征提取,并使用两种的时间窗口进行滑动处理。最后,输入到 SDAE-DT Net 模型的两个编码器中,进行 RUL 预测。实例应用预测中,选取模型预测过程其中一段时间的预测效果及其误差进行展示,如图 14 所示。




图 14 截割大臂轴承剩余寿命预测结果

Fig. 14 RUL prediction results of cutter boom

实时预测过程中的 E_{RMSE} 值为 0.098,与表 6 的实验相比,预测同等数量样本所需时间为 36 s。由图 14 可知,预测过程前期数据量较少,拟合过程波动较大,随着后期数据量增加,预测效果不断趋于稳定,第 85 个样本的 RUL 预测值为 917 min,真实值为 1 009 min,预测误差为 2.94%。实时数据的预测结果与表 5 实验数据集的预测结果接近。实验结果说明,本文模型在实时数据的预测中同样能够有效捕捉掘锚机截割大臂轴承数据中不同时间长度序列的特征,抑制数据中的噪声干扰并准确预测 RUL。

实例应用结果表明,数据交互的掘锚机健康状态监测方法结合 3 维可视化技术的定性分析与深度学习方法的定量预测结果,实现了掘锚机运行状态监测与关键零部件截割大臂轴承的 RUL 预测。掘锚机 3 维可视化健康状态监测系统的实现,在可视化监测与管理掘锚机健康状态的同时既是对本文理论方法的验证,又可以在煤矿实际生产过程中为工作人员的维护决策做技术支撑。

3 总结

针对煤矿复杂作业环境下,掘锚机的健康状态监测问题,将 3 维可视化技术和深度学习方法有机地结合,设计了完整的掘锚机健康状态监测体系框架;构建了 SDAE-DT Net 模型,将数据中不同时间长度序列的特征有效结合,提高了存在噪声干扰时 RUL 预测的准确度,利用掘锚机实际运行数据集与 IMS 数据集进行实验验证,确保了模型的可靠性;采用 3 维建模技术构建了掘锚机的 3 维可视化模型,并在使用云端数据存储与处理方法实现数据交互的基础上结合应用实例,开发了掘锚机 3 维可视化健康状态监测系统,实现了运行状态与采煤异常监测,为煤矿设备的高效运行和维护提供理论基础。

本文研究中考虑的是掘锚机与其他设备之间相互独立的情况,而煤矿实际生产过程中设备之间的相互关系同样影响着设备的健康状态,后续将结合设备之间的复杂关系,进一步对健康状态监测问题进行研究。

参考文献:

- [1] Wang Guofa, Zhang Liang, Li Shoubin, et al. Progresses in theory and technological development of unmanned smart mining system[J]. Journal of China Coal Society, 20, 48(1): 34-53. [王国法, 张良, 李首滨, 等. 煤矿无人化智能开采系统理论与技术研发进展[J]. 煤炭学报, 20, 48(1): 34-53.]
- [2] Wang Guofa, Du Yibo. Development direction of intelligent coal mine and intelligent mining technology[J]. Coal Science and Technology, 2019, 47(1): 1-10. [王国法, 杜毅博. 智慧煤矿与智能化开采技术的发展方向[J]. 煤炭科学技术, 2019, 47(1): 1-10.]
- [3] Yang Xueqi, Gao Xinqin, Zheng Haiyang. Operation parameters optimization method of coal flow transportation equipment based on convolutional neural network[J]. Mining, Metallurgy & Exploration, 2024, 41(4): 1793-1806.
- [4] Bao Jiusheng, Zhang Quanli, Ge Shirong, et al. Basic research and application practice of unmanned auxiliary transportation system in coal mine[J]. Journal of China Coal Society, 2023, 48(2): 1085-1098. [鲍久圣, 章全利, 葛世荣, 等. 煤矿井下无人化辅助运输系统关键基础研究及应用实践[J]. 煤炭学报, 2023, 48(2): 1085-1098.]
- [5] Gao Xinqin, Yang Xueqi, Zheng Haiyang. Residual life prediction method of belt conveyors based on MDT learning [J]. China Mechanical Engineering, 2024, 35(8): 1435-1448. [高新勤, 杨学琦, 郑海洋. 基于多源域迁移学习的带式输送机剩余寿命预测方法[J]. 中国机械工程, 2024, 35(8): 1435-1448.]
- [6] Liao Linxia, Köttig F. Review of hybrid prognostics approaches for remaining useful life prediction of engi-

