

中文引用格式:滕春阳,李庆健,陈金刚,等.基于N-BEATS的托辊滚动轴承剩余寿命预测[J].中国安全科学学报,2024,34(增刊1):246-252.

英文引用格式:TENG Chunyang, LI Qingjian, CHEN Jingang, et al. Remaining life prediction of roller bearings based on N-BEATS[J]. China Safety Science Journal, 2024, 34(S1):246-252.

## 基于 N-BEATS 的托辊滚动轴承剩余寿命预测 \*

滕春阳,李庆健 工程师,陈金刚,张建飞,薛国庆

(国能宝日希勒能源有限公司,内蒙古 呼伦贝尔 021000)

中图分类号:X956

文献标志码:A

DOI: 10.16265/j.cnki.issn1003-3033.2024.S1.0030

**【摘要】** 为减少煤矿井下带式输送机因托辊故障带来的安全事故和经济损失,提高工作人员和机组设备的安全性和运输效率,对于不同工况下不同位置托辊滚动轴承出现的异常振动情况,应用具有深层结构和残差网络的 N-BEATS 预测模型进行滚动轴承寿命预测。首先,分析时间序列预测模型 N-BEATS 的原理及结构,并根据 N-BEATS 原理建立适用于托辊滚动轴承的寿命预测模型;然后,以某矿带式输送机托辊实际运行工况为背景,搭建基于 DVS 技术的托辊滚动轴承振动信号监测平台,采集不同工况下的托辊轴承振动信号数据;最后,将采集到的托辊滚动轴承振动数据输入到基于时间序列预测模型(N-BEATS)、卷积神经网络(RCNN)、相似性预测模型中,与真实值进行对比,并评估3种托辊滚动轴承剩余寿命预测质量。结果表明:N-BEATS 预测模型相对于 RCNN 和相似性预测模型,其平均绝对误差分别提升了 5.3%和 4.1%;N-BEATS 预测模型相对均方根误差分别提升了 6.3%和 5.2%。

**【关键词】** 基于时间序列(N-BEATS)预测模型;托辊;滚动轴承;寿命预测;带式输送机;振动信号

### Remaining life prediction of roller bearings based on N-BEATS

TENG Chunyang, LI Qingjian, CHEN Jingang, ZHANG Jianfei, XUE Guoqing

(CHN Energy Baorixile Energy Co., Ltd., Hulun Buir Inner Mongolia 021000, China)

**Abstract:** In order to reduce safety accidents and economic losses caused by roller failures of underground belt conveyors in coal mines and improve the safety and transportation efficiency of workers and unit equipment, the N-BEATS prediction model with deep structure and residual network was applied to predict the life of rolling bearings for abnormal vibration of roller bearings at different positions under different working conditions. Firstly, the principle and structure of the N-BEATS prediction model were analyzed, and a life prediction model suitable for roller bearings was established based on the N-BEATS principle. Then, a vibration signal monitoring platform for roller bearings based on DVS technology was built against the actual roller operating conditions of a conveyor belt. The vibration signals of roller bearings under different working conditions were collected. Finally, the collected vibration data of roller bearings were input into the N-BEATS model, convolutional neural network (RCNN), and similarity prediction model, and they were compared with the actual values. The remaining life prediction quality of the three types of roller bearings was evaluated. The results show that the N-BEATS prediction model has an average

absolute error increase of 5.3% and 4.1%, respectively, compared to RCNN and similarity prediction models. The relative root mean square error of the N-BEATS prediction model is increased by 6.3% and 5.2%.

**Keywords:** neural basis expansion analysis for interpretable time series (N-BEATS) prediction model; roller; rolling bearing; life prediction; belt conveyor; vibration signal

## 0 引言

带式输送机处于煤炭运输系统的中枢环节,其托辊滚动轴承的性能会随使用时间的增长逐渐衰退,且这一退化过程受到工作环境、负载状态等多种因素影响,呈现出不确定性和非线性的特征<sup>[1]</sup>。其一旦出现故障,会导致输送带撕裂、零部件挤压变形,将造成物料的大量堆积,并因链式反应而导致矿井停产造成经济损失,引起安全事故,更严重的会造成人员伤亡<sup>[2]</sup>。

