

DOI: 10.19344/j.cnki.issn1671-5276.2025.02.007

基于累积模糊熵与 Bi-LSTM 的滚动轴承退化趋势预测

唐斌¹, 池茂儒¹, 赵明花²

(1. 西南交通大学 轨道交通运载系统全国重点实验室, 四川 成都 610031;

2. 青岛国家高速列车技术创新中心, 山东 青岛 266111)

摘要:为了弥补模糊熵特征难以反映滚动轴承在退化过程中单调性劣化趋势的不足,更准确地实现轴承的退化趋势预测,提出一种结合累积模糊熵特征指标与双向长短期记忆神经网络(Bi-LSTM)的预测方法。依据模糊熵算法提取振动信号的特征序列;通过累积变换得到累积模糊熵特征指标;基于历史状态退化特征通过 Bi-LSTM 预测轴承的退化趋势。实验结果表明:累积模糊熵特征指标不仅可以反映轴承的早期退化,而且具有良好的单调性;基于相同的累积模糊熵特征指标与 LSTM、GRU 预测模型相比,所构建的 Bi-LSTM 预测模型具有更高的预测准确性。

关键词:滚动轴承;退化趋势预测;累积模糊熵;双向长短期记忆神经网络

中图分类号:TH133.3 **文献标志码:**A **文章编号:**1671-5276(2025)02-0037-05

Prediction of Rolling Bearing Degradation Trend Based on Cumulative Fuzzy Entropy and Bi-LSTM

TANG Bin¹, CHI Maoru¹, ZHAO Minghua²

(1. State Key Laboratory of Rail Transit Vehicle System, Southwest Jiaotong University, Chengdu 610031, China;

2. Qingdao National Innovation Center of High Speed Train, Qingdao 266111, China)

Abstract: In order to compensate for the deficiency that the fuzzy entropy feature has difficulty in reflecting the monotony deterioration trend of rolling bearing in the process of degradation, and predict the bearing degradation trend more accurately, a prediction method combining the cumulative fuzzy entropy feature index and Bi-LSTM is proposed. The feature sequence of the vibration signal is extracted according to the fuzzy entropy algorithm, and the cumulative fuzzy entropy feature index is obtained through the cumulative transformation. The degradation trend of the bearing is predicted by the Bi-LSTM based on features of historical state degradation. The experimental results show that the cumulative fuzzy entropy characteristic index can not only reflect the early degradation of the bearing, but also has good monotonicity. And for the same cumulative fuzzy entropy feature index, the Bi-LSTM prediction model, compared with LSTM and GRU prediction models, has higher prediction accuracy.

Keywords: rolling bearing; degradation trend prediction; cumulative fuzzy entropy; bidirectional long-short term memory neural network

0 引言

滚动轴承作为机械旋转系统中的核心组成部件,在工程机械中得到大量的应用,其在工作过程中的状态不仅影响着设备稳定性,更是对安全性有着重大影响^[1]。因此,较好地预测滚动轴承的退化趋势对避免安全事故、减少经济损失有着重大意义。

提取合适的特征与建立合适的预测模型是预测轴承状态退化的关键。在滚动轴承的运行过程中,其振动信号往往具有非平稳、非线性的特点;而传统的时域分析是将轴承振动信号作为平稳信

号来进行特征提取,所以并不能很好地表征轴承的退化过程,存在对轴承早期状态退化不敏感等问题^[2-3]。随着非线性科学理论的发展,熵作为一种反映信号复杂度的非线性分析指标^[4],在轴承振动信号的特征提取中得到了应用,比如模糊熵^[5-6]。

滚动轴承在工作过程中总会经历由正常退化至失效的过程。从本质上来说,轴承在退化过程中的劣化程度是逐步加重的,即劣化程度的变化趋势是单调性的。然而,纯粹的模糊熵特征一般不具备很好的单调性,因此很难反映出轴承劣化程度的单调性变化。

基金项目:国家自然科学基金区域创新发展联合基金项目(U21A20168)

