

doi: 10.11835/j.issn.1000-582X.2025.06.007

引用格式:陈宇豪,杨正益,文俊浩. CNN 和双向编码解码 LSTM 融合的起重机械健康预测方法[J]. 重庆大学学报, 2025,48(6): 74-83.



# CNN 和双向编码解码 LSTM 融合的起重机械健康预测方法

陈宇豪,杨正益,文俊浩  
(重庆大学 大数据与软件学院,重庆 400044)

**摘要:**针对起重机械设备健康状态多时间单位步长预测中出现的监测数据时间跨度小、数据量密集、特征多维、没有标签的问题,提出一种结合卷积神经网络(convolutional neural network, CNN)和双向编码解码长短期循环神经网络(bidirectional long short-term memory with encoder-decoder, ED-BLSTM)的起重机械设备健康预测方法。对监测数据进行时序排列,在保证相同输入-输出时间步长尺寸情况下对数据集切分重组,将处理后数据集输入到卷积神经网络,提取主要特征,得到多维矩阵。采用基于编码解码器的双向长短期循环神经网络对多维矩阵进行训练,建立起起重机械多时间单位步长的目标预测模型,达到长期预测起重机械设备健康状态的目的。对比实验表明,所提方法的验证损失最多降低 0.474%,最少降低 0.097%;预测损失最多降低 1.411%,最少降低 1.230%,实际预测性能有较大提高,对工业起重机械健康预测技术的发展有积极意义。

**关键词:**起重机械;健康预测;双向长短期循环神经网络;卷积神经网络;编码解码器

中图分类号:TP399

文献标志码:A

文章编号:1000-582X(2025)06-074-10

## Health prediction of lifting machinery based on CNN and bidirectional LSTM with encoder-decoder architecture

CHEN Yuhao, YANG Zhengyi, WEN Junhao

(School of Big Data & Software Engineering, Chongqing University, Chongqing 400044, P. R. China)

**Abstract:** To address challenges in multi-time-step health prediction for lifting machinery, such as short data spans, high-frequency measurements, multi-dimensional feature complexity, and limited labeled data, this paper proposes a hybrid method combining convolutional neural network (CNN) and bidirectional long short-term memory (BiLSTM) networks with an encoder-decoder architecture (ED-BLSTM). The method begins by chronologically organizing monitoring data, followed by segmenting and reconstructing the dataset while maintaining consistent input-output time step sizes. The processed data is first fed into a CNN to extract the main features, generating a multi-dimensional feature matrix. This matrix then trains a BiLSTM network within an

收稿日期:2021-05-11

基金项目:国家重点研发计划(2024YFC3014900)。

Supported by the National Key R&D Program of China(2024YFC3014900).

作者简介:陈宇豪(1997—),男,硕士研究生,主要从事特种设备健康分析预测等方向研究。

通信作者:杨正益(1979—),男,副教授,硕士生导师,(E-mail) zyyang@cqu.edu.cn。

encoder-decoder framework to build a predictive model for multistep forecasting of machinery health status. Comparative experimental results show that the method reduces validation loss by 0.097% to 0.474% and prediction loss by 1.230% to 1.411%, outperforming current mainstream approaches. These results demonstrate its potential to advance predictive maintenance in industrial equipment.

**Keywords:** lifting machinery; health prediction; bidirectional long short-term memory; convolutional neural network; encoder-decoder

特种设备安全直接关系到国家经济建设平稳运行、人民生命财产安全和社会稳定,起重机械属于特种设备中的一种<sup>[1]</sup>。国内外越来越重视对特种设备的安全监测<sup>[2]</sup>。在特种设备安全监测过程中会产生大量的时间序列数据,针对这些时间序列数据,目前有自回归滑动平均模型(auto regression moving average, ARMA)、梯度提升回归树(gradient boosting decision tree, GBDT)和长短期循环神经网络模型(long short-term memory, LSTM)等预测方法。ARMA适合预测平稳时间序列,一般要求这类数据时间跨度较大且数据变化规律具有周期性,例如金融股票走势<sup>[3]</sup>、航空公司季度流量变化、海上风机随机风场模拟<sup>[4]</sup>等。GBDT适合具有标签的时间序列数据,通过监督学习在已知样本其他特征数据情况下获得样本标签的概率分布,如:多标签文本分类<sup>[5]</sup>、ICU临床干预预测<sup>[6]</sup>等。LSTM是深度学习方法,适合密度高、特征多的时序数据,如:使用LSTM预测修复电网电能的正向有功功率<sup>[7]</sup>、基于Time-Attention机制和LSTM模型的极短期太阳能发电预测方法<sup>[8]</sup>。当前这些方法都无法预测时间序列数据中多时间单位步长监测值。