众多学者对带式输送机托辊滚动轴承剩余寿命预测开展大量研究。例如:都平安等<sup>[3]</sup>利用 Workbench 软件分析了正常支撑托辊和前倾托辊的等效应力、应变云图,研究托辊疲劳寿命预测,指出提高轴承质量或保障轴承良好工作状态可提高托辊组的使用寿命;高波等<sup>[4]</sup>基于径向基函数神经网络检测托辊筒皮磨损、托辊轴承失效和托辊弯曲变形 3 种工况的故障程度,得出通过托辊的故障等级评价模型,可有效地判断托辊的故障程度;王善忠等<sup>[5]</sup>从托辊设计、材料选择、加工工艺和应用 4 个方面,探究了托辊的耐用性,并通过适当的维护方式,延长了托辊的使用寿命;李锋<sup>[6]</sup>搭建了托辊加载试验台,根据试验情况分析托辊故障原因和影响托辊使用寿命时间,得出托辊在相同载荷下,改变托辊转速和轴承动态对轴承角位移的影响;戴忠林<sup>[7]</sup>通过卷积神经网络、双向长短期记忆网络和粒子群优化算法建立托辊寿命预测模型,并于其他托辊寿命预测模型对比,得出卷积神经网络、双向长短期记忆网络和粒子群优化算法构建的预测模型平均得分更高,误差更小;姚德臣等<sup>[8]</sup>通过融合注意力机制的门控循环单元算法分析旋转机械中的滚动轴承剩余使用寿命随时间的变化趋势,预测托辊故障程度,得出融合注意力机制的门控循环单元算法在预测结果上更贴近实际寿命曲线,拟合程度高;王奉涛等<sup>[9]</sup>搭建了长短期记忆网络预测模型,通过对滚动轴承进行全寿命试验,准确分析出滚动轴承的剩余使用寿命,得出长短期记忆网络预测模型可准确预测滚动轴承剩余寿命;周哲韬等<sup>[10]</sup>提出一种基于

Transformer 模型的托辊轴承剩余使用寿命预测方法,得出 Transformer 模型累积特征相比于传统统计特征平均绝对误差降低了 92.63%,平均得分提高了 558.39%;刘琦<sup>[11]</sup>提出一种基于短时傅里叶变化和卷积神经网络算法的滚动轴承寿命预测方法,并通过托辊轴承全寿命数据集检验短时傅里叶变化和卷积神经网络算法建立的滚动轴承寿命模型,得出该轴承故障预测方法可以很好地发现轴承退化起始点;李卓漫<sup>[12]</sup>提出了基于粒子群算法和长短期记忆神经网络算法的托辊轴承使用寿命预测,得出这种预测方法具有一定的鲁棒性。针对以上学者的研究,目前带式输送机托辊滚动轴承寿命预测精度还有待提高,一些学者只通过单一寿命预测方法预测托辊滚动轴承的寿命,具有一定局限性,存在托辊滚动轴承振动信息来源于试验台,未考虑煤矿现场实际影响因素,检测信号的准确性有待加强。

鉴于此,笔者拟提出一种基于时间序列预测模型(Neural Basis Expansion Analysis for Interpretable Time Series Forecasting, N-BEATS)的托辊滚动轴承剩余寿命预测方法,通过搭建带式输送机托辊轴承故障检测试验台,采集不同工况下托辊的振动信号,并将该托辊滚动轴承剩余寿命预测模型与区域卷积神经网络(Regions with Convolutional Neural Networks, RCNN)和相似性预测模型对比,以期提高托辊滚动轴承剩余寿命预测精度。

## 1 N-BEATS 原理及结构

传统的时间序列分析法通常涉及趋势变化、周期变化、不规则波动和循环波动等变化状态的叠加或耦合。N-BEATS 的基本架构如图 1 所示。N-BEATS 神经结构由多个栈组成,每个栈由多个块结构组成。块结构的的上半部分是一个完全连接的 4 层全连接网络, $K$  为时间序列分解层数,经过 2 个分支分别输出前向  $\theta_l^f$  和后向  $\theta_l^b$  的预测系数。这里的预测系数可理解为存储着时间序列信息的低维向量;块结构的下半部分计算式如下:

$$(y_b) \hat{y}_l = G_l^f(\theta_l^f), (y_f) \hat{x}_l = G_l^b(\theta_l^b) \quad (1)$$

