

文章编号: 1005-0523(2025)04-0048-13



## 基于深度学习的列车制动盘剩余使用寿命预测研究

朱海燕, 许晋华, 徐晨钊, 李祥坤, 周生通

(华东交通大学机电与车辆工程学院, 江西 南昌 330013)

**摘要:** 为实现制动盘剩余使用寿命的精准预测, 保障列车制动安全并优化经济性维护, 提出基于自注意力机制与长短期记忆网络融合并以裂纹扩展寿命为划分依据的预测模型。首先采集制动盘试验数据并标定工况, 建立热力耦合有限元模型获取仿真数据集; 其次构建 Time-GAN 神经网络, 通过双层 LSTM 生成器与物理约束判别器增强数据, 其分布相似性、均方根误差与决定系数均显著优于传统模型; 最后提出 BiLSTM-SA 融合预测模型, 利用双向 LSTM 和自注意力机制捕捉时序依赖与关键特征, 在单一扩展型裂纹预测中较传统 LSTM、TCN-LSTM 的 RMSE 分别下降 49.8%、46.5%, 复杂工况下 RMSE 与 Score 分别下降 25.5%、51.1%, 显著提升预测精度与鲁棒性。该研究可为高速列车制动盘的状态监测与预防性维护提供可靠的技术方案。

**关键词:** 制动盘; 疲劳裂纹; 剩余寿命预测; 时间序列生成对抗网络; 自注意力机制

**中图分类号:** U270.35; TP183

**文献标志码:** A

**本文引用格式:** 朱海燕, 许晋华, 徐晨钊, 等. 基于深度学习的列车制动盘剩余使用寿命预测研究[J]. 华东交通大学学报, 2025, 42(4): 48-61.

## Research on Prediction of Remaining Useful Life of Train Brake Disc Based on Deep Learning

Zhu Haiyan, Xu Jinhua, Xu Chenzhao, Li Xiangkun, Zhou Shengtong

(School of Mechatronics & Vehicle Engineering, East China Jiaotong University, Nanchang 330013, China)

**Abstract:** To achieve accurate prediction of the remaining useful life (RUL) of brake discs, ensure train braking safety, and optimize economical maintenance, this paper proposes a prediction model based on the fusion of self-attention mechanism and long short-term memory network (BiLSTM-SA), which takes the crack propagation life as the division basis. Firstly, the test data of brake discs are collected and the working conditions are calibrated, and a thermal-mechanical coupling finite element model is established to obtain the simulation dataset. Secondly, a Time-GAN neural network is constructed, which enhances data through a double-layer LSTM generator and a physical constraint discriminator. Its distribution similarity, root mean square error and coefficient of determination are significantly better than traditional models. Finally, the BiLSTM-SA fusion prediction model is proposed, which uses bidirectional LSTM and self-attention mechanism to capture temporal dependencies and key features. In the prediction of single expanding cracks, the RMSE is reduced by 49.8% and 46.5% compared with the traditional LSTM and TCN-LSTM, respectively. In complex working conditions, the RMSE and Score are optimized by 25.5% and 51.1%, respectively, significantly improving the prediction accuracy and robustness.

**收稿日期:** 2025-07-03

**基金项目:** 国家自然科学基金项目(52162045); 江西省自然科学基金重点项目(20232ACB204022); 轨道交通运载系统全国重点实验室开放课题(RVL2403); 江西省 2023 年度研究生创新专项资金项目(YC2023-S464)

This study can provide a reliable technical solution for condition monitoring and preventive maintenance of high-speed train brake discs.

**Key words:** brake disc; fatigue crack; remaining life prediction; time series generation adversarial network; self-attention mechanism

**Citation format:** ZHU H Y, XU J H, XU C Z, et al. Research on prediction of remaining useful life of train brake disc based on deep learning[J]. Journal of East China Jiaotong University, 2025, 42(4): 48–61.

深度学习技术作为早期机器学习演化的一种分支,相较于机器学习技术具有能够自动提取特征数据的优势<sup>[1]</sup>。其中,卷积神经网络技术凭借其在图像特征表达以及高维信息提取方面的应用逐渐进入大众视野<sup>[2-3]</sup>。卷积网络架构以原始二维图像作为输入,通过一系列卷积层与全连接层的处理,最终输出各类别对应的预测概率,为多领域研究提供了新思路。

制动盘裂纹主要由冷热循环载荷引发,高温下材料的屈服强度极限降低,即使应力变化不大也可能导致疲劳裂纹,其热疲劳寿命是指从投入使用到因循环热应力导致裂纹萌生、扩展并最终达到临界尺寸所经历的制动循环次数或使用时间<sup>[4-5]</sup>。当前主流研究多依托有限元仿真,通过FRANC3D、ZENCRACK 等专业疲劳分析软件与 ANSYS、ABAQUS 耦合,导入热力耦合结果进行裂纹扩展模拟。杨智勇等<sup>[6]</sup>明确了 SiCp/A356 复合材料制动盘的裂纹扩展前期受 SiCp 颗粒偏转与二次裂纹驱动力抑制;Wolf<sup>[7]</sup>研究发现在裂纹闭合状态下,只有当外加载荷达到一定阈值时,裂纹才重新张开,解释了裂纹闭合现象,并提出了裂纹完全张开的应力强度因子;Jiang 等<sup>[8]</sup>,Solanki 等<sup>[9]</sup>对二维裂纹模型和三维裂纹模型的闭合效应进行了深入研究,提出了闭合效应的影响参数。现有研究普遍基于疲劳损伤累计理论构建物理模型,虽为特征提取提供参考,但在复杂工况适应性上存在局限。