起重机械监测数据时间跨度小、数据量密集、特征多维、没有标签。标准LSTM能对时间序列进行拟合,预测出时间序列单位的目标值,但无法对未来某一时间段进行预测分析。编码解码器模式可以解决单一时序单位目标值预测问题。如:机场跑道视点预测的多步LSTM模型<sup>[9]</sup>、图像字幕深度分层<sup>[10]</sup>、基于动态语义编码双向LSTM的中文语义相似度计算<sup>[11]</sup>。数据集的特征多维、算法模型易出现过拟合。在LSTM中结合卷积神经网络可以识别时间序列的空间结构,提取数据的主要特征,简化LSTM层的输入。如:基于超深卷积神经网络和长短期记忆网络的混合模型对中文文本进行分类<sup>[12]</sup>、应用于网络故障预测的CNN-LSTM(convolutional neural network and long short-term memory, CNN-LSTM)混合神经网络模型<sup>[13]</sup>、基于CNN-LSTM模型实现机器人地面分类识别<sup>[14]</sup>。双向LSTM模型通过正序、逆序组成数据,充分挖掘时序数据的隐藏信息。如:双向LSTM模型在航空发动机气路故障诊断的应用<sup>[15]</sup>、预测设备工作负载的深度双向LSTM网络<sup>[16]</sup>、基于双向LSTM模型的卫星遥测数据异常检测<sup>[17]</sup>。

针对起重机械监测时序数据的特点,构造编码解码器双向长短时循环神经网络,通过卷积神经网络的结合对模型进行优化,实现对起重机械设备的多时间单位步长健康预测,通过对比实验验证目标模型在验证和预测损失上相比于目前主流预测模型有一定降低。

## 1 起重机械健康预测模型

### 1.1 总体流程

起重机械监测数据时间跨度小、数据量密集、特征多维,针对目前预测模型无法预测时间序列数据中多时间单位步长监测值问题,提出一种对起重机械的健康预测方法,如图1所示。起重机械工作点将传感器监测数据存入监测数据库中,从数据库提取原始数据,通过结构化函数将数据转换为算法模型所需要的格式。然后,将结构化数据作为训练数据集输入目标算法模型,得到训练完成的算法模型。使用此模型输出预测某一时间段的设备监测数据,并传输到数据分析机构,机构通过该预测值综合分析此设备在该预测时间段的健康状态,并反馈预测结果。

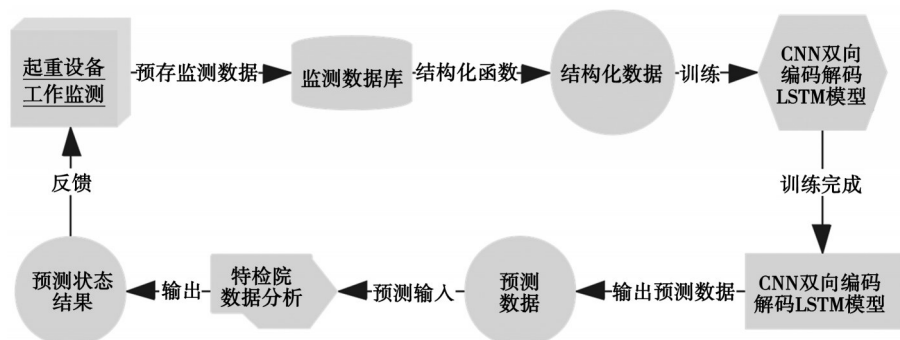


图1 数据预测的流程

Fig.1 Process of data prediction

## 1.2 LSTM基础单元结构

LSTM长短期记忆网络是循环神经网络的一种改进,它的基础结构是一个记忆单元,通过循环一定数量的记忆单元训练网络(如图2所示)。LSTM的基础记忆单元由3个门组成,分别是:遗忘门、输入门和输出门。遗忘门的作用是忘记上一个时间节点的细胞部分状态信息,遗忘系数 $f_g$ 的计算公式为

