

基于互相关能比熵和 BiGRU—GRU 的 轧机关键零部件早期故障诊断

胡 睿

(重庆交通大学 机电与车辆工程学院, 重庆 400000)

摘要: 轧机作为机械制造行业的重要设备, 工况环境复杂, 其关键零部件极易发生故障, 对其进行早期故障诊断, 趋势预测存在困难; 对此文章以轴承为例, 提出了一种新型性能退化指标用于检测出现早期故障的时刻; 对于防止轧机工作环境复杂的问题, 首先要对采集到的样本信号进行降噪, 实现对噪声信号的去除, 之后利用互相关函数对样本前后数据进行互相关分析, 然后求分析所得数据的所有极值点能量与总能量得比值, 最后将做的比值带入信息熵公式, 即为最终得性能退化指标, 即互相关能比熵, 并通过包络谱分析验证指标的有效性; 针对轴承性能退化趋势预测的问题, 利用门控循环单元网络 (GRU) 和双向门控循环单元网络 (BiGRU) 各自的优点建立了 BiGRU—GRU 网络。将采集到的数据分为训练数据和测试数据, 在训练数据中训练之后, 对测试数据进行预测, 实现了对轴承性能退化趋势的预测。并通过对比实验证明了所提性能评估指标和网络比一般指标和网络具有更好的效果。

关键词: 轧机; 轴承; 早期故障诊断; 退化趋势预测; 互相关能比熵; 门控循环单元网络

Early Fault Diagnosis of Key Parts of Rolling Mill Based on Cross—Correlation Energy Ratio Entropy and BiGRU—GRU

HU Rui

(School of Mechatronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400000, China)

Abstract: As an important equipment for metallurgy, rolling mill has complex working conditions, and its key parts are easy to break down, so it is difficult to make early fault diagnosis and trend prediction. Taking bearing as an example, a new performance degradation index is proposed to detect the moment of early failure. To prevent the mill work environment complex problems, first of all samples were collected for signal de-noising and implementation, the noise signal is eliminated after the cross-correlation function is used to analyzed the data before and after the sample cross-correlation, then the ratio data is analyzed from all the extreme value and total energy, which taken into the information entropy formula, finally the ultimate performance degradation index is made out, namely the cross correlation energy ratio entropy, and the index validity is verified by the envelope spectrum analysis. Aiming at the problem of bearing performance degradation trend prediction, the BiGRU—GRU network is established based on the respective advantages of Gate Recurrent Unit (GRU) and Bidirectional Gate Recurrent Unit (BiGRU). The collected data are divided into training data and test data. After training in the training data, the test data are predicted to realize the bearing performance degradation trend. Comparative experiments show that the proposed performance evaluation index and network have more effective than the general index and network.

Keywords: rolling mill; bearing; early fault diagnosis; degradation trend prediction; cross-correlation energy ratio entropy; gate recurrent unit

收稿日期: 2021-11-15; 修回日期: 2021-12-21。

作者简介: 胡睿 (1995-), 男, 河南禹州人, 硕士研究生, 主要从事机械轧制成型、结构分析、故障诊断方向的研究。

引用格式: 胡睿. 基于互相关能比熵和 BiGRU—GRU 的轧机关键零部件早期故障诊断[J]. 计算机测量与控制, 2022, 30(2): 95-102.

0 引言

钢材是实体制造业必不可少的材料,而轧机是生产钢材必须的工业设备。随着对钢铁材料的需求和质量的提升,轧机的工艺情况和工作环境也变得越来越复杂,进而导致轧机出现故障的频率不断上升^[1-2]。因此轧机的故障诊断技术也变得越来越重要,较快诊断出轧机故障所在位置能较大减少损失,提高生产效率。较早或提前检测出轧机可能出现的故障则能最大程度减少损失。轧机出现故障的主要原因之一就是因其关键零部件过度磨损造成,即轴承、齿轮、电机、轧辊等。因此对关键零部件的早期故障诊断变得尤为重要,且极为困难^[3],其主要诊断方式为通过传感器采集关键零部件的振动数据,对其进行分析诊断。本文以关键零部件轴承为例,对其进行早期故障诊断研究分析。主要研究内容为两点:一是判断出轴承出现早期故障时的时期,二是如何实现对轴承的退化趋势进行预测。