第一作者简介:唐斌(1996—),男,湖南永州人,硕士研究生,研究方向为车辆智能运维,2320913893@qq.com。

对于上述问题,本文将累积变换方法与模糊熵相结合,通过对提取的模糊熵特征序列逐点进行累加与缩放操作,进一步得到单调性更好的累积模糊熵特征序列。

在得到合适的退化特征之后,则需要构建预测模型进行预测。从本质上来讲,所提取出的轴承退化特征序列是一个时间序列。在深度学习模型中,循环神经网络(RNN)是一种适用于时间序列的学习模型,但其在处理长序列时会有梯度消失等问题,因此长短期记忆神经网络(LSTM)应运而生^[7]。然而,LSTM按时间顺序处理序列,仅考虑过去信息而忽略未来信息;而实际上滚动轴承的衰退过程是一个在时间上具有前后依赖关系的连续变化过程,当前信息的处理也有必要整合“未来”的信息^[8]。因此,本文采用可以在前向和后向两个方向上处理时间序列的双向长短期记忆神经网络(Bi-LSTM)作为预测模型。

综上所述,本文提出一种结合累积模糊熵与 Bi-LSTM 的滚动轴承状态退化趋势预测方法。首先提取轴承振动信号的模糊熵特征,再采用累积变换方法得到累积模糊熵特征,最后将所提取的状态退化特征输入所构建的网络模型来预测滚动轴承的退化趋势。

1 特征提取方法

1.1 模糊熵

模糊熵的定义如下^[9]。

1)对于长度为 N 的时间序列 $\{u(i):1 \leq i \leq N\}$,将其构造为 m 维向量,可得

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i) \quad (1)$$

$$u_0(i) = m^{-1} \sum_{j=0}^{m-1} u(i+j) \quad (2)$$

式中: m 为嵌入维度, $1 \leq i \leq N-m+1$ 。

2)定义 X_i^m 与 X_j^m 间的距离 $d[X_i^m, X_j^m]$ 为两者对应元素差值的最大值,即

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} \{ |[u(i+k) - u_0(i)] - [u(j+k) - u_0(j)]| \}; \quad i, j = 1, 2, \dots, N-m, i \neq j \quad (3)$$

3)通过模糊函数 $\mu(d_{ij}^m, n, r)$ 定义矢量 X_i^m 和 X_j^m 的相似度 D_{ij}^m ,即

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = e^{-(d_{ij}^m)^{n/r}} \quad (4)$$

式中模糊函数 $\mu(d_{ij}^m, n, r)$ 为指数函数, n 和 r 分别为其边界的梯度和宽度。

4)定义函数

$$\phi^m(n, r) = \frac{\sum_{i=1}^{N-m} [(N-m-1)^{-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^m]}{(N-m)} \quad (5)$$

5)类似地,再对维数 $m+1$,重复式(1)一式(4),得

$$\phi^{m+1}(n, r) = \frac{\sum_{i=1}^{N-m} [(N-m-1)^{-1} \sum_{j=1, j \neq i}^{N-m} D_{ij}^{m+1}]}{(N-m)} \quad (6)$$

6)有限长度时间序列的模糊熵定义为

$$F_{\text{uzzyEn}}(m, n, r, N) = \ln \phi^m(n, r) - \ln \phi^{m+1}(n, r) \quad (7)$$

假设采集的轴承全寿命周期振动信号包括 l 组数据,通过式(1)一式(7)可得到模糊熵特征序列 $\{Z_1, Z_2, \dots, Z_l\}$ 。

1.2 平滑处理

采用 Savitzky-Golay 滤波器对模糊熵特征序列 $\{Z_1, Z_2, \dots, Z_l\}$ 进行平滑处理,得到平滑后的模糊熵特征序列 $\{F_{E,1}, F_{E,2}, \dots, F_{E,l}\}$ 。