$$f_g = \sigma(W_{f_g} \cdot [m_{i-1}, x_i] + b_{f_g}) \quad (1)$$

式中: $W_{f_g}$ 是遗忘神经网络层的权重矩阵; $b_{f_g}$ 是遗忘神经网络层的偏置系数; $m_{i-1}$ 是上邻接时间节点的隐藏层输出; $x_i$ 是此刻单元细胞的输入; $\sigma$ 是sigmoid激活函数,用于将遗忘系数控制在[0,1]之间。输入门的作用是决定状态需要增添的信息,可能增添的状态信息 $\tilde{U}_i$ 以及系数 $\text{input}_i$ 的计算公式为

$$\text{input}_i = \sigma(W_{\text{input}} \cdot [m_{i-1}, x_i] + b_{\text{input}}), \quad (2)$$

$$\tilde{U}_i = \text{ReLU}(W_U \cdot [m_{i-1}, x_i] + b_U), \quad (3)$$

式中: $W_{\text{input}}$ 、 $W_U$ 是到遗忘门的全连接层的权重矩阵; $b_{\text{input}}$ 、 $b_U$ 是对应神经网络层的偏置系数; $m_{i-1}$ 是上邻接时间节点下记忆单元的隐藏层输出; $x_i$ 是此刻单元细胞的输入; $\sigma$ 是sigmoid激活函数;ReLU是线性整流函数,作为激活函数使用。

通过遗忘门和输入门得到此刻下该记忆单元的状态信息 $U_i$ ,计算公式为

$$U_i = f_g \times U_{i-1} + \text{input}_i \times \tilde{U}_i, \quad (4)$$

式中, $U_{i-1}$ 是上邻接时间节点下记忆单元的状态信息。

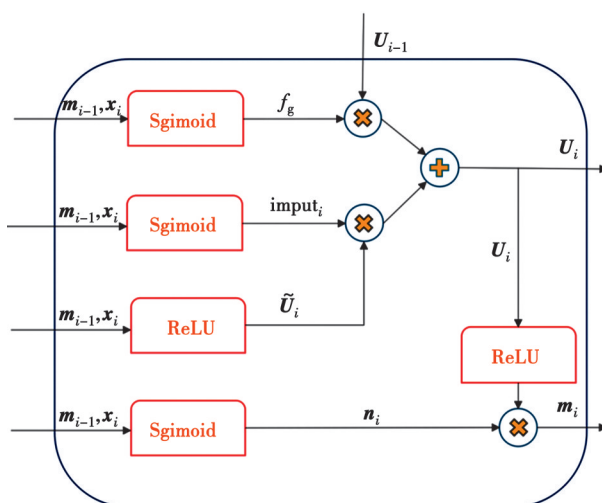


图2 LSTM中循环神经网络的结构

Fig.2 The structure of recurrent neural network in LSTM

输出门的作用是在更新完状态信息后,更新记忆单元的隐藏层输出。隐藏层的权重 $n_i$ 和输出 $m_i$ 的计算公式为

$$n_i = \sigma(W_n \cdot [m_{i-1}, x_i] + b_n), \quad (5)$$

$$m_i = n_i \times \text{ReLU}(U_i), \quad (6)$$

式中:  $W_n$  是到隐藏输出的全连接层的权重矩阵;  $b_n$  是对应网络层的偏置系数;  $m_{i-1}$  是上邻接时间节点下记忆单元的隐藏层输出。

### 1.3 目标算法模型

目标算法模型是结合 CNN 与双向编码解码 LSTM 的模型结构,如图 3 所示。模型的第 1 层结构是 CNN 卷积神经网络:结构化数据在输入之前被拆分成若干个子输入,每个子输入首先经过卷积层进行特征提取,输出结果进入最大池化层去除不明显特征,将输出张量平展到单个时间步长的二维向量(样本、特征数),至此第 1 层的卷积神经网络的处理结束。