对于判断早期故障点时刻的方法目前主要是通过设计性能衰退指标的方式来进行判断的。Li 等^[4]采用均方根和峭度值指标对轴承性能进行评估,Zhang 等^[5]采用排列熵作为轴承的性能退化指标,Boskoski 等^[6]利用 Renyi 熵建立了特征指标,此外还有利用时域、频域指标主成分分析进行融合的方式建立性能评估指标^[7-8]。而以上方法要么不能很好地判别出轴承的早期故障点,要么会出现误判断行为,对早期故障不敏感。针对上述情况本文利用小波降噪,互相关分析及信息熵提出了一种判别轴承故障诊断的新型指标,即互相关能比熵,较好地解决了早期故障诊断的难题,通过准备判断出轴承出现早期故障的位置,尽可能的降低因轴承损坏造成的损失,防止事故的发生。

通过对计算出的轴承性能评估指标进行预测,即利用已采集的数据的指标预测下一阶段的退化指标,能够观察轴承的性能退化趋势,对其运行状态进行检测^[9]。Chen 等^[10]利用支持向量机(SVM, support vector machine)对计算出的指标进行预测,郑小霞等^[11]利用门控循环单元网络(GRU, gate recurrent unit)网络预测性能退化指标趋势,于重重等^[12]提出将时间卷积网络(TCN, time convolution network)

用于退化指标的预测。很少有人分别有人将两种不同网络的优点进行结合组成一个新型网络,进而去预测轴承的退化趋势。因此本文通过利用双向门控循环单元能对时间序列的将来特征和过去特征同时提取的优点,以及 GRU 较快的训练和预测运算速度进行结合提出了一种新的时间预测网络 BiGRU-GRU (bidirectional gate recurrent unit)。可以较准确地实现对轴承退化趋势的预测。

综上所述,针对轧机中的关键部件轴承,本文首先建立了互相关能比熵指标,通过对采集到的样本数据进行计算判断出早期故障点,之后利用所提出的 BiGRU-GRU 网络实现对轴承退化趋势的预测。

1 理论基础

1.1 小波变换

小波变换广泛应用于数据处理中,尤其在非线性瞬时变信号中,它通过其伸缩平移功能实现对信号的多尺度分析^[13]。其原理是利用不同尺度的小波基函数对信号进行分解,最终得到不同尺度下的小波系数。连续信号下定义的小波变换公式如式(1)所示:

$$WT(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} f(t) * \varphi\left(\frac{t-\tau}{a}\right) dt \quad (1)$$

式中, a 为尺度因子, τ 为位移因子,分别实现伸缩和平移功能。由于轴承振动信号为离散数据,所以需要对其进行离散化处理。通过公式(2)对尺度因子和位移因子进行变换,最终得到离散形式下的小波变换,如公式(3)所示:

$$\begin{cases} a = a_0^j \\ \tau = ka_0^i \tau_0 \end{cases} \quad j, k \in Z \quad (2)$$

$$DWT(j, k) = a_0^{-\frac{j}{2}} \int_{-\infty}^{+\infty} f(x) \bar{\omega}(a_0^{-j} t - k\tau_0) dx \quad (3)$$

在对信号进行小波变换之后,得到一系列小波系数,其中噪声信号所对应的系数较小,而正常信号对应的系数较大,所以可以将小波系数较小的信号进行滤除,只保留正常信号所对因的小波系数,之后再对小波系数进行反变换得到去噪声干扰后的信号^[14]。选用 3.1 节中所提的全寿命轴承数据按照上述降噪方法对轴承信号进行降噪,结果如图 1 所示。