近年来,在工业领域应用中智能化诊断(intelligent fault diagnosis, IFD)与健康管理(prognostics and health management, PHM)依托深度学习(deep learning, DL)实现了技术突破<sup>[10]</sup>。卷积神经网络(convolutional neural network, CNN),循环神经网络(recurrent neural network, RNN),长短期记忆网络(long short-term memory, LSTM),深度神经网络(deep neural networks, DNN),自注意力机制等方

法,通过自适应特征提取与非线性映射,推动数据驱动的剩余使用寿命(remaining useful life, RUL)预测成为主流<sup>[11-15]</sup>。

相较于依赖部件运行机制及 S 寿命退化失效原理的物理模型,基于数据驱动的 RUL 预测方法能够从数据特征中找出部件退化规律,进而从海量的数据中自动提取出关键特征,并识别非线性高纬度高噪声等杂糅数据,找到关键特征与设备运行失效的映射关系,解决了复杂工况下的建模难题<sup>[16-17]</sup>。郑国康等<sup>[18]</sup>通过自编码器对原始信号进行特征提取, RUL 预测效果有明显提升;赵冬冬<sup>[19]</sup>在迁移学习的轴承健康状态评估的基础上分别从跨设备、跨工况,混合多工况 3 种情景进行退化预测;刘晓飞<sup>[20]</sup>基于 LSTM 神经网络对于滚动轴承进行了剩余使用寿命预测分析,并搭建了预测平台;李荣达<sup>[21]</sup>以动车组制动闸片为研究对象,制定了磨耗量、摩擦系数等失效判据,利用 GA-BP 神经网络对磨耗量与制动距离进行预测;Lim 等<sup>[22]</sup>利用时间窗口对原始数据进行输入批量处理,然后通过多层感知机(multi-layer perceptron, MLP)对发动机的 RUL 进行预测;袁焯等<sup>[23]</sup>通过将生成对抗网络(generative adversarial network, GAN)的生成能力与门控循环单元(gate recurrent unit, GRU)的预测能力相结合,解决了自编码器参数过多引起模型训练不充分的问题;季文强<sup>[24]</sup>提出一种基于 Autoencoder-TCN 混合网络的 RUL 方法,通过 K-means 聚类和数据增强等方法进行数据预处理,以提升设备系统在复杂运行工况下预测的准确性;Elsheikh 等<sup>[25]</sup>,Huang 等<sup>[26]</sup>提出了一种新的 LSTM 结构,用于在给定随机初始磨损的短监测观测序列的情况下预测 RUL;程一伟等<sup>[27]</sup>提出了一种新的 LSTM 网络叫 NLSTM,将原先的网络结构嵌套了两层,使其中的候选记忆单元改为一层新的 LSTM;王文庆等<sup>[28]</sup>利用 CNN 自动提取传感器局部特征,采用 GRU 对轴承进行 RUL 预测之后

对结果再次使用了CNN滤波,结果显著提升了准确性;王思齐<sup>[29]</sup>首次使用神经网络以及MySQL建立金属材料数据库对低周疲劳的零部件疲劳寿命预测;贾渊杰<sup>[30]</sup>提出一种CNN与LSTM的融合模型,结果证明了较传统网络模型有一定的提升。实践表明,数据驱动方法在复杂运动部件的退化规律挖掘中优势显著,而将深度学习与列车制动盘热疲劳特性结合,有望构建更精准的寿命预测模型,为行车安全与维护优化提供技术支撑。

本研究以高速列车轴装制动盘为对象,提出了基于深度学习的RUL预测框架。针对制动盘原始数据样本不足的缺陷,通过Time-GAN神经网络对其进行数据增强,丰富裂纹初始状态不同的静态特征,进一步增强训练数据集样本数量,接着构建BiLSTM-SA神经网络模型使用数据增强样本进行训练优化,最终通过制动盘试验数据集进行预测结果验证。

## 1 理论基础

### 1.1 疲劳强度寿命理论

疲劳寿命理论根据材料或者部件实际应用的场景不同,有不同的疲劳寿命理论,包括应力-寿命理论,应变-寿命理论,断裂力学理论,疲劳累积损伤理论等。制动盘寿命的判定依据疲劳累积损伤理论,Miner's Rule的计算公式为

$$\sum_i \frac{n_i}{N_i} = D_{\text{total}} = 1 \quad (1)$$

式中:  $n_i$  为第  $i$  个载荷级别下的循环次数;  $N_i$  为第  $i$  个载荷级别下材料的疲劳寿命(对应于该应力幅的循环数),通常由S-N曲线获得;  $D_{\text{total}}$  为总损伤。