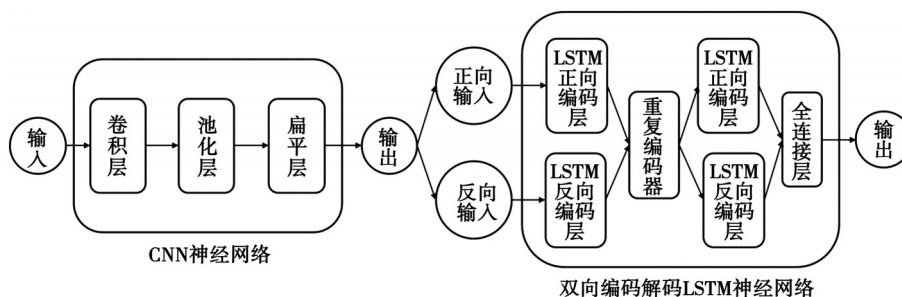


图 3 目标算法模型的结构

Fig. 3 The structure of the target algorithm model

模型的第 2 层结构是基于编码解码器的双向 LSTM 神经网络:通过第 1 层 CNN 神经网络结构后,输入变为单个二维向量,该输入分为正序和逆序进入双向 LSTM 编码层,该层同样会输出以样本和特征数为维度的二维向量。该输出通过重复编码器将数据形式转换为三维向量(样本、时间步长、特征),其中时间步长维度的值是重复编码的次数;接下来三维向量输入到双向 LSTM 解码层,解码层输出同样结构的三维向量;最后通过全连接层把各个特征维度的向量连接起来,输出目标定义的数据序列。

## 2 实验对比

### 2.1 数据集

为了分析目标算法模型的性能并验证其有效性,从中国特种设备检测研究院获得某钢铁冶炼企业的冶金起重机(如图 4 所示)实时监测数据,该数据是 12 个同类型应变传感器在冶金起重机各位置采集的实时监测数据。采集点的位置如图 5 所示,表 1 展示测点的具体布置信息。



图 4 冶金起重机的结构

Fig. 4 Structure of metallurgical lifting machine






图 5 测点布控平面图

Fig. 5 Location of measuring points

表 1 测点位置信息

Table 1 Information of measuring points' location

测点编号	测点位置	数量
1	副主梁与端梁连接上盖板(西)	1
2	副主梁连接上盖板(西)	1
3A	主梁端部变截面连接焊缝	1
3B	北侧主梁下盖板 1/4 跨(东)	1
4	北侧主梁下盖板 1/2 跨	1
5	北侧主梁下盖板 1/4 跨(西)	1
6	副主梁连接上盖板(东)	1
7	副主梁与端梁连接上盖板(东)	1
8	北侧主梁主腹板 1/4 跨(西)	1
9	北侧主梁主腹板 1/2 跨	1
10	北侧主梁主腹板 1/4 跨(东)	1
11	主梁端部变截面连接焊缝	1

选取起重机在工作状态时间段 2019 年 10 月 12 日的 10:39:42.493—11:18:04.493 共计 2 302 s 内的 12 个应变传感器的采集数据,传感器每 0.4 s 采集 1 次,共计 5 756 条数据,采集数据如图 6 所示。预测实验进行 5 次,每次预测该起重设备在时间为 11:18:04.493 和 11:18:04.893(即训练数据集结束之后的 2 个时间步长)各传感器的预测值并记录每次实验的评估参数。




图 6 采集监测数据

Fig. 6 Monitoring data

## 2.2 数据预处理

输入数据形式为二维数组,通过设置输入步长和输出步长对原数组进行预处理。举例如图 7 所示,设置输入步长  $A$  为 3,输出步长  $B$  为 2,按时间顺序将原数组重构成三维数组,三维数组的每个元素都是具有 2 个数组元素的二维数组,2 个数组分别代表输入数据和输出数据。