1.3 累积模糊熵

得到模糊熵特征序列 $\{F_{E,1}, F_{E,2}, \dots, F_{E,l}\}$ 之后,进一步通过累积变换方法^[10]得到模糊熵特征序列。

1)对于特征序列 $\{F_{E,1}, F_{E,2}, \dots, F_{E,l}\}$,选取轴承正常状态下的一段特征序列,并求取该序列的平均值作为标准值,如式(8)所示。

$$F_{E,\text{nor}} = (n+1)^{-1} \sum_{t=y}^{y+q} F_{E,t} \quad (8)$$

式中: $F_{E,t}$ 为序列中的第 t 个值; $y, q \in N^+$ 。

2)计算序列中第 s 个累积特征,如式(9)所示。

$$C_{FE,s} = \sqrt{\sum_{t=1}^s (F_{E,t} - F_{E,\text{nor}})^2} \quad (9)$$

式中 $C_{FE,s}$ 为第 s 个的累积特征指标, $1 \leq s \leq l$ 。

经过式(8)一式(9),最后可得到累积模糊熵特征序列 $\{C_{FE,1}, C_{FE,2}, \dots, C_{FE,l}\}$ 。

1.4 单调性评价指标

为了说明特征序列在经过累积变换之后其单调性的变化,采用式(10)一式(11)计算特征序列的单调性评估值:

$$M = \frac{\left| \sum_{i=1}^{H-1} \delta(x_{i+1} - x_i) - \sum_{i=2}^H \delta(x_{i-1} - x_i) \right|}{(H-1)} \quad (10)$$

$$\delta(a) = \begin{cases} 1, a \geq 0 \\ 0, a < 0 \end{cases} \quad (11)$$

式中: M 为单调性评估值; H 为特征序列长度; x 为特征序列。

2 基于 Bi-LSTM 的预测方法

2.1 双向长短期记忆神经网络

LSTM 模型由输入门 i_t 、遗忘门 f_t 、输出门 o_t 以及记忆单元 c_t 构成; 通过 i_t 、 f_t 和 o_t 对网络中的信息进行选择性的输入、输出以及遗忘操作, 能够有效克服一般神经网络所存在的梯度消失问题^[11], 其单元内部结构如图 1 所示。

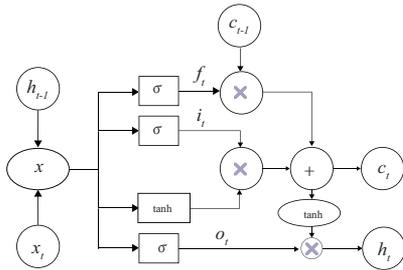


图 1 LSTM 单元结构图

LSTM 的表达式如式 (12) — 式 (17) 所示。

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_t \\ h_{t-1} \end{bmatrix} \quad (12)$$

$$f_t = \sigma(W_f \cdot \mathbf{X} + b_f) \quad (13)$$

$$i_t = \sigma(W_i \cdot \mathbf{X} + b_i) \quad (14)$$

$$o_t = \sigma(W_o \cdot \mathbf{X} + b_o) \quad (15)$$

$$c_t = f_t \otimes c_{t-1} + i_t \otimes \tanh(W_c \cdot \mathbf{X} + b_c) \quad (16)$$

$$h_t = o_t \otimes \tanh(c_t) \quad (17)$$

式中: \mathbf{x}_t 表示 t 时刻的输入向量; h_t 是时间 t 的隐藏层状态; W 和 b 分别是 LSTM 的权值和偏置; σ 是激活函数 sigmoid; \otimes 为逐点乘积。

双向长短期记忆神经网络的工作原理是: 通过前向 LSTM 和后向 LSTM 得到两个时间序列相反的隐藏层状态, 然后将其连接得到同一个输出。前向 LSTM 和后向 LSTM 可以分别获取输入序列的过去信息和未来信息。

在本文中, 将轴承退化开始之前的数据作为训练集, 退化之后的数据作为测试集。为了评价预测结果的准确性, 用决定系数 R^2 作为评价指标, 其计算表达式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^P (x_i - \hat{x}_i)^2}{\sum_{i=1}^P (x_i - \bar{x})^2} \quad (18)$$