多个块结构连接在一起形成一个栈,并且整体上以

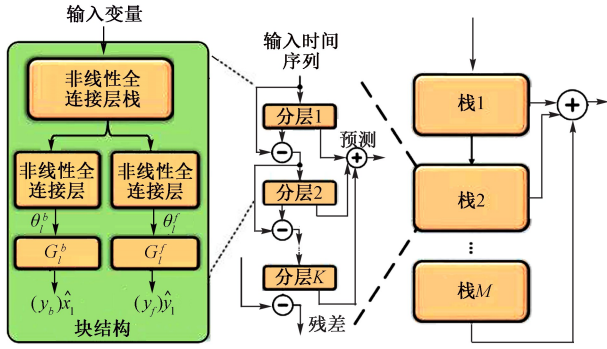


图1 N-BEATS 神经结构

Fig.1 N-BEATS nerve structure

双重残差结构展现,内部还包括前向预测残差分支和后向预测残差分支。在后向预测残差分支中,将每个块结构的 $(y_b)\hat{y}_l$ 及其接收的整个输入残差值作为下一个块结构的输入,最终作为下一个栈的输入。而在前向预测残差分支中,将每个块的输出 $(y_f)\hat{x}_l$ 进行累加,作为对应栈的输出,而模型所有栈的输出则是这些部分输出的累加结果,最终构成了整体的输出。

块是 N-BEATS 网络中的最小组成单元之一,块与堆栈结构如图 2 所示。图 2 展示了第 1 个块的结构。每个块都接受 1 个输入,并产生 2 个输出值。对于第  $l$  个块,其输入  $x_l$  来自整个模型的输入  $x$ ,而第  $l$  块的输入  $x_l$  来自第  $l-1$  块的残差输出。第 1 个块分别产生 2 个输出值,分别是回溯  $(b)\hat{x}_l$  元和预测  $(f)\hat{y}_l$  元,通常情况下,回溯值的长度是预测值长度的 2~7 倍。上述过程可由下列公式表示:

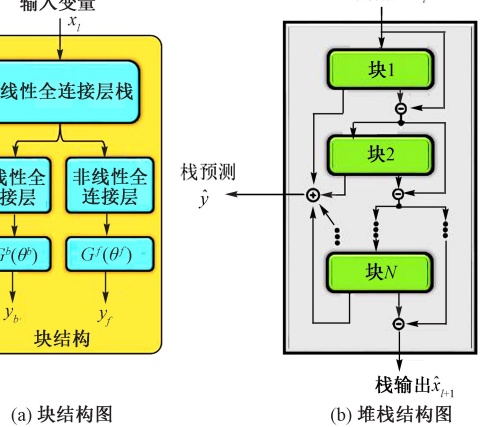
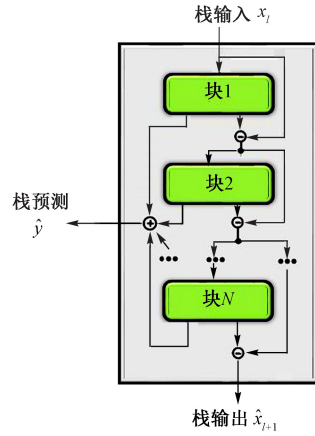
$$h_{l,1} = C(x_l), h_{l,i} = C(h_{l-1}, i) \quad (2)$$

$$h_{l,1} = \text{RELU}(w_{l,1}x_l + b_{l,1}) \quad (3)$$

$$\theta_l^b = \text{LINEAR}(h_{l,4}), \theta_l^f = \text{LINEAR}(h_{l,4}) \quad (4)$$