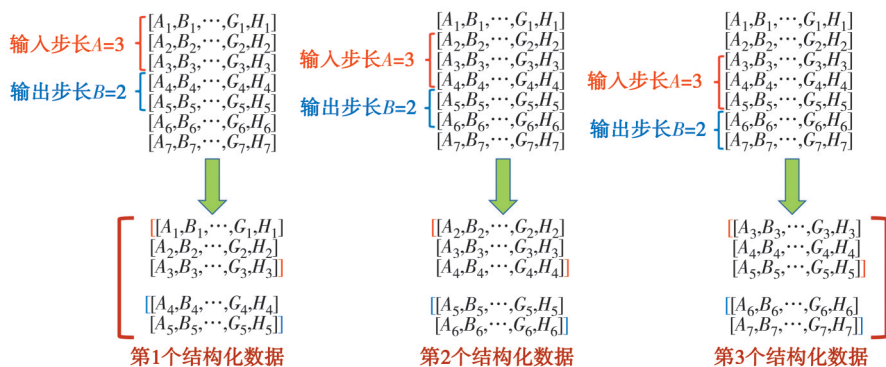


图 7 数据预处理

Fig. 7 The data preprocessing

其中,  $A, B, \dots, G, H$  分别表示传感器在测点 1~7 的数据, 下标表示数据的时间顺序。

## 2.3 结果与分析

### 2.3.1 实验参数

实验设置输入步长为 8, 输出步长为 2。模型参数设置 CNN 网络卷积层过滤器数量为 81, 内核尺寸为 2, 子序列输入长度为 4, 池化层大小为 2。双向 LSTM 编码解码层的单元数为 200, 训练期数为 300, 激活函数全部使用 ReLU 线性整流函数, 验证数据集的占比为 0.2, 计算 50 个采集数据集的 RMSPE 平均值作为实验结果。训练网络均采用 Adam 优化器, 默认初始学习率为 0.001, 学习率  $\alpha_t$  的变化策略为

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2, \quad (7)$$

$$\tilde{v}_t = v_t / (1 - \beta_t^2), \quad (8)$$

$$\alpha_t = \alpha_{t-1} / (\sqrt{\tilde{v}_t} + \text{epsilon}), \quad (9)$$

式中:  $v_t$  为梯度平方的指数移动平均数;  $\beta_2$  为指数衰减率, 默认为 0.999;  $g_t$  为时间步  $t$  的梯度;  $\tilde{v}_t$  为偏差修正后梯度平方的指数移动平均数; 数值稳定性常数 epsilon =  $10^{-8}$ , 为防止除数为 0。

使用标准编码解码 LSTM 模型、CNN+标准编码解码 LSTM 模型(convolutional neural network and long short-term memory with encoder-decoder, CNN+ED-LSTM)、双向编码解码 LSTM 模型(bidirectional long short-term memory with encoder-decoder, ED-BLSTM)作对比试验, 对比实验模型中的参数设置都与目标模型 CNN+双向编码解码 LSTM 模型(convolutional neural network and bidirectional long short-term memory with encoder-decoder, CNN+ED-BLSTM)相同。

### 2.3.2 评估参数

实验使用均方根百分比误差 RMSPE 作为实验的损失指标, 该损失函数的计算公式定义为

$$\text{RMSPE} = \sqrt{\frac{1}{n} \times \sum_{n=1}^n \left( \frac{y_t - y_p}{y_t} \right)^2} \times 100\%, \quad (10)$$

式中:  $y_t$  是样本真实值;  $y_p$  是模型预测值。使用该损失指标记录了预测误差与真实值的百分比, 直观表达了模型预测的准确度。

### 2.3.3 预测结果

实验结果将应变型数据转换为应力型数据, 转换公式为

$$\sigma = E |\varepsilon|, \quad (11)$$

式中:  $\varepsilon$  为应变监测值;  $E = 0.206 \text{ MPa}$ ;  $\sigma$  为相应应力值。各测点的安全系数表示为

$$n_s = \frac{R_e}{\sigma}, \quad (12)$$

式中:  $\sigma$  为测点应力值;  $R_e$  为结构材料的屈服强度, 对于本冶金起重机, 取  $R_e = 345 \text{ MPa}$ 。考虑工作环境构件在设备中的重要性, 损坏后造成后果的严重程度, 取安全系数为 4.0, 即各测点中最小安全系数  $n_{\min} \geq 4.0$ , 则设备此时的健康状态为安全。5 次预测实验中, 目标时间 11:18:04.493 和 11:18:04.893 各算法预测出各测点中的平均最大应变值如表 2~3 所示。