式中: P 是数据长度; x_i 为第 i 个真实值; \hat{x}_i 是第 i

个预测值; \bar{x} 为真实值的平均值。

2.2 预测步骤

1) 获取滚动轴承的振动信号, 计算出相应的模糊熵特征序列。

2) 通过累积变换方法得到累积模糊熵特征序列, 并将累积特征序列划分为训练集和测试集。

3) 将测试集数据输入到训练好的 Bi-LSTM 预测模型中实现轴承的退化趋势预测。

预测步骤如图 2 所示。

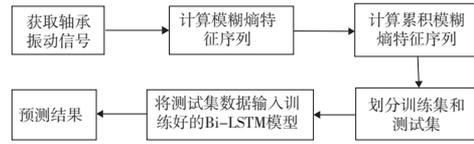


图 2 预测步骤

3 实例分析

3.1 特征提取

该实验数据为美国辛辛那提大学智能维护系统的滚动轴承全寿命周期振动数据。所采用数据集的采样频率为 20 kHz, 每两个数据文件之间的采样间隔为 10 min, 每次采集 20 480 个数据点, 其中共有 984 组数据, 实验结束时轴承外圈失效, 相应的理论故障特征频率为 236.4 Hz, 其振动信号如图 3 所示。

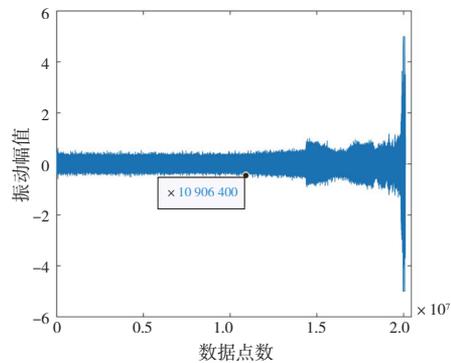


图 3 滚动轴承振动信号图

由图 3 可以看出, 在第 533 组数据 (第 10 895 361 个数据点到 10 915 840 个数据点) 附近, 振动信号的振动幅值呈现出增大的趋势。此外, 分别计算第 531、532、533 以及 534 组数据的包络谱, 如图 4 所示。

可以看出, 第 531、532 组数据都没有发现明显的故障频率, 而第 533 和 534 组数据的频谱图在频

率 230.5 Hz 处有清晰的峰值,接近外圈故障的理论频率值(236.4 Hz)。这进一步说明是在第 533 组数据处出现了外圈故障,即轴承状态开始退化。

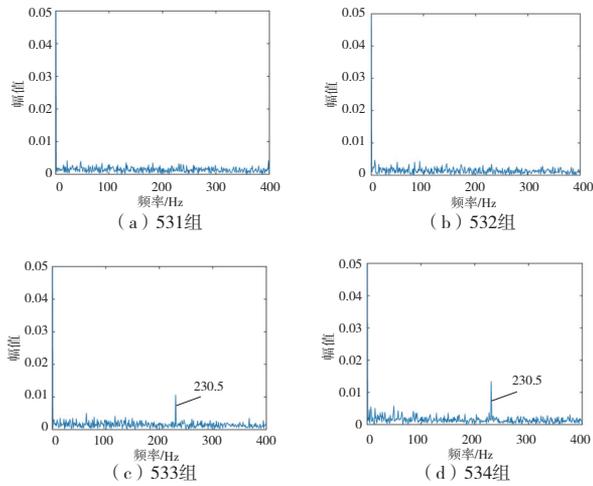


图 4 包络谱分析

进一步提取振动信号的模糊熵特征并同时提取峭度特征进行对比,相应的特征序列(经过平滑处理)如图 5 所示。可以看出,峭度特征在第 600 个状态点之后才有明显变化;相较之下,模糊熵特征从第 533 个状态点附近呈现出增大的趋势(与原始振动信号一样),而且变化明显。这说明其可以捕获轴承的早期退化,对表征轴承状态的退化具有一定的优越性。