式中: $C$ 为带有 ReLU 激活函数的非线性全连接层; $h_{l,i}$ 为第  $l$  个块中第  $i$  层经过  $C$  后生成的映射; $w_{l,1}$ 为神经元的权重; $b_{l,1}$ 为神经元的偏置; $\theta_l^f$ 和 $\theta_l^b$ 分别为第  $l$  个块的正向预测基展开系数和后向预测基展开系数;LINEAR 为不带有任何激活函数的线性映射层。 $\theta_l^f$ 和 $\theta_l^b$ 会通过 $G_l^f$ 和 $G_l^b$ 函数生成预测输出和回溯输出,其中, $G_l^b$ 能够移除不利于后续预测的信息,而 $G_l^f$ 能够用来优化当前块预测输出的精度。 $G$ 函数是可以配置的,通过选择不同的函数能够消除输入序列的不同成分。

堆栈(stack)是 N-BEATS 网络中的另一种单元结构,图 2 中为第 1 个堆栈的结构。堆栈采用双残差拓扑结构,与块的输入输出类似,包含 1 个输入和



(a) 块结构图

(b) 堆栈结构图

图2 块与堆栈结构

Fig.2 Block and stack structures

2 个输出。第 1 个堆栈的输入等于整个模型的输入,而其他堆栈的输入 $\hat{x}_{l-1}$ 来自上 1 个堆栈传入的残差。每个堆栈会输出 1 个预测值 $\hat{y}$ ,该预测值是所有块预测的叠加总和。上述过程可表示为:

$$x_l = x_{l-1} - \hat{x}_{l-1} \quad (5)$$

$$\hat{y} = \sum_l \hat{y}_l \quad (6)$$

式中: $x_l$ 为某个栈中第 1 块的输入; $x_{l-1}$ 为某个栈中第  $l-1$  块的输入; $\hat{x}_{l-1}$ 为第  $l-1$  个块的后向预测残差; $\hat{y}$ 为每个堆栈输出的预测值; $\sum_l \hat{y}_l$ 为所有块预测的叠加总和。

## 2 建立预测模型结构

研究滚动轴承的剩余寿命预测实质上是选取能代表退化趋势的指标,进行非线性回归预测。应用神经网络预测时,通常需要讨论单变量多步预测问题。单变量多步预测结构包括直接预测结构、递归预测结构和直接递归预测结构。在这些结构中,递归预测指的是在预测时使用相同预测模型的多个周期,并将上一个周期的预测值作为下一个周期预测的输入。该过程的计算过程如下:

$$\hat{y}_{n+h} = \begin{cases} \hat{f}(y_N, \dots, y_{N-d+1}), & h = 1 \\ \hat{f}(y_{N+h-1}, \dots, y_{N+1}, y_N, \dots, y_{N-d+1}), & h \in \{2, 3, \dots, H\} \end{cases} \quad (7)$$

式中:  $h$  为已经预测的长度;  $N$  为待预测序列的长度;  $d$  为输入变量的长度;  $H$  为需要预测的总长度。直接预测是指当需要预测序列的总长度为  $H$  时, 使用  $M$  种不同的模型分别预测每个待预测的值。该预测结构将序列视为独立数据, 忽略了变量之间的相关性。

直接预测法精度较低, 其预测模型计算过程如下:

$$\hat{y}_{N+h} = \{\hat{f}_h(y_N, \dots, y_{N-d+1})\}, \quad h \in \{1, 2, \dots, H\} \quad (8)$$

利用数据集进行剩余寿命预测时, 总是希望在历史数据相对较少的情况下预测的结果更准确, 以更好地对轴承健康时间做出正确判断。因此, 需要借助递归预测结构进行预分析, 而 N-BEATS 应用的原理是直接预测结构, 因此, 文中将 2 种结构相结合以提高精度。即将上一个周期的预测值作为下一个预测周期的数据集的一部分, 其预测模型如图 3 所示。