表 2 11:18:04.493 预测结果  
Table 2 Predict result in 11:18:04.493

方法	$ \varepsilon_{\text{avg}} $	$ \varepsilon_{\text{avg}} - \varepsilon_{\text{true}} $	$n_s$	结果
CNN+ED-BLSTM	191.269 605	<b>1.068 041</b>	8.756 003	safe
ED-LSTM	193.349 503	3.147 939	8.661 813	safe
CNN+ED-LSTM	192.076 910	1.875 346	8.719 201	safe
ED-BLSTM	192.617 437	2.415 873	8.918 450	safe

注: 加粗数据表示最佳的预测结果值。

表 3 11:18:04.893 预测结果  
Table 3 Predict result in 11:18:04.893

方法	$ \varepsilon_{\text{avg}} $	$ \varepsilon_{\text{avg}} - \varepsilon_{\text{true}} $	$n_s$	结果
CNN+ED-BLSTM	190.872 124	<b>0.759 785</b>	8.774 237	safe
ED-LSTM	192.439 920	2.327 581	8.702 754	safe
CNN+ED-LSTM	191.415 793	1.303 454	8.749 316	safe
ED-BLSTM	191.264 907	1.152 568	8.756 218	safe

注:加粗数据表示最佳的预测结果差值。

虽然各算法对目标时间点的设备状态预测都正确,但各算法预测出平均最大应变值和真实值的差值  $|\varepsilon_{\text{avg}} - \varepsilon_{\text{true}}|$  各不相同,其中目标算法模型 CNN+ED-BLSTM 分别为 1.068 041 和 0.759 785,最接近真实值,因此预测结果最准确。

2.3.4 验证和预测损失

目标算法模型和对比模型在训练中的验证损失曲线如图 8 所示。其中:绿线表示目标算法模型 CNN+双向编码解码 LSTM(CNN+ED-BLSTM);红线表示双向编码解码 LSTM 模型(ED-BLSTM);蓝线表示 CNN+标准编码解码 LSTM 模型(CNN+ED-LSTM);黄线表示标准编码解码 LSTM 模型(ED-LSTM)。可以看出,目标算法模型的收敛速度最快,模型收敛后,目标模型的损失最低,为 4.307%。其他的,ED-LSTM 为 4.404%、CNN+ED-LSTM 为 4.457%、ED-BLSTM 为 4.781%。

目标算法模型和对比模型在 5 次实际预测过程中的预测损失曲线如图 9 所示。其中:绿线表示目标算法模型 CNN+双向编码解码 LSTM(CNN+ED-BLSTM);红线表示双向编码解码 LSTM 模型(ED-BLSTM);蓝线表示 CNN+标准编码解码 LSTM 模型(CNN+ED-LSTM);黄线表示标准编码解码 LSTM 模型(ED-LSTM)。5 次预测过程中的损失如表 4 所示,目标模型的平均预测损失最低,为 4.339%。ED-LSTM 为 5.569%,CNN+