由图 1 可以看出信号经过小波变换降噪之后由于

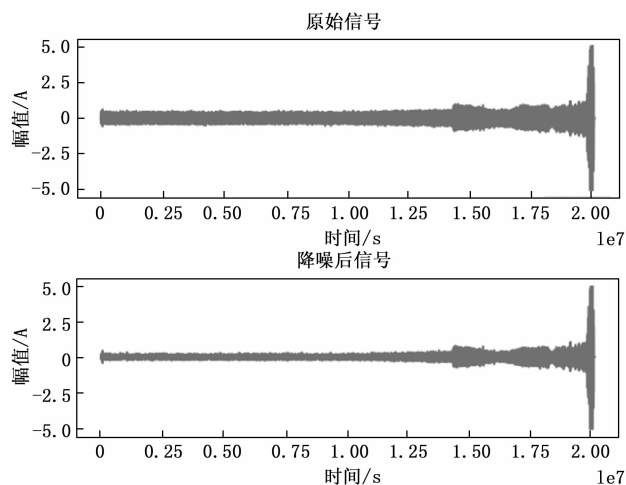


图 1 全寿命信号降噪前后对比

去除了一系列噪声信号变得更加平滑，因此避免了在计算指标时候引起不必要的干扰。

1.2 互相关函数

互相关函数是描述两个数据或信号 $f(t)$ 和 $g(t)$ 在不同时刻取值之间的联系^[15]，具体表示如式 (4) 所示：

$$(f * g)(\tau) = \int_{-\infty}^{+\infty} f^*(t)g(t + \tau)dt \quad (4)$$

式 (4) 为其连续形式，一般只有在做理论分析时采用，在实际工程应用上一般采用其离散形式，其离散形式表示为公式 (5)：

$$(f * g)(N) = \sum_{k=1}^N f^*[M]g(M + N) \quad (5)$$

式中， M 表示当前时刻， N 表示移动了多少个采样周期， $N + M$ 即表示第 $N + M$ 个时刻。由公式 (4) 和 (5) 可以看出其运算方式类似于卷积运算，都是由两段数据进行滑动相乘，但不同的是卷积满足交换律，而互相关不满足交换律。对信号进行互相关运算的最终目的是提取出两信号之间的关联性。

1.3 信息熵

信息熵是用来衡量数据混乱程度的一种度量^[16]，数据混乱程度越高，熵值越大，混乱程度越低，熵值越小。设 $X = (x_1, x_2, \dots, x_n)$ 为随机信号，其熵值计算如公式 (6) 所示：

$$H(X) = - \sum_{i=1}^n p(x_i) \ln_2 p(x_i) \quad (6)$$

式中， $p(x_i)$ 为数据 x_i 出现的概率，且 $\sum_{i=1}^n p(x_i) = 1$ ，当随机变量 X 中每个数据出现的概率都相等时，信息熵取最大值。

1.4 门控循环单元网络

循环神经网络 (RNN, recurrent neural network) 是一种处理时间序列的网络，被应用于时间序列的分类、预测等问题^[17]。但由于其网络结构特性导致在处理长时间序列的时候容易导致梯度消失和梯度爆炸的现象。而之后的长短时记忆网络 (LSTM, long-short term memory)^[18] 通过改进网络结构并引入细胞状态很好地解决了这一问题。GRU 网络^[19] 是 LSTM 的一种变体，通过将 LSTM 的遗忘门和输入们进行合并，得到一个更新门，更新门的值越大，表明前一时刻的信息越重要，保留的越多。同时还将隐藏状态和细胞状态进行融合，以及其他的一些改动，最终形成图 2 所示的结构，只有更新门和重置门两个门结构，简化了 LSTM 网络，使其运算速度较 LSTM 有很大提升，其具体公式如 (7) ~ (10) 所示：

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (7)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (8)$$

$$\tilde{h} = \tanh(W \cdot [r_t * h_{t-1}, x_t]) \quad (9)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (10)$$

式中， z_t, r_t 分别为更新门和重置门， σ 为 sigmoid 激活函数，输出区间为 $[0, 1]$ ，通过这样，网络能确定哪些信息重要，哪些信息不重要或者需要遗忘。tanh 为双曲正切函数，输出区间为 $[-1, 1]$ 。上一隐藏层输出 h_{t-1} 和输入 x_t 的汇总为 \tilde{h} ， W_z, W_r 和 W 为待训练参数。