其中,  $t$  为输入变量的长度;  $n$  为 1 个周期预测周期的长度;  $m$  为预测周期的个数。

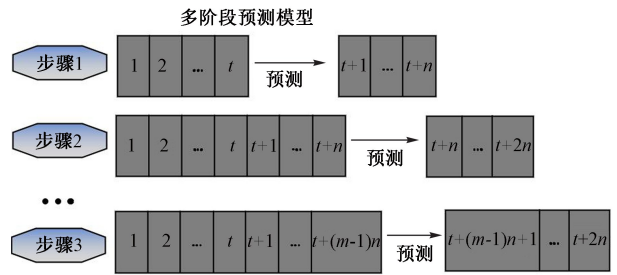


图 3 预测结构

Fig.3 Predicted structures

### 3 试验系统搭建及数据采集

#### 3.1 分布式光纤振动监测系统搭建

试验系统的硬件设施包括滚动轴承故障试验台、振动信号光纤、不同故障类型的滚动轴承、数据采集系统。试验中采用的带式输送机托辊滚动轴承故障试验系统如图 4 所示, 试验系统运转时, 轴带动轴承内圈固定不转, 轴承外圈旋转。采集到的振动信号通过特征提取、故障诊断等智能分析上传到客户端以监测设备状态。

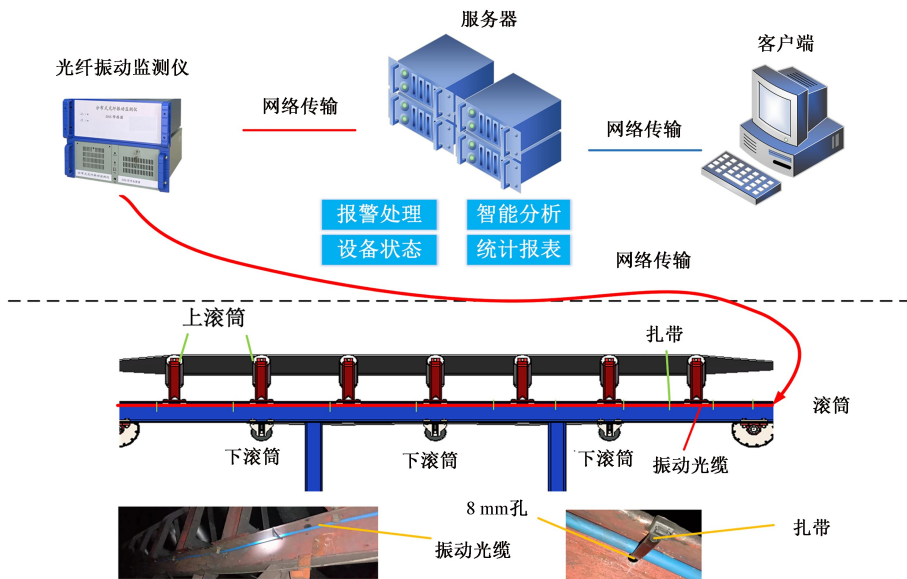


图 4 带式输送机托辊轴承故障诊断试验系统

Fig.4 Experimental system for fault diagnosis of roller bearings of belt conveyors

#### 3.2 试验数据采集方案

分布式光纤主要用于监测振动信号, 故选择 4 芯单模光缆, 常见的单模 4 芯光缆的光纤直径为  $9/125 \mu\text{m}$ , 可用于连接不同的设备或模块以实现高速数据传输和通信。根据现场地形、设备和其他障

碍物, 为使光缆能尽可能达到使用效果, 选择将光缆铺设于槽钢上部或内部。

为使光纤诊断更加准确, 选择铺设 20 m 光纤进行对比试验, 前 10 m 光纤采用打孔安装, 后 10 m 光纤直接安装在槽钢上部。铺设完成后安装光纤接头

盒和其他光缆附件。将铺设的 20 m 光纤处更换上输送机损坏托辊,经过多次测试和试验,能及时诊断出现故障的部位并报出相关位置,并通过对比,得出打孔布置的光纤检测故障振动信号更强。

试验设计包括 3 种工况,每种工况的数据集中的转速和径向力各不相同。转速主要由交流电机的转速控制器设置和调节,而径向力则由液压加载系统产生。施加在轴承中的 3 种工况见表 1。