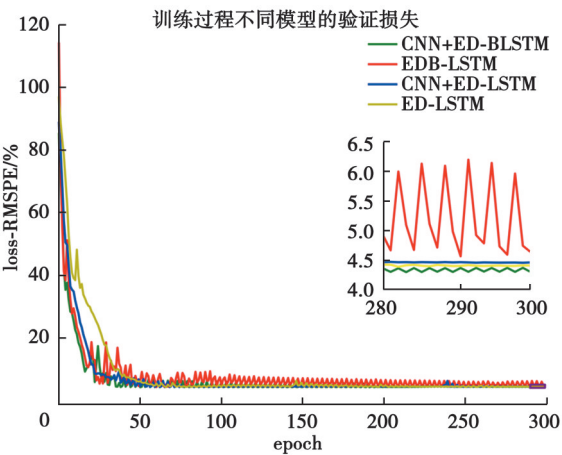


图 8 验证损失的实验结果

Fig. 8 Experimental result of validation loss

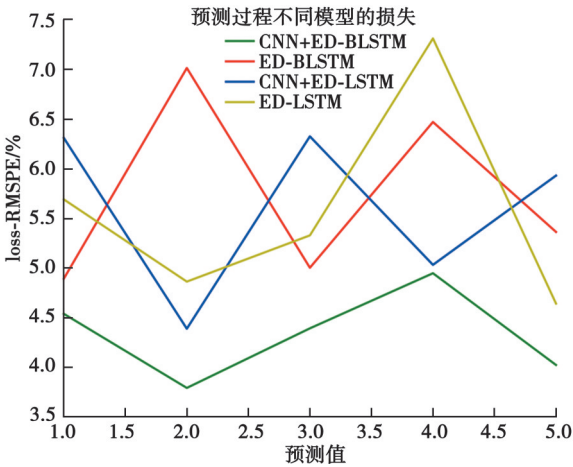


图 9 预测损失的试验结果

Fig. 9 Experimental results of prediction loss

表 4 预测损失的试验结果  
Table 4 Experimental results of prediction loss

Times	CNN+ED-BLSTM	ED-BLSTM	CNN+ED-LSTM	ED-LSTM
1	4.539	4.892	6.312	5.692 7
2	3.792	7.016	4.389	4.863 7
3	4.392	5.003	6.327	5.329 6
4	4.948	6.472	5.032	7.314 8
5	4.023	5.364	5.932	4.642 3
Avg	4.339	5.750	5.600	5.569 0



ED-LSTM 为 5.600%, ED-BLSTM 为 5.750%。

### 2.3.5 实验小结

实际预测过程中,目标算法模型 CNN+ED-BLSTM 预测出的平均最大应变值与真实值的差值最小,预测结果最准确。验证损失对比实验中,目标算法模型 CNN+ED-BLSTM 相较于次最优模型 ED-LSTM 的性能提升较小,损失降低了 0.097%;而在预测损失对比实验中,目标算法模型相较于次最优模型 ED-LSTM 的性能提升较大,损失降低了 1.230%。

## 3 结 语

针对无法进行起重机械设备健康状态多时间单位步长预测的问题,研究提出了一种结合卷积神经网络和基于编码解码器的双向长短期循环神经网络的算法模型对起重机械设备监测数据进行预测。在算法模型中前置了卷积神经网络,提取数据输入的主要特征,简化长短期循环神经网络的输入,实现对未来多个时间间隔的目标值预测。模型中设置了双向长短期循环神经网络的结构,LSTM 单元结构中的遗忘门和验证数据集减少了模型对训练数据集的过度拟合,正向和逆向的数据输入提高了模型的预测精度。

通过对比实验验证了结合卷积神经网络和编码解码双向长短期循环神经网络的目标算法模型,其验证损失和预测损失均低于标准长短期循环神经网络、卷积神经网络+标准长短期循环神经网络以及双向长短期循环神经网络模型。在实际预测过程中,目标算法模型的表现甚至更好,证明了目标算法模型具有一定的有效性。