### 1.2 自注意力机制

自注意力机制(self-attention mechanism)核心目的是在处理序列数据时,通过计算序列中不同位置之间的相似性,为每个输入赋予不同的权重,从而使得模型能聚焦于重要信息,减少对外部信息的依赖(图1)。图1中  $W$  为权重。主要通过动态建模序列内部元素间的相关性,实现全局信息的高效融合,其计算公式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d}}\right)\mathbf{V} \quad (2)$$

式中:  $\mathbf{Q}$  为查询矩阵;  $\mathbf{K}$  为键矩阵;  $\mathbf{V}$  为数值矩阵;  $\sqrt{d}$  为键向量的维度。

### 1.3 模型评价指标

模型评价指标为均方根误差(root mean square error, RMSE)和评分指标(Score),均方误差是模型预测值与实际值之间的平均误差,模型预测的结果越准确则RMSE值就越小,其计算公式为

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y'_i - y_i)^2} \quad (3)$$

式中:  $y_i$  和  $y'_i$  分别为真实数据值和模型预测值;  $n$  为样本数量。

常见的Score评价指标为决定系数,用于衡量模型预测值与实际值之间的拟合程度,决定系数越接近1代表预测性能越好。具体的计算公式为

$$\text{Score} = \begin{cases} \sum_{i=1}^n e^{\frac{y'_i - y_i}{13}} - 1, & y'_i - y_i < 0 \\ \sum_{i=1}^n e^{\frac{y'_i - y_i}{10}} - 1, & y'_i - y_i > 0 \end{cases} \quad (4)$$




图1 自注意力机制网络结构图

Fig. 1 Structure diagram of self-attention mechanism network



根据式(3)与式(4)可知, RMSE的数值越小代表数据越接近真实样本, 模型预测性能越优异。

## 2 Time-GAN 数据增强网络模型

### 2.1 算法流程

图2展示了Time-GAN神经网络的算法流程。它由4个模块组成, 分别为嵌入模块、恢复模块、生成模块以及判别模块。其中嵌入模块与恢复模块属于自动编码组件, 生成模块以及判别模块为对抗组件, 两者联合训练, 使Time-GAN同时学习编码特征, 生成表达数据以及跨时间的迭代。

首先, 制动盘裂纹扩展的训练数据(温度, 振动, 压力, 对流系数等时序数据输入)通过嵌入模块在低维的潜在空间中输出一维时序数据, 而对抗网络则在此潜在空间内运行。然后, 生成器通过添加随机噪音的方式, 对低维的训练数据进行数据增强, 并与判别器进行对抗训练。最后生成的一维数据输出至潜在空间, 通过恢复模块转化为多维向量数据。其中自编码网络即嵌入函数在对多维数据进行压缩以及恢复模块进行维度扩展时会产生数据重构损失, 在低维潜在空间内的生成对抗网络在生成数据时会产生无监督对抗损失, 最后在两个网络与潜在空间进行数据传输时会产生一定的有监督误差损失。Time-GAN神经网络的综合损失为3个损失之和, 因此需综合考虑各损失占比进行联合训练, 最终实现高准确率的数据增强效果。

### 2.2 网络结构

图3为生成器网络结构图。生成器网络主要由

两个部分组成, 首先是主通路上的双层LSTM与Dropout循环模块, 将潜在空间内一维的制动盘剩余寿命数据输入至LSTM神经网络并添加随机噪音, 在输出结果时通过正则化Dropout, 最终通过tanh激活函数将数据输出至 $(-1, 1)$ 。tanh函数相较于Sigmoid具有对称性的优势。在面对制动盘裂纹扩展数据中, 由于残余应力会产生拉压应力, 因此数据样本中存在负值, 而对称性使得tanh在处理负输入时表现较好, 计算公式为

$$\tanh h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5)$$

式中:  $e$ 为自然对数的底数;  $x$ 为输入值。

完成一次主通路之后, 生成器在tanh后进行时序标签的数据统计, 将全部数据再次输入第二次循环, 经过循环后的数据通过Liner线性层输出, 最终生成器将生成结果与时序数据标签进行拼接。

通过分析研究, Time-GAN神经网络主要包括3种损失, 嵌入损失(embedding loss), 恢复损失(reconstruction loss)以及对抗损失(adversarial loss), 3种损失分别代表无监督对抗损失, 有监督误差损失, 数据重构损失。总损失函数即为3个损失函数部分的加权和, 计算公式为

$$L_{\text{total}} = L_{\text{embed}} + L_{\text{recon}} + L_{\text{adv}} \quad (6)$$

式中:  $L_{\text{embed}}$ 为嵌入损失, 通过欧几里得距离来衡量生成数据与真实数据在潜在空间的差异;  $L_{\text{recon}}$ 是恢复损失, 可采用L2损失来衡量生成数据和真实数据之间的差异;  $L_{\text{adv}}$ 为对抗损失, 用于训练生成器和判别器。




图2 Time-GAN神经网络算法流程

Fig. 2 Algorithm flow of Time-GAN neural network








图5 BiLSTM-SA 算法流程图

Fig. 5 Algorithm flow chart of BiLSTM-SA network

本章模型验证的测试数据集。通过比较制动盘裂纹寿命生成数据与原始数据的分布性检验模型性能,并使用t-SNE降维技术对生成效果进行可视化展示。另外,使用RCGAN、T-Forcing和P-Forcing主流时序数据增强模型对制动盘裂纹扩展剩余使用寿命数据集进行数据增强实验,以评估和对比模型性能差异,进而比较Time-GAN神经网络对制动盘剩余使用寿命数据样本的数据生成表现和效果。