通过测量振动加速度获取滚动轴承剩余寿命预测数据集。在不同工况下,滚动轴承的剩余使用寿命和失效位置各不相同,详细介绍见表 2。

表 1 托辊轴承数据集工况

Table 1 Working conditions of roller bearing dataset

工况	工况 1	工况 1	工况 3
转速/(r·min <sup>-1</sup> )	2 100	2 250	2 400
径向力/kN	12	11	10

表 2 托辊轴承数据集

Table 2 Roller bearing dataset

数据集(工况)	样本总数	$L_{10}/h$	实际寿命/min	失效位置
Bearing 1_1(1)	123	5. 600~9. 677	123	外圈
Bearing 1_2(1)	161		161	外圈
Bearing 1_3(1)	158		198	外圈
Bearing 1_4(1)	122		122	保持架
Bearing 1_5(1)	52		52	内圈、外圈
Bearing 2_1(2)	491	6. 786~11. 726	491	内圈
Bearing 2_2(2)	161		161	外圈
Bearing 2_3(2)	533		533	保持架
Bearing 2_4(2)	42		42	外圈
Bearing 2_5(2)339	339		339	外圈
Bearing 3_1(3)	2 538	8. 468 ~14. 632	2 538	外圈
Bearing 3_2(3)	2 496		2 496	内圈、滚动体、保持架、外圈
Bearing 3_3(3)	371		311	内圈
Bearing 3_4(3)	1 515		1 515	内圈
Bearing 3_5(3)	114		114	外圈

试验采样频率设置为 25.6 kHz,采样间隔为 1 min,每次采样时长为 1.28 s。文中选取工况 1 中的轴承 1\_4,工况 2 中的轴承 2\_4 以及工况 3 中的轴承 3\_3 进行算法验证,训练集与验证集划分见表 3。

表 3 数据集与验证集划分

Table 3 Division of dataset and validation set

工况类别	工况 1	工况 2	工况 3
训练集	轴承 1-1	轴承 2-1	轴承 3-1
	轴承 1-2	轴承 2-2	轴承 3-2
验证集	轴承 1-3	轴承 2-3	轴承 3-3
	轴承 1-4	轴承 2-4	轴承 3-4
	轴承 1-5	轴承 2-5	轴承 3-5

### 4 试验结果分析

选取轴承 1\_4 的退化阈值作为起始预测点,以及 10 个数据点作为历史数据集。在第 1 个周期进行了 5 个数据点的预测,然后将预测得到的数据点与历史数据共 15 个点一起作为神经网络的输入,以

预测下一个周期的 5 个数据点,共进行 2 个周期的预测。N-BEATS 方法与其他 2 种方法的对比结果如图 5 所示。




图 5 轴承 1\_4RMS 预测对比

Fig.5 Comparison of RMS prediction for bearing 1\_4

N-BEATS 方法以轴承 2\_4 的退化阈值作为起始预测点,并选择了 85 个数据点作为历史数据集。在第 1 个周期进行了 25 个数据点的预测,随后将预测得到的数据点与历史数据共 110 个点作为神经网络

络的输入,用以预测下一个周期的 45 个数据点,共进行 2 个周期的预测。该方法与其他 2 种预测方法的对比结果如图 6 所示。




图 6 轴承 2\_4 RMS 预测对比

Fig.6 Comparison of RMS prediction for bearing 2\_4

采用轴承 3\_3 的退化阈值作为起始预测点,并将该点作为起始点,选择 25 个数据点作为历史数据集。在第 1 个周期进行了 15 个数据点的预测,然后在第 2 个周期进行了 7 个数据点的预测,总共进行 2 个周期的预测。该方法与其他 2 种方法的对比结果如图 7 所示。