- neered systems, and an application to battery life prediction [J]. *IEEE Transactions on Reliability*, 2014, 63(1): 191–207.
- [7] Li Tianmei, Si Xiaosheng, Liu Xiang, et al. Data-model interactive remaining useful life prediction technologies for stochastic degrading devices with big data [J]. *Acta Automatica Sinica*, 2022, 48(9): 2119–2141. [李天梅, 司小胜, 刘翔, 等. 大数据下数模联动的随机退化设备剩余寿命预测技术 [J]. *自动化学报*, 2022, 48(9): 2119–2141.]
- [8] Li Tianmei, Pei Hong, Si Xiaosheng, et al. Prognosis for stochastic degrading systems with massive data: A data-model interactive perspective [J]. *Reliability Engineering & System Safety*, 2023, 237: 109344.
- [9] Huang Zeyi, Xu Zhengguo, Wang Wenhai, et al. Remaining useful life prediction for a nonlinear heterogeneous Wiener process model with an adaptive drift [J]. *IEEE Transactions on Reliability*, 2015, 64(2): 687–700.
- [10] Zhang Qiang, Zhang Jiayao, Lv Fuyan. Prediction of pick wear degradation states of road header based on Wiener process [J]. *Journal of Vibration and Shock*, 20, 42(1): 207–214. [张强, 张佳瑶, 吕馥言. 基于维纳过程截齿磨损失退化预测研究 [J]. *振动与冲击*, 20, 42(1): 207–214.]
- [11] Peng Weiwen, Li Yanfeng, Yang Yuanjian, et al. Bivariate analysis of incomplete degradation observations based on inverse Gaussian processes and copulas [J]. *IEEE Transactions on Reliability*, 2016, 65(2): 624–639.
- [12] Wang Haikun, Huang Hongzhong, Li Yanfeng, et al. Condition-based maintenance with scheduling threshold and maintenance threshold [J]. *IEEE Transactions on Reliability*, 2015, 65(2): 513–524.
- [13] Pei Hong, Hu Changhua, Si Xiaosheng, et al. Review of machine learning based remaining useful life prediction methods for equipment [J]. *Journal of Mechanical Engineering*, 2019, 55(8): 1–13. [裴洪, 胡昌华, 司小胜, 等. 基于机器学习的设备剩余寿命预测方法综述 [J]. *机械工程学报*, 2019, 55(8): 1–13.]
- [14] Khan S, Yairi T. A review on the application of deep learning in system health management [J]. *Mechanical Systems and Signal Processing*, 2018, 107: 241–265.
- [15] Li Xiang, Ding Qian, Sun Jianqiao. Remaining useful life estimation in prognostics using deep convolution neural networks [J]. *Reliability Engineering & System Safety*, 2018, 172: 1–11.
- [16] Zhou Yu, Fang Qian, Pei Zexuan, et al. Fault diagnosis of rolling bearing based on improved sparrow search algorithm optimized LSTM [J]. *Advanced Engineering Sciences*, 2024, 56(2): 289–298 [周玉, 房倩, 裴泽宣, 等. 基于改进麻雀搜索算法优化 LSTM 的滚动轴承故障诊断 [J]. *工程科学与技术*, 2024, 56(2): 289–298.]