#### 4.1 数据集描述

训练数据集选取了对于预测模型的准确性至关重要的16个输入特征,各输入特征的名称及具体含义如表1所示。部分输入特征为静态特征,如裂纹的初始状态,包括裂纹的初始长度和裂纹的初始角度,裂纹的长短半径比,其余均为随时间序列变化的动态特征。

如表1所示,制动盘状态监测数据由多个传感器参数组成,各特征数值类型和单位均不相同,这将给后续的预测带来较大的误差,因此有必要通过归一化处理消除特征之间的量纲差异,增强数据的稳定性。为此采用最大最小归一化操作对原始数据进行预处理,使得监测值在 $[-1,1]$ ,具体表达式为

$$x' = 2 \frac{x - x_{\min}}{x_{\max} - x_{\min}} - 1 \quad (11)$$

式中:  $x_{\max}$  与  $x_{\min}$  分别是该参数在其集合中的最大

表1 特征参数详细信息

Tab.1 Detailed information of characteristic parameters

| 状态参数 | 具体描述              | 单位                    |
|------|-------------------|-----------------------|
| T1   | 制动盘盘面最高温度(裂纹植入点处) | K                     |
| P10  | 制动盘闸片压力           | kN                    |
| S1   | 制动盘振动激励频谱         | mm                    |
| P20  | 制动盘等效残余应力(裂纹植入点处) | MPa                   |
| P30  | 制动盘周向应力(裂纹植入点处)   | MPa                   |
| P40  | 制动盘径向应力(裂纹植入点处)   | MPa                   |
| P50  | 制动盘轴向应力(裂纹植入点处)   | MPa                   |
| C1   | 制动盘外表面对流换热系数(平均值) | W/(m <sup>2</sup> ·K) |
| C2   | 制动盘内表面对流换热系数(平均值) | W/(m <sup>2</sup> ·K) |
| V1   | 列车运行速度            | m/s                   |
| L1   | 裂纹初始长度            | mm                    |
| a/c  | 裂纹的长短半径比          | —                     |
| A1   | 裂纹初始角度            | (°)                   |

数值与最小数值,通过将每个参数减去其集合中的最小数值并与总体集合长度相除,即可得到其在集合中的归一化统一量纲数据。

在模型训练之前需对特征数据进行选取,因为其中的静态特征通过后续模型的线性层即可添加其对制动裂纹扩展寿命的影响比例,这些数值与RUL之间没有直接关联需要去除。

基于有限元的同工况模拟仿真,通过间接耦合法,在仿真计算中将高速列车制动过程视为匀减速运动,并假设闸片压力恒定。基于间接耦合方法对制动盘应力场进行数值仿真(图6),将热通量施加制动盘后得到的温度场结果作为边界条件施加在制动盘模型上。不同制动工况产生的热残余应力数值及分布存在差异,共选取5种不同速度不同制动方式下的制动工况,具体的制动工况如表2所示。

基于不同制动工况下的输入特征参数,对仿真的初始边界条件进行相应的调整,计算不同制动工况下的残余热应力,以300 km/h紧急制动工况下列车制动结束后1 000 s为例,其结果如图7




图6 制动盘有限元计算流程

Fig. 6 Finite element calculation process of brake disc

表2 制动工况参数

Tab.2 Brake working condition parameters

| 制动工况                  | 初速度/<br>(km/h) | 轴重/<br>t | 制动时<br>间/s | 闸片压<br>力/kN | 摩擦<br>系数 |
|-----------------------|----------------|----------|------------|-------------|----------|
| 200 km/h 紧急<br>制动     | 200            | 16       | 50         | 18          |          |
| 200 km/h 常规<br>制动     | 200            | 16       | 50         | 17          |          |
| 300 km/h 常规<br>制动     | 300            | 16       | 75         | 28          | 0.435    |
| 300 km/h 紧急<br>制动     | 300            | 16       | 75         | 29          |          |
| 270 km/h 常规<br>一次恒压制动 | 270            | 16       | 68         | 26          |          |

所示。分析图7可知,列车制动结束后,制动盘的残余拉应力集中在制动盘表面中心处与散热筋交界处,最大值为210.56 MPa,其余工况下的残余拉应力结果分布位置相似,而拉应力数值存在差异。

在模型训练前需进行特征筛选,由于静态特征对制动裂纹扩展寿命的影响能够通过模型线性层量化表征,且其数值与 RUL 无直接映射关系,故应予以剔除。图8给出了Ansys仿真训练集中4种常见的紧急制动工况的监测特征归一化数据,分别是T1、V1、P10、P20、P30、P40、P50、C1、C2。

AE: 瞬态结构

等效应力

类型: 等效(Von-Mises) 应力

单位: MPa

210.56 最大  
187.28  
164  
140.72  
117.44  
94.159  
70.877  
47.596  
24.315  
1.033 9 最小