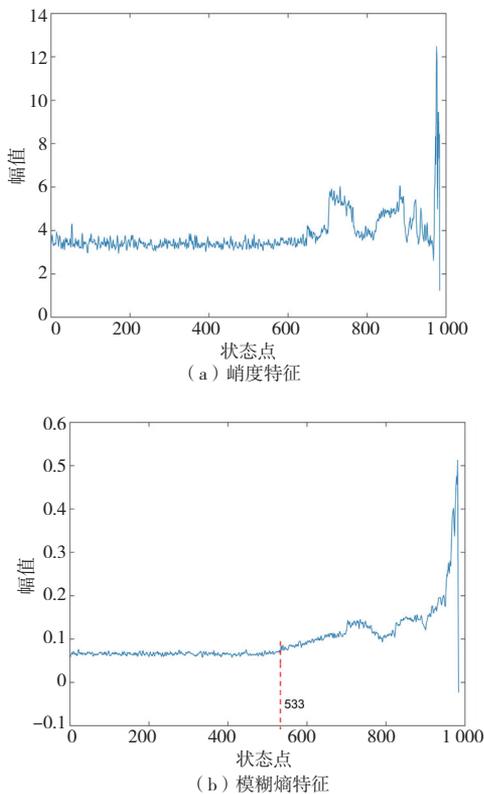


图 5 特征序列图

尽管将模糊熵作为退化特征指标具有一定的优越性,但由图 5(b)可以看出模糊熵特征的单调性并不是很好。因此,进一步采用累积变换方法对模糊熵特征进行处理,所得累积模糊熵特征序列如图 6 所示。

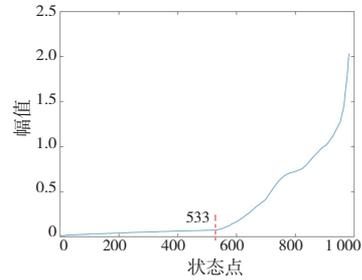


图 6 累积模糊熵特征

从上文可以看出,累积模糊熵的特征曲线在第 533 个状态点之前的变化幅度基本上没有明显变化,说明轴承状态保持相对稳定;同样在第 533 个状态点之后,累积模糊熵特征的增长幅度发生明显变化,说明轴承状态开始发生退化。此外,通过式(10)一式(11)分别计算模糊熵特征序列与累积模糊熵特征序列的单调性评估值,如表 1 所示。可以看出,模糊熵特征经过累积变换后,其单调性评估值变为 1,说明单调性得到明显提升,累积模糊熵特征序列整体上保持递增,更加符合轴承劣化程度的单调性变化。

表 1 特征单调性

特征	模糊熵	累积模糊熵
单调性评估值	0.030	1.000

3.2 退化趋势预测

利用所构建的 Bi-LSTM 模型对提取的退化特征指标进行预测,预测结果如图 7 所示。可以看出,基于 Bi-LSTM 模型所得的预测值与真实值在整体上有着很好的拟合效果,通过式(18)可得相应的决定系数为 0.982,进一步说明预测效果不错。

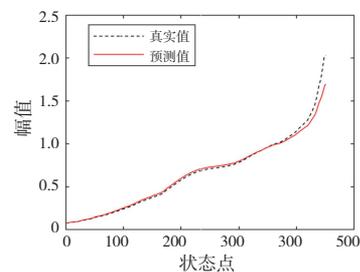


图 7 预测结果

3.3 预测方法对比分析

采用相同的累积模糊熵特征序列,对比 LSTM 模型、GRU 模型以及所构建 Bi-LSTM 模型的预测准确性,并且训练集和测试集保持一致。利用式 (18) 计算预测结果的决定系数 R^2 ; 同时,为避免偶然性的结果,对 3 个模型各训练 10 次,采用 10 次预测结果的决定系数平均值进行比较,其结果如表 2 所示。从表 2 中可以看出,所构建的 Bi-LSTM 模型在预测准确性上有着最好的表现。