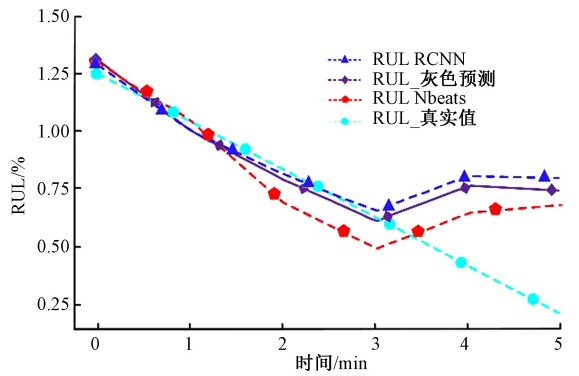


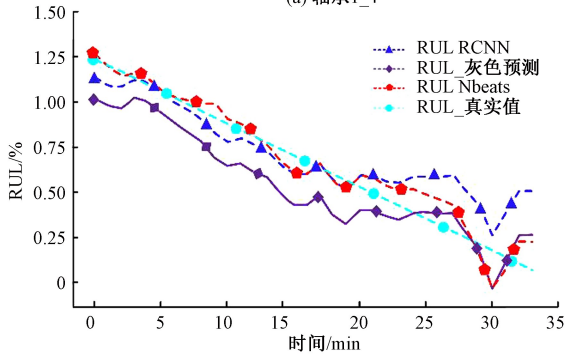
图 7 8 轴承 3\_3RMS 预测对比

Fig.7 Comparison of RMS prediction for bearing 3\_3

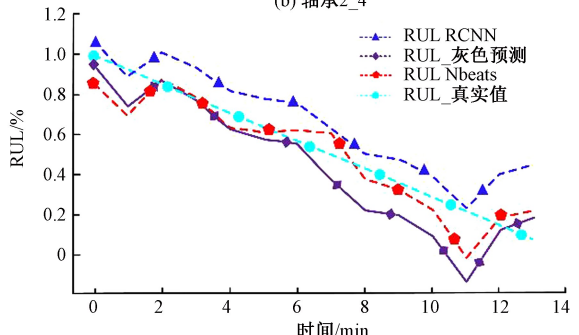
在采集的托辊滚动轴承剩余寿命数据集中,每个数据点代表 1 min。如果预测的退化指标值等于失效阈值,可以判定滚动轴承已经失效。则可以将退化指标中从起始预测点到失效阈值所经历的数据点转换为滚动轴承的剩余使用时间。数据集中的剩余寿命比例如图 8 所示。



(a) 轴承 1\_4



(b) 轴承 2\_4



(c) 轴承 3\_3

图 8 托辊轴承剩余寿命预测对比

Fig.8 Comparison for predicting remaining life of roller bearings

## 5 试验结果评价

为评估预测效果,使用平均绝对误差和相对均方根误差作为准确率度量标准。计算过程如下:

$$MAE = \frac{1}{s} \sum_{i=1}^s |y_i - y_r| \quad (9)$$

$$RMSE = \sqrt{\frac{1}{s} \sum_{i=1}^s (y_i - y_r)^2} \quad (10)$$

式中: $y_r$  为第  $i$  时刻的真实值; $y_i$  为第  $i$  时刻对应的预测值; $s$  为数据长度。

评价托辊滚动轴承寿命预测效果时,计算了 3 种工况下预测值的平均绝对误差和相对均方根误差,分别见表 4 和表 5。针对文中提出的算法,发现相对于 RCNN 和相似性预测模型,其平均绝对误差分

别提升了 5.3% 和 4.1%，相对均方根误差分别提升了 6.3% 和 5.2%。

表 4 3 种轴承数据集 MAE 值

Table 4 MAE values of three rolling bearings datasets

%			
预测方法	RCNN	相似性预测	文中所提方法
Bearing 1_4	0.153	0.138	0.139
Bearing 2_4	0.121	0.122	0.052
Bearing 3_1	0.146	0.124	0.071
平均值	0.140	0.128	0.087

表 5 3 种轴承数据集 RMSE 值

Table 5 RMSE values of three rolling bearings datasets

%			
预测方法	RCNN	相似性预测	文中所提方法
Bearing 1_4	0.232	0.214	0.182
Bearing 2_4	0.137	0.141	0.059
Bearing 3_1	0.168	0.149	0.108
平均值	0.179	0.168	0.116

由表 4 和表 5 可知：对于 3 种不同工况下的轴承寿命预测数据集，文中提出的预测神经网络和预测结构均展现出较传统算法更好的预测效果。

## 6 结 论

1) 将 N-BEATS 模型与 RCNN 和相似性预测模型对比，相对于 RCNN 和相似性预测模型，N-BEATS 模型平均绝对误差分别提升了 5.3% 和 4.1%。

2) N-BEATS 模型相对于 RCNN 和相似性预测模型，其相对均方根误差分别提升了 6.3% 和 5.2%。

3) 目前仅分析和对比了 N-BEATS 模型、RCNN 和相似性预测模型下的寿命预测，存在一定局限性，下一步将 N-BEATS 预测模型和更多模型对比，进一步提高寿命预测精度。

## 参 考 文 献

[1] 齐庆杰,王欢,董子文,等.矿井胶带运输巷火灾蔓延规律的数值模拟研究[J].中国安全科学学报,2016,26(10):36-41.  
QI Qingjie, WANG Huan, DONG Ziwen, et al. Numerical simulation of belt conveyor fire spreading law in coal mine[J]. China Safety Science Journal, 2016,26(10): 36-41.