图7 制动盘应力场分布云图

Fig. 7 Stress field distribution nephogram of brake disc


试验数据集以西南交大制动试验平台的试验数据为基础,其试验基于已经产生裂纹的制动盘,对其进行1:1台架试验。试验结果出现众多不同的裂纹初始长度,且存在各种龟裂纹,因此对于裂纹的选取仅考虑制动盘的失效判据裂纹即径向主裂纹。在进行径向主裂纹长度的测量过程中,若存在多条径向主裂纹尖端彼此接近且未完全贯通,裂纹尖端间距小于5 mm,则可将其视为单一裂纹进行尺




(a) 200 km/h 紧急制动



(b) 250 km/h 紧急制动



(c) 270 km/h 紧急制动



(d) 300 km/h 紧急制动

图8 制动盘仿真各项输入特征参数

Fig. 8 Input characteristic parameters for brake disc simulation



寸测定。对于非共线的多条径向裂纹,若其周向间距小于2 mm,则将其合并为一条裂纹进行长度测定。至于径向主裂纹尖端的龟裂纹,由于其尺寸微小且呈网状分布,故不纳入主裂纹长度的测量范畴。

试验条件下最高速度可达300 km/h,制动次数共1 001次,其制动压力载荷施加顺序如表3所示。制动过程中通过喷洒液态水冷却,以便快速降低制动盘的温度。

对制动盘试验数据与表1所示特征参数进行数据归一化处理,并保留原始噪音,制动盘试验数据集如图9所示。

4.2 数据增强结果

数据增强后的制动盘裂纹扩展寿命数据为高纬度数据,由于具有多个维度特征难以通过二维图片展示,因此需要对其进行降维可视化。通过t-SNE (t-distributed stochastic neighbor embedding)降维方法对生成数据结果进行降维操作,将高维数据映射到二维或三维空间,高维度空间相似度计算公式为

$$p_{ji} = \frac{\exp\left(-\frac{d_{ij}^2}{2\sigma_i^2}\right)}{\sum_{k \neq i} \exp\left(-\frac{d_{ik}^2}{2\sigma_i^2}\right)} \quad (12)$$

表3 制动盘台架试验的载荷工况参数  
Tab.3 Load condition parameters of brake disc bench test

| 阶段   | 制动类别 | 制动次数/次 | 速度/( km/h ) | 制动压力  |
|------|------|--------|-------------|-------|
| 第1阶段 | B7   | 126    | 200         | B7级变压 |
|      | B7   | 72     | 180         | B7级变压 |
|      | B7   | 90     | 200         | B7级变压 |
| 第2阶段 | EB   | 159    | 200         | B7级变压 |
|      | B7   | 66     | 200         |       |
|      | EB   | 55     | 200         |       |
|      | HY   | 13     | 200         | 29 kN |
|      | HY   | 75     | 200         | 27 kN |
|      | HY   | 75     | 200         | 28 kN |
| 第3阶段 | HY   | 9      | 118         | 28 kN |
|      | B7   | 45     | 118         | B7级变压 |
| 第4阶段 | HY   | 3      | 120         | 28 kN |
|      | HY   | 3      | 160         | 28 kN |
|      | HY   | 8      | 200         | 28 kN |
|      | HY   | 2      | 120         | 29 kN |
|      | HY   | 2      | 160         | 29 kN |
|      | HY   | 198    | 200         | 29 kN |

式中:  $\sigma_i$  为点中心的高斯核贷款,通过困惑度控制。  
获取相似度后需继续优化目标,最小化高位空间概率分布的KL散度计算公式为




图9 制动盘试验数据各项输入特征参数  
Fig.9 Input characteristic parameters of brake disc test data

$$KL(P||Q) = \sum_{i \neq j} p_{ij} \log \frac{p_{ij}}{q_{ij}} \quad (13)$$

通过t-SNE对基于Time-GAN神经网络生成的制动盘裂纹扩展失效数据以及其他主流算法进行降维,对生成的结果进行可视化,其结果如图10所示。分析图10可知,RCGAN与Time-GAN两个模型的分布一致性要明显优于T-Forcing与P-Forcing模型,尤其是数据的重叠度。但是在降维特征负数区间内,RCGAN的数据存在一定的数据结构偏离,生成数据与原始数据出现一定的分叉。而P-Forcing与T-Forcing由于对时序数据中时间关联性捕捉不到位,出现多个离散数据点的异常点,对于时序数据存在的数据结构也有明显的结构偏离。

#### 4.3 RUL预测结果

通过构建的BiLSTM-SA模型对制动盘试验中的有裂纹扩展数据进行拟合,并根据选中的30条裂纹进行编号排列,其拟合结果如图11所示。分析图11可知,模型预测曲线与试验趋势大致相同,但存在局部偏差。在裂纹编号2、6、9、10、21、26这几个裂纹的剩余寿命预测上,预测值要高于试验数据。