- [17] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [J]. *Advances in neural information processing systems*, 2017, 30: 1–11.
- [18] Li Guorui, Wu Yajun, Wang Ying, et al. Attention-based remaining useful lifetime prediction method for industrial Internet of Things [J]. *Advanced Engineering Sciences*, 2022, 54(6): 67–74. [李国瑞, 武雅君, 王颖, 等. 基于注意力的工业物联网设备剩余寿命预测方法 [J]. *工程科学与技术*, 2022, 54(6): 67–74.]
- [19] Deng Feiyue, Chen Zhe, Hao Ruijiang, et al. Research on bearing remaining useful life prediction based on an MsTCN-Transformer model [J]. *Journal of Vibration and Shock*, 2024, 43(4): 279–287. [邓飞跃, 陈哲, 郝如江, 等. 基于 MsTCN-Transformer 模型的轴承剩余使用寿命预测研究 [J]. *振动与冲击*, 2024, 43(4): 279–287.]
- [20] Sun Tao, Zhou Cheng, Duan Xiaodong, et al. Digital twin network (DTN): Concepts, architecture, and key technologies [J]. *Acta Automatica Sinica*, 2021, 47(3): 569–582. [孙滔, 周铨, 段晓东, 等. 数字孪生网络 (DTN): 概念、架构及关键技术 [J]. *自动化学报*, 2021, 47(3): 569–582.]
- [21] Jiang Xianliang, Chen Lingyu, Zheng Jieji, et al. High-precision control method of direct drive components based on digital twin model [J]. *Journal of Mechanical Engineering*, 2021, 57(17): 98–109. [江献良, 陈凌宇, 郑杰基, 等. 基于数字孪生模型的直驱部件高精度控制方法 [J]. *机械工程学报*, 2021, 57(17): 98–109.]
- [22] Yang Linyao, Chen Siyuan, Wang Xiao, et al. Digital twins and parallel systems: State of the art, comparisons and prospect [J]. *Acta Automatica Sinica*, 2019, 45(11): 2001–2031. [杨林瑶, 陈思远, 王晓, 等. 数字孪生与平行系统: 发展现状、对比及展望 [J]. *自动化学报*, 2019, 45(11): 2001–2031.]
- [23] Hazrathosseini A, Moradi Afrapoli A. The advent of digital twins in surface mining: Its time has finally arrived [J]. *Resources Policy*, 2023, 80: 103155.
- [24] Chi Huanlei, Yuan Zhi, Cao Yan, et al. Study on digital twin-based smart fully-mechanized coal mining workplace monitoring technology [J]. *Coal Science and Technology*, 2021, 49(10): 153–161. [迟焕磊, 袁智, 曹琰, 等. 基于数字孪生的智能化工作面三维监测技术研究 [J]. *煤炭科学技术*, 2021, 49(10): 153–161.]
- [25] Ding Hua, Yang Liangliang, Yang Zhaojian, et al. Health prediction of shearers driven by digital twin and deep learning [J]. *China Mechanical Engineering*, 2020, 31(7): 815–823. [丁华, 杨亮亮, 杨兆建, 等. 数字孪生与深度学习融合驱动的采煤机健康状态预测 [J]. *中国机械工程*, 2020, 31(7): 815–823.]
- [26] Yang Chunyu, Bu Lingchao, Chen Bin. Operation optimization method of long-distance belt conveyor driven by digital twins [J]. *China Industrial Economics*, 2024, 11: 2204–