表 2 不同预测方法对比

预测方法	决定系数
GRU	0.918
LSTM	0.974
Bi-LSTM	0.988

4 结语

1) 相较于模糊熵特征,通过累积模糊熵特征来表征轴承退化过程,不仅同样可以体现出早期的轴承退化,而且弥补了模糊熵特征单调性较差的不足,可以更好地反映出劣化程度逐步加重的轴承退化过程。

2) 基于具有良好单调趋势的累积模糊熵特征,应用 Bi-LSTM 模型对轴承退化趋势进行预测,并对比 LSTM 与 GRU 模型,发现 Bi-LSTM 模型具有较高的预测准确性。

参考文献:

[1] 汤勇. 基于 Morlet 小波与尺度空间的轴承故障诊断方法研究[D]. 成都:西南交通大学,2020.
 [2] 张景超,张金敏,张淑清,等. 基于小波及非线性预测的轴承故障诊断方法[J]. 仪器仪表学报,2012,

33(1):127-131.

[3] 陈法法,杨勇,马婧华,等. 信息熵与优化 LS-SVM 的轴承性能退化模糊粒化预测[J]. 仪器仪表学报,2016,37(4):779-787.
 [4] JIN Z Z, XIAO Y L, HE D Q, et al. Fault diagnosis of bearing based on refined piecewise composite multivariate multiscale fuzzy entropy[J]. Digital Signal Processing,2023,133:103884.
 [5] 陈剑,蔡坤奇,陶善勇,等. 基于 IITD 模糊熵与随机森林的滚动轴承故障诊断方法[J]. 计量学报,2021,42(6):774-779.
 [6] JIN Z Z, SUN Y Q. Bearing fault diagnosis based on VMD fuzzy entropy and improved deep belief networks[J]. Journal of Vibration Engineering & Technologies,2023,11(2):577-587.
 [7] 唐旭,徐卫晓,谭继文,等. 基于 LSTM 的滚动轴承剩余使用寿命预测[J]. 机械设计,2019,36(增刊1):117-119.
 [8] 康守强,周月,王玉静,等. 基于改进 SAE 和双向 LSTM 的滚动轴承 RUL 预测方法[J]. 自动化学报,2022,48(9):2327-2336.
 [9] CHEN W T, WANG Z Z, XIE H B, et al. Characterization of surface EMG signal based on fuzzy entropy[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering,2007,15(2):266-272.
 [10] DUAN L X, ZHAO F, WANG J J, et al. An integrated cumulative transformation and feature fusion approach for bearing degradation prognostics [J]. Shock and Vibration,2018,2018:9067184.
 [11] QIU H, LEE J, LIN J, et al. Wavelet filter-based weak signature detection method and its application on rolling element bearing prognostics [J]. Journal of Sound Vibration,2006,289(4/5):1066-1090.

收稿日期:2023-08-07

(上接第 16 页)

[9] JIANG H Y, LI Q, YU X, et al. Ventilation improvement after pneumonia treatment evaluated with electrical impedance tomography: an observational study [J]. Physiological Measurement,2021,42(10):104001.
 [10] THEERAWIT P, PUKAPONG P, SUTHERASAN Y. Relationship between lung ultrasound and electrical impedance tomography as regional assessment tools during PEEP titration in acute respiratory distress syndrome caused by multi-lobar pneumonia: a pilot study [J]. Journal of Clinical Monitoring and

Computing,2023,37(3):889-897.

[11] 中国卫生信息与健康医疗大数据学会重症医学分会标准委员会,北京肿瘤学会重症医学专业委员会,中国重症肺电阻抗工作组,等. 肺电阻抗成像技术在重症呼吸管理中的临床应用中国专家共识[J]. 中华医学杂志,2022,102(9):615-628.
 [12] GRYCHTOL B, MÜLLER B, ADLER A. 3D EIT image reconstruction with GREIT [J]. Physiological Measurement,2016,37(6):785-800.

收稿日期:2024-12-27