BiLSTM-SA模型对制动盘制动试验的裂纹扩展数据总体预测效果较好,其平均MAE(绝对误差)为18.26, RMSE(均方误差)为19.85。

基于Time-GAN神经网络进行数据增强后,在生成的数据中随机选取250条具有不同裂纹长度的制动盘寿命数据样本,通过BiLSTM-SA模型对生成数据的制动盘剩余使用寿命进行预测,结果如图12所示。分析图12可知, BiLSTM-SA预测模型在制动盘裂纹寿命低于60 000次的预测结果中表现优异,其平均RMSE为18.79, 平均MAE为17.86。而对于裂纹扩展寿命大于60 000次的裂纹寿命仿真数据,模型的平均RMSE为19.31, 平均MAE为18.02。这表明,尽管模型在长寿命裂纹预测上存在一定的局限性,但其整体性能依然表现良好,特别是在预测短寿命裂纹方面表现尤为突出。

为更直观地展示建立的BiLSTM-SA模型在制动盘裂纹扩展寿命预测数据中的性能,在制动盘裂纹寿命试验数据中,分别在A面以及B面各选取两条裂纹扩展数据,对比两种LSTM模型(单一LSTM、TCN-LSTM)在训练过程中的性能表现,不




图10 t-SNE降维可视化结果对比

Fig. 10 Comparison of t-SNE dimensionality reduction visualization results




图11 制动盘裂纹剩余寿命试验数据趋势拟合  
Fig. 11 Trend fitting of brake disc crack remaining life test data

同模型预测结果如图13所示。分析图13可知,在A12裂纹中TCN-LSTM的预测结果与真实值偏差严重,尤其是裂纹扩展在制动次数200~800次出现短暂的失真现象,而BiLSTM-SA模型的拟合效果明显优于其余两个模型。在A13裂纹拟合中,单一




图12 制动盘裂纹剩余寿命仿真数据趋势拟合  
Fig. 12 Trend fitting of brake disc crack remaining life simulation data

的LSTM模型与TCN-LSTM模型在制动次数400~800次均出现偏离现象,具体原因是A13裂纹的扩展长度较大,两个模型对于数据特征的全局性能比BiLSTM-SA模型差。

如表4所示,对于3个模型的拟合效果,通过评价指标均方误差RMSE与得分函数Score对模型进







图13 不同算法裂纹扩展寿命预测结果  
Fig. 13 Prediction results of crack propagation life by different algorithms



表4 3种模型结果对比  
Tab.4 Comparison of the results of three models

| 模型        | A12  |       | A13  |       | B2   |       | B14  |       |
|-----------|------|-------|------|-------|------|-------|------|-------|
|           | RMSE | Score | RMSE | Score | RMSE | Score | RMSE | Score |
| LSTM      | 18.4 | 671   | 24.3 | 1 081 | 19.8 | 693   | 21.4 | 784   |
| TCN-LSTM  | 26.5 | 1 240 | 22.8 | 846   | 18.5 | 682   | 19.5 | 711   |
| BiLSTM-SA | 13.7 | 328   | 12.2 | 319   | 14.1 | 353   | 15.8 | 427   |

行量化处理。分析表4可知,与单一LSTM神经网络以及TCN-LSTM神经网络相比,构建的BiLSTM-SA神经网络在4个随机的制动盘裂纹试验数据上均有显著的性能差异。以裂纹编号A13为例,在单一扩展的裂纹状态中,BiLSTM-SA相比于单一的LSTM结构网络模型以及TCN-LSTM模型,其RSME分别下降了49.8%,46.5%,Score得分函数指标分别下降了70.5%,62.3%。而在扩展裂纹中相对复杂的裂纹编号A12与B14中,其RSME对比最好的模型数据结果分别下降了25.5%,19.0%,Score得分函数指标分别下降了51.1%,39.9%。因此可得,所提出的算法对于制动盘裂纹扩展寿命的预测性能表现优异,具有更高的准确性。

## 5 结论

采用Time-GAN数据增强与BiLSTM-SA融合建模方法,对多工况多裂纹状态下的列车制动盘剩余使用寿命(RUL)进行了系统研究,得出以下结论。

1) 提出的Time-GAN神经网络以制动次数为序列划分依据,通过双层LSTM生成器与物理准则约束的判别器优化模型,生成数据的分布相似性、均方根误差与决定系数均显著优于传统RCGAN等模型。

2) 构建的双向长短期记忆-自注意力机制融合模型(BiLSTM-SA),通过双向LSTM捕捉退化数据的时序依赖,结合自注意力机制强化关键特征权重分配。在单一裂纹扩展场景中,较传统LSTM与TCN-LSTM模型,预测RMSE分别降低49.8%和46.5%,Score分别优化70.5%与62.3%;复杂工况下RMSE与Score仍实现25.5%和51.1%的提升,验证了模型在多维度退化特征识别中的高精度与鲁棒性。