## 参考文献

- [1] 李志勇,马志强.浅谈国内起重机械发展现状[J].起重运输机械,2020(17):35-37.  
Li Z Y, Ma Z Q. Development status of domestic hoisting machinery[J]. Hoisting and Conveying Machinery, 2020(17): 35-37. (in Chinese)
- [2] 齐凯,王新华,何成忠.大型起重机械安全预警机制的研究[J].中国安全科学学报,2011,21(1):136-139.  
Qi K, Wang X H, He C Z. Research of crane machinery security early warning mechanism[J]. China Safety Science Journal, 2011, 21(1): 136-139. (in Chinese).
- [3] 黄时文,柴啸龙,林晓瑜.中国股市周期性研究及其价格监控[J].经济数学,2019,36(3):16-20.  
Huang S W, Chai X L, Lin X Y. The research of the periodicity of Chinese stock market and the monitoring of its price[J]. Journal of Quantitative Economics, 2019, 36(3): 16-20. (in Chinese)
- [4] 李鹏,朱洪泽,骆光杰,等.基于 ARMA 模型的海上风场随机风场模拟[J].武汉大学学报(工学版),2024,57(1):112-120.  
Li P, Zhu H Z, Luo G J, et al. Stochastic wind field simulation of offshore wind turbines based on ARMA model[J]. Journal of Wuhan University(Engineering Edition), 2024, 57(1): 112-120. (in Chinese)
- [5] 俞学豪,赵子岩,马应龙,等.基于 BR 和 GBDT 的电力信息通信客服系统多标签文本分类[J].电力系统自动化,2021,45(11):144-151.  
Yu X H, Zhao Z Y, Ma Y L, et al. Multi-label text classification for power ICT custom service system based on binary relevance and gradient boosting decision tree[J]. Automation of Electric Power Systems, 2021, 45(11): 144-151. (in Chinese)
- [6] 张娅峰,龚振.基于迭代决策树的 ICU 临床干预预测[J].计算机技术与发展,2020,30(12):118-122.  
Zhang Y F, Gong Z. ICU clinical intervention prediction based on GBDT[J]. Computer Technology and Development, 2020, 30(12): 118-122. (in Chinese)
- [7] Bai Y W, Cheng Y, Zheng K Y, et al. Positive active power missing value repairing with LSTM prediction[C]//2020 12th IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC). Nanjing, China: IEEE, 2020: 9220663.
- [8] Pan C, Tan J, Feng D D, et al. Very short-term solar generation forecasting based on LSTM with temporal attention mechanism [C]//2019 IEEE 5th International Conference on Computer and Communications (ICCC). Chengdu, China: IEEE, 2019: 9064298.
- [9] Meng Y L, Qi F L, Zuo H, et al. Multi-step LSTM prediction model for visibility prediction[C]//2020 International Joint Conference on Neural Networks (IJCNN). Glasgow, UK: IEEE, 2020: 1-8.
- [10] Xiao X Y, Wang L F, Ding K, et al. Deep hierarchical encoder-decoder network for image captioning[J]. IEEE Transactions on

- Multimedia, 2019, 21(11): 2942-2956.
- [11] 初雅莉, 郑虹, 侯秀萍. 基于动态语义编码双向 LSTM 的中文语义相似度计算[J]. 计算机应用与软件, 2020, 37(6): 224-229.
- Chu Y L, Zheng H, Hou X P. Chinese semantic similarity calculation based on dynamic semantic coding bi-directional lstm[J]. Computer Applications and Software, 2020, 37(6): 224-229. (in Chinese)
- [12] 彭玉青, 宋初柏, 闫倩, 等. 基于 VDCNN 与 LSTM 混合模型的中文文本分类研究[J]. 计算机工程, 2018, 44(11): 190-196.
- Peng Y Q, Song C B, Yan Q, et al. Research on Chinese text classification based on hybrid model of VDCNN and LSTM[J]. Computer Engineering, 2018, 44(11): 190-196. (in Chinese)
- [13] Tan Z L, Pan P S. Network fault prediction based on CNN-LSTM hybrid neural network[C]//2019 International Conference on Communications, Information System and Computer Engineering (CISCE). China: IEEE, 2019: 00113.
- [14] Li X X, Wu J H, Li Z Z, et al. Robot ground classification and recognition based on CNN-LSTM model[C]//2021 IEEE 2nd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE). Nanchang, China: IEEE, 2021: 1110-1113.
- [15] 刘利军, 雷宇, 余臻. 双向 LSTM 模型在航空发动机气路故障诊断的应用[J]. 航天控制, 2020, 38(5): 67-72.
- Liu L J, Lei Y, Yu Z. The application of bidirectional LSTM model in aero-engine gas path fault diagnosis[J]. Aerospace Control, 2020, 38(5): 67-72. (in Chinese)
- [16] Ruta D, Cen L, Vu Q H. Deep bi-directional LSTM networks for device workload forecasting[C]//2020 15th Conference on Computer Science and Information Systems (FedCSIS). Sofia, Bulgaria: IEEE, 2020: 115-118.
- [17] Pan D W, Song Z, Nie L Q, et al. Satellite telemetry data anomaly detection using Bi-LSTM prediction based model[C]//2020 IEEE International Instrumentation and Measurement Technology Conference (I2MTC). Dubrovnik, Croatia: IEEE, 2020: 9129010.

(编辑 侯 湘)