[2] 李铭,李春广,梁睦,等.煤矿带式输送机事故分析及防护措施[J].中国安全科学学报,2006,18(3):140-144,148.  
LI Ge, LI Chunguang, LIANG Mu, et al. Accident analysis of belt conveyor used in coal mine and its protective measures[J]. China Safety Science Journal, 2006,18(3): 140-144,148.

[3] 都平安,韩刚,李金泊,等.基于 Ansys 的前倾托辊组疲劳寿命分析[J].起重运输机械,2024,(3):27-32.  
DU Ping'an, HAN Gang, LI Jinbo, et al. Fatigue life analysis of forward-leaning idler set based on ansys[J]. Hoisting and Conveying Machinery, 2024,(3): 27-32.

[4] 高波,袁媛,岳伟,等.基于机器学习的托辊故障等级评价模型研究[J].物流科技,2023,46(13):32-35.  
GAO Bo, YUAN Yuan, YUE Wei, et al. Research on fault grade evaluation model of roller based on machine learning[J]. Logistics Sci-Tech, 2023, 46(13): 32-35.

[5] 王善忠,杨绍雷,李深.托辊耐久性设计及其应用研究[J].中国机械,2023(7):52-55.  
WANG Shanzhong, YANG Shaolei, LI Shen. Durability design and application research of idler[J]. Machine China, 2023(7): 52-55.

[6] 李锋.托辊寿命快速试验方法的研究[J].煤矿机械,2021,42(3):38-40.  
LI Feng. Research on rapid test method of idler life[J]. Coal Mine Machinery, 2021, 42(3): 38-40.

[7] 戴忠林.带式输送机托辊轴承故障智能诊断与寿命预测研究[D].阜新:辽宁工程技术大学,2022.  
DAI Zhonglin. The study of intelligent diagnosis and life prediction for idler bearing fault of belt Conveyor[D].Fuxin: Liaoning Technical University, 2022.

[8] 姚德臣,李博阳,刘恒畅,等.基于注意力 GRU 算法的滚动轴承剩余寿命预测[J].振动与冲击,2021,40(17):116-123.  
YAO Dechen, LI Boyang, LIU Hengchang, et al. Residual life prediction of rolling bearing based on attention GRU algorithm[J]. Journal of Vibration and Shock, 2021, 40(17): 116-123.

[9] 王奉涛,刘晓飞,邓刚,等.基于长短期记忆网络的滚动轴承寿命预测方法[J].振动·测试与诊断,2020,40(2):303-309,419.  
WANG Fengtao, LIU Xiaofei, DENG Gang, et al. Remaining useful life prediction method for rolling bearing based on the long short-term memory network[J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(2): 303-309,419.

[10] 周哲韬,刘路,宋晓,等.基于 Transformer 模型的滚动轴承剩余使用寿命预测方法[J].北京航空航天大学学报,2023,49(2):430-443.  
ZHOU Zhetao, LIU Lu, SONG Xiao, et al. Remaining useful life prediction method of rolling bearing based on Transformer model[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(2): 430-443.

[11] 刘琦.基于卷积神经网络的滚动轴承故障诊断及剩余寿命预测研究[D].长春:吉林大学,2021.  
LIU Qi. Research on fault diagnosis and remaining life prediction of rolling bearings based on convolutional neural network[D].Changchun: Jilin University, 2021.

[12] 李卓漫.基于 LSTM 的滚动轴承剩余寿命预测[D].昆明:昆明理工大学,2021.  
LI Zhuoman. Prediction of remaining life of rolling bearings based on lstm[D].Kunming: Kunming University of Science and Technology, 2021.

作者简介: 滕春阳 (1995—),男,满族,辽宁凤城人,本科,主要从事煤矿智能化及煤矿机电管理工作。E-mail:1442926901@qq.com。