3) 在以单一径向裂纹为失效判据的场景中,BiLSTM-SA模型可自适应提取制动盘失效特征,

精准预测裂纹扩展长度及RUL,其性能显著优于典型LSTM变种算法,为高速列车制动盘的状态监测与预防性维护提供了可靠的技术方案。

## 参考文献:

- [1] 程一伟,朱海平,吴军,等.基于嵌套长短期记忆网络的机械装备剩余使用寿命预测方法[J].中国科学:技术科学,2022,52(1):76-87.  
CHENG Y W, ZHU H P, WU J, et al. A remaining useful life prediction method based on nested long short-term memory network for mechanical equipment[J]. Scientia Sinica (Technologica), 2022, 52(1): 76-87.
- [2] 王文庆,郭恒,范启富.基于CNN与GRU的航空发动机剩余寿命预测[C]//中国自动化会控制理论专业委员会.第37届中国控制会议论文集(F).北京:《中国学术期刊(光盘版)》电子杂志社有限公司,2018:546-551.  
WANG W Q, GUO H, FAN Q F. Predict remaining useful life of aerospace engine based on CNN and GRU[C]// Control Theory Committee of China Automation Society. Proceedings of the 37th Chinese Control Conference(F). Beijing: "China Academic Journal (CD)" Electronic Magazine Co., Ltd., 2018: 546-551.
- [3] 朱海燕,黎洁,肖乾,等.轮轨激励对高速列车轴装制动盘热-机耦合疲劳分析[J].机械工程学报,2024,60(4):409-419.  
ZHU H Y, LI J, XIAO Q, et al. Thermal-mechanical coupling fatigue analysis of high-speed train axle-mounted brake disc under wheel-rail excitation[J]. Journal of Mechanical Engineering, 2024, 60(4): 409-419.
- [4] 黄益昌,张继旺,苏凯新,等.高速列车铸钢制动盘表面裂纹应力强度因子分析[J].机械科学与技术,2025,44(6):1080-1089.  
HUANG Y C, ZHANG J W, SU K X, et al. Analysis of surface crack stress intensity factor for cast steel brake disc of high-speed train[J]. Mechanical Science and Technology for Aerospace Engineering, 2025, 44(6): 1080-1089.

- [5] 杨智勇, 李志强, 李卫京, 等. 制动盘摩擦面热损伤的形成机理分析[J]. 铁道机车车辆, 2012, 32(3): 14-19.  
YANG Z Y, LI Z Q, LI W J, et al. Research on forming mechanism of thermal damages of brake disc in service [J]. Railway Locomotive & Car, 2012, 32(3): 14-19.
- [6] 杨智勇, 臧家俊, 方丹琳, 等. 城轨列车制动盘 SiCp/A356 复合材料热疲劳裂纹扩展机理[J]. 材料工程, 2022, 50(7): 165-175.  
YANG Z Y, ZANG J J, FANG D L, et al. Thermal fatigue crack propagation mechanism of SiCp/A356 composites for urban rail train brake disc[J]. Journal of Materials Engineering, 2022, 50(7): 165-175.
- [7] WOLF E. Fatigue crack closure under cyclic tension[J]. Engineering Fracture Mechanics, 1970, 2(1): 37-45.
- [8] JIANG Y Y, FENG M L, DING F. A reexamination of plasticity-induced crack closure in fatigue crack propagation[J]. International Journal of Plasticity, 2005, 21(9): 1720-1740.
- [9] SOLANKI K, DANIEWICZ S R, NEWMAN J C. Finite element analysis of plasticity-induced fatigue crack closure: an overview[J]. Engineering Fracture Mechanics, 2004, 71(2): 149-171.
- [10] 温玉颖, 张晓新, 燕青芝. 高铁制动盘失效原因和改进对策[J]. 机械工程学报, 2023, 59(14): 264-276.  
WEN Y Y, ZHANG X X, YAN Q Z. Failure causes and the improvement countermeasures on high-speed brake disc[J]. Journal of Mechanical Engineering, 2023, 59(14): 264-276.
- [11] 左建勇, 王雪萍, 周苏芬, 等. 动车组制动盘热仿真方法适用性研究[J]. 中国铁道科学, 2022, 43(5): 78-86.  
ZUO J Y, WANG X P, ZHOU S F, et al. Applicability research on thermal simulation methods for EMU brake discs[J]. China Railway Science, 2022, 43(5): 78-86.
- [12] 张永超, 杨海昆, 刘嵩寿, 等. 基于RBM-CNN模型的滚动轴承剩余使用寿命预测[J]. 轴承, 2025(5): 96-101.  
ZHANG Y C, YANG H K, LIU S S, et al. Remaining useful life prediction of rolling bearings based on RBM-CNN model[J]. Bearing, 2025(5): 96-101.
- [13] 梁天添, 刘健, 梁贺焱, 等. 轴承剩余使用寿命预测的IDSA-LSTMNN[J]. 振动测试与诊断, 2025, 45(2): 273-280.  
LIANG T T, LIU J, LIANG H Y, et al. IDSA-LSTMNN for prediction of bearing remaining useful life[J]. Journal of Vibration, Measurement & Diagnosis, 2025, 45(2): 273-280.
- [14] 徐自力, 高京京, 覃曼青, 等. 基于混合机器学习模型的两级加载下金属材料的剩余疲劳寿命预测方法[J]. 机械工程学报, 2025, 61(12): 73-82.  
XU Z L, GAO J J, QIN M Q, et al. Hybrid machine learning method for remaining fatigue life prediction of the metallic materials under two-step loading[J]. Journal of Mechanical Engineering, 2025, 61(12): 73-82.
- [15] 潘美琪, 贺兴. 基于TimeGAN-Stacking的风电机组变桨系统故障诊断方法[J]. 太阳能学报, 2025, 46(1): 192-200.  
PAN M Q, HE X. Fault diagnosis method for wind turbine pitch system based on TimeGAN-Stacking[J]. Acta Energiae Solaris Sinica, 2025, 46(1): 192-200.
- [16] 苗磊, 刘杨, 田童晖, 等. 基于TimeGAN-LSTM的月径流预测模型[J]. 水电能源科学, 2024, 42(11): 12-15.  
MIAO L, LIU Y, TIAN T H, et al. Monthly runoff prediction based on TimeGAN-LSTM model[J]. Water Resources and Power, 2024, 42(11): 12-15.
- [17] 黄开远, 罗娜. 基于Attention机制改进TimeGAN的小样本时间序列预测方法[J]. 华东理工大学学报(自然科学版), 2023, 49(6): 890-899.  
HUANG K Y, LUO N. Improved TimeGAN based on Attention for time series prediction method with few shot [J]. Journal of East China University of Science and Technology, 2023, 49(6): 890-899.
- [18] 郑国康, 周峥, 严如强. 基于深度强化学习的机械装备剩余使用寿命预测方法[J]. 中国科学: 技术科学, 2023, 53(7): 1175-1188.  
ZHENG G K, ZHOU Z, YAN R Q. Method for predicting the remaining useful life of mechanical equipment based on deep reinforcement learning[J]. Scientia Sinica (Technologica), 2023, 53(7): 1175-1188.
- [19] 赵冬冬. 基于深度学习的动车组轴承状态评估与剩余使用寿命预测方法研究[D]. 北京: 北京交通大学, 2022.  
ZHAO D D. Research on EMUs bearing condition assessment and remaining useful life prediction method based on deep learning[D]. Beijing: Beijing Jiaotong University, 2022.
- [20] 刘晓飞. 基于LSTM网络的滚动轴承可靠性评估及寿命预测[D]. 大连: 大连理工大学, 2019.  
LIU X F. The Reliability assessment and remaining useful life prediction of rolling bearing based on the LSTM network[D]. Dalian: Dalian University of Technology, 2019.
- [21] 李荣达. 动车组制动闸片寿命预测及可靠性分析[D].