2218. [杨春雨, 卜令超, 陈斌. 数字孪生驱动的长距离带式输送机运行优化方法[J]. 自动化学报, 2024, 11: 2204–2218.]
- [27] Ge Shirong, Zhang Fan, Wang Shibo, et al. Digital twin for smart coal mining workplace: Technological frame and construction[J]. *Journal of China Coal Society*, 2020, 45(6): 1925–1936. [葛世荣, 张帆, 王世博, 等. 数字孪生智采工作面技术架构研究[J]. 煤炭学报, 2020, 45(6): 1925–1936.]
- [28] Lin Shan, Dong Miao, Cao X, et al. The pre-trained explainable deep learning model with stacked denoising autoencoders for slope stability analysis[J]. *Engineering Analysis with Boundary Elements*, 2024, 163: 406–425.
- [29] Tijjani S, Ab-Wahab M N, Mohd-Noor M H. An enhanced particle swarm optimization with position update for optimal feature selection[J]. *Expert Systems with Applications*, 2024, 247: 123337.
- [30] Liu Shujun, Xu Tong, Du Xiaoze, et al. A hybrid deep learning model based on parallel architecture TCN–LSTM with Savitzky–Golay filter for wind power prediction[J]. *Energy Conversion and Management*, 2024, 302: 118122.
- [31] Shi Jiayu, Zhong Jingshu, Zhang Yuxuan, et al. A dual attention LSTM lightweight model based on exponential smoothing for remaining useful life prediction[J]. *Reliability Engineering & System Safety*, 2024, 243: 109821.
- [32] Qian Yuning, Yan Ruqiang, Gao R X. A multi-time scale approach to remaining useful life prediction in rolling bearing[J]. *Mechanical Systems and Signal Processing*, 2017, 83: 549–567.
- [33] Liu Yongbin, He Bing, Liu Fang, et al. Remaining useful life prediction of rolling bearings using PSR, JADE, and extreme learning machine[J]. *Mathematical Problems in Engineering*, 2016, 2016: 8623530.
- [34] Liao Haitao, Zhao Wenbiao, Guo Huairui. Predicting remaining useful life of an individual unit using proportional hazards model and logistic regression model[C]// *Proceedings of the 2006 Annual Reliability and Maintainability Symposium*. Newport Beach: IEEE, 2006: 127–132.
- [35] Ben Ali J, Chebel–Morello B, Saidi L, et al. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network[J]. *Mechanical Systems and Signal Processing*, 2015, 56: 150–172.
- [36] Yan Mingming, Wang Xingang, Wang Bingxiang, et al. Bearing remaining useful life prediction using support vector machine and hybrid degradation tracking model[J]. *ISA Transactions*, 2020, 98: 471–482.
- [37] Guo Liang, Li Naipeng, Jia Feng, et al. A recurrent neural network based health indicator for remaining useful life prediction of bearings[J]. *Neurocomputing*, 2017, 240: 98–109.
- [38] Chang Zihan, Yuan Wei, Huang Kou. Remaining useful life prediction for rolling bearings using multi-layer grid search and LSTM[J]. *Computers and Electrical Engineering*, 2022, 101: 108083.
- [39] Gupta M, Wadhvani R, Rasool A. A real-time adaptive model for bearing fault classification and remaining useful life estimation using deep neural network[J]. *Knowledge-Based Systems*, 2023, 259: 110070.

Deep Learning Based 3D Visualization Health Condition Monitoring Method for Anchor Digging Machines

YANG Xueqi^{1,2}, GAO Xinqin^{1*}, ZHENG Haiyang¹, YANG Jun²

(1. School of Mechanical and Precision Instrument Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. Business-intelligence of Oriental Nations Corporation Limited, Beijing 100025, China)

Abstract:

Objective In coal mining, anchor digging machines operate under harsh and complex conditions. They are subjected to high-intensity loads, resulting in frequent failures, and the challenge of effective health management becomes increasingly prominent. Therefore, it is crucial to monitor the operational status of anchor digging machines and ensure their reliable performance. This study integrates deep learning and 3D visualization technology, designs a comprehensive health monitoring system framework, and proposes a health monitoring method for anchor digging machines.

Methods Based on deep learning, a data-driven remaining useful life (RUL) prediction method was proposed for key components of anchor digging machines. A dual time-length transformer (DT) RUL prediction model incorporating a stacked denoising autoencoder (SDAE) was constructed (SDAE–DT Net), and particle swarm optimization (PSO) was used for model hyperparameter optimization. The model possessed the structure of dual time-length encoding, which meant that the features of long-time sequences were retained and allowed efficient processing of tightly connected short-time series data. SDAE improved the model, which accurately predicted the RUL in the presence of significant noise interference in the dataset. Experimental validation was conducted using the actual production dataset sourced from the coal mine and the Intelligent Maintenance System (IMS) dataset. The results showed that the SDAE–DT Net model achieved the highest accuracy and the best prediction performance. On this basis, a 3D visualization health condition monitoring method of the anchor digging machine with data interaction was proposed. The 3D model of the anchor digging machine and the coal mining geological model were constructed using 3D visualization modeling technology. Finally, combined with examples, the 3D visualization health condition monitoring system of the anchor digging machine was developed, which realized the data mapping between the integrated coal mining working face and the 3D visualization model and verified the correct-

ness and feasibility of the method proposed in this study.

Results and Discussions For the performance validation experiments of the SDAE–DT Net model, the sensitivity analysis experiments for PSO hyperparameter optimization showed that the best results were achieved when the population size and inertia factor were 40 and 0.5, respectively. The optimal hyperparameters were: the number of iterations was 239, the number of coder/decoder layers was [4, 4], the number of training samples was 153, and the number of hidden neurons was 107. At this point, the PSO–SDAE–DT Net model reached the optimal value of each evaluation index in the training set as 0.157, 0.899, 0.192, and 0.087. The ablation experiments explored the effects of the improvements on the model through DT and SDAE. The results showed that the SDAE–DT Net model was significantly more stable during the training process than the other three experimental sets due to its ability to capture deep features and suppress noise, with a loss of 0.087. Comparison experiments of the prediction results with commonly used models, such as BiGRU, LSTM, and BiLSTM, similarly demonstrated the superiority of the proposed method. Compared with multiple existing methods, experiments were conducted using the IMS dataset. The results showed that the SDAE–DT Net model has an RMSE value of 0.056 and the best prediction error of 48.36 min, which was the best performance among the models compared. The prediction time of the proposed model was 32 seconds, which was greater than the SVM model's 28 seconds, but the RMSE value was less than 1.214, so both models have their advantages. As a result, the proposed model has the smallest prediction error and higher prediction accuracy. The developed three-dimensional visualization health monitoring system of the anchor digging machine can display real-time environmental data and the operating status of the digging work. In actual production, the real-time monitoring operation status of the anchor digging machine was selected from the system at a specific moment, and the normal value of the operation indices was compared to the actual value. The results showed that all indicators were within the normal range. The vibration signals of the cut-off boom bearing were collected online for prediction to verify the real-time RUL prediction effect of the SDAE–DT Net model. The results showed that the RMSE value during real-time prediction was 0.098, and the time required was 36 seconds. The predicted RUL value of the 85th sample was 917 min, and the true value was 1 009 min, with a prediction error of 2.94%. The experimental results were close to the results of the historical data.

Conclusions The designed health condition monitoring framework for anchor digging machines is capable of real-time and accurate monitoring. The constructed SDAE–DT Net model effectively integrates features from sequences of varying time lengths within the data, enhancing the RUL prediction accuracy even under noise interference. Utilizing cloud data storage and processing, the developed three-dimensional visualized health condition monitoring system for anchor digging machines enables data interaction and real-time monitoring. The proposed method supports the monitoring of operating status and coal mining anomalies and can serve as a theoretical basis for the efficient operation and maintenance of coal mining equipment.

Key words: anchor digging machines; 3D visualization; health condition monitoring; remaining useful life prediction; Transformer model

(编辑 吴芝明)

引用格式: Yang Xueqi, Gao Xinqin, Zheng Haiyang, et al. Deep learning based 3D visualization health condition monitoring method for anchor digging machines[J]. *Advanced Engineering Sciences*, 2025, 57(4): 326–341. [杨学琦, 高新勤, 郑海洋, 等. 基于深度学习的掘锚机3维可视化健康状态监测方法[J]. *工程科学与技术*, 2025, 57(4): 326–341.]