- 哈尔滨: 哈尔滨理工大学, 2022.
- LI R D. Brake pad life prediction and reliability analysis for electrical multiple unit[D]. Harbin: Harbin University of Science and Technology, 2022.
- [22] LIM P, GOH C K, TAN K C. A time window neural network based framework for remaining useful life estimation[C]//Vancouver: 2016 International Joint Conference on Neural Networks (IJCNN), 2016: 1746-1753.
- [23] 袁焘, 黄虹, 程骋, 等. 基于特征注意力机制的GRU-GAN航空发动机剩余寿命预测[J]. 中国科学: 技术科学, 2022, 52(1): 198-212.
- YUAN Y, HUANG H, CHENG C, et al. Remaining useful life prediction of the aircraft engine based on the GRU-GAN network with a feature attention mechanism [J]. Scientia Sinica (Technologica), 2022, 52(1): 198-212.
- [24] 季文强. 基于深度学习和不确定性量化的数据驱动剩余寿命预测方法研究[D]. 合肥: 中国科学技术大学, 2020.
- JI W Q. Research on data-driven remaining useful life prediction method based on deep learning and uncertainty quantification[D]. Hefei: University of Science and Technology of China, 2020.
- [25] ELSHEIKH A, YACOUT S, OUALI M S. Bidirectional handshaking LSTM for remaining useful life prediction [J]. Neurocomputing, 323(5):148-156.
- [26] HUANG C G, HUANG H Z, LI Y F. A bidirectional LSTM prognostics method under multiple operational conditions[J]. IEEE Transactions on Industrial Electronics, 2019, 66(11): 8792-8802.
- [27] 程一伟, 朱海平, 吴军, 等. 基于嵌套长短期记忆网络的机械装备剩余使用寿命预测方法[J]. 中国科学: 技术科学, 2022, 52(1): 76-87.
- CHENG Y W, ZHU H P, WU J, et al. A remaining useful life prediction method based on nested long short-term memory network for mechanical equipment[J]. Scientia Sinica (Technologica), 2022, 52(1): 76-87.
- [28] 王文庆, 郭恒, 范启富. 基于CNN与GRU的航空发动机剩余寿命预测[C]// 武汉: 第37届中国控制会议论文集(F), 2018: 546-551.
- WANG W Q, GUO H, FAN Q F. Predict remaining useful life of aerospace engine based on CNN and GRU[C]// Wuhan: Proceedings of the 37th Chinese Control Conference(F), 2018: 546-551.
- [29] 王思齐. 基于神经网络的低周疲劳寿命预测方法研究[D]. 大连: 大连理工大学, 2022.
- WANG S Q. Neural network based low cycle fatigue life prediction[D]. Dalian: Dalian University of Technology, 2022.
- [30] 贾渊杰. 基于深度学习的涡扇发动机剩余使用寿命预测研究[D]. 西安: 长安大学, 2022.
- JIA Y J. Research on remaining useful life prediction of turbofan engines base on deep learning[D]. Xi'an: Chang'an University, 2022.



通信作者: 朱海燕(1975—), 男, 教授, 博士, 博士生导师, 研究方向为高速列车系统动力学及疲劳强度。E-mail: zhupe-trelcao@163.com。

(责任编辑: 吴海燕)