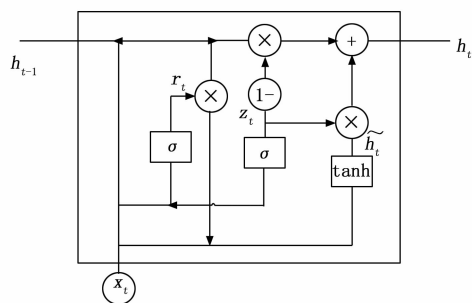


图 2 GRU 结构

在前向传播过程时，首先计算更新门和重置门的

值,即按照公式 1)~7) 将 x_t 和 h_{t-1} 与随机初始化的权重矩阵进行相乘,然后经过 sigmoid 激活函数使输出为 $[0, 1]$ 之间。之后重置门输出值作用在 h_{t-1} 上,控制上一时刻输出的信息有多少被利用,最后就是与 x_t 和更新门的输出进行线性化运算后乘相应矩阵,再过 tanh 激活函数,得到最含状态输出 \tilde{h} 。

1.5 双向门控循环单元网络

无论是 LSTM 还是 GRU 网络在计算过程中只考虑了过去的信息,而对未来信息没有进行考虑,而 Bi-GRU^[20] 则同时对过去信息和未来信息进行考虑。Bi-GRU 通过将传输方向相反的隐藏层连接到一个输出层,因此输出层便可以同时从过去来未来两个时态获取信息。通过前向网络获取前向时间序列信息,通过后向网络获取后向时间序列信息。这意味着可以训练出更精确的模型。其网络运算过程如图 3 所示,其当前隐藏层状态可以由当前输入 $x_t, (t-1)$ 时刻的前向隐藏层状态 h_{t-1} 和反向隐藏层状态 h'_{t-1} 三者共同决定。其中 Bi-GRU 内部结构单元及计算公式和 GRU 一样。

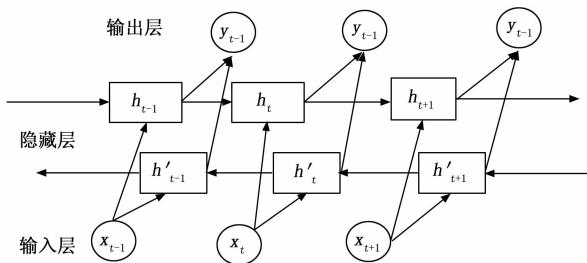


图 3 BiGRU 展开图

2 早期故障诊断方法

2.1 性能退化指标构建

通过对采集到的轴承信号进行分析,进而判断轴承是否出现故障,是一种有效且实用的故障诊断方法。其主要分析方法有时域、频域、时频域等,但这都需要一定专家知识,不利于实际生产应用,且对于早期故障信号不敏感,而本文通过构建性能退化指标的方式能较好地解决这些问题。性能退化指标构建的步骤如下:

1) 由于轧机系统工作环境复杂,采集的数据易受噪声干扰,因此首先对信号进行降噪,首先进行小波变换得到一系列小波系数,将较小系数对于的信号

进行滤除,之后对其余系数进行小波反变换得到降噪后的信号。

2) 将每个降噪后的样本信号等分为前后两部分,之后将公式 1)~2) 转换为离散形式并做互相关运算,每个样本经运算后得到一组数据。

3) 对得到的每组数据求出所有局部极大值点。计算极大值点能量。

4) 将每组数据的极大值点能量与总能量进行相比,得到极大值能量与总能量的比值,称之为互相关能量比,其计算公式如(11)所示:

$$p_i = \frac{\sum M_m^2}{\sum_{j=1}^n S_j^2}, i = 1, 2, \dots, n \quad (11)$$

式中, M_m 表示互相关运算后局部极大值点, S_j 则表示所有数据。

5) 最后将得到的互相关能量比 P_i 带入式(1)~(3)所示的信息熵公式中求得采集到的一个样本的退化指标,即互相关能比熵。其具体流程如图 3 所示。

在对采集到数据求的指标之后,还需要知道指标达到哪一个值得时候,轴承开始出现故障,即对指标进行阈值划定,本文采用切比雪夫不等式的方法进行阈值划分,其公式如式(12)所示:

$$P\{|X - \mu| < \epsilon\} \geq 1 - \frac{\sigma^2}{\epsilon^2} \quad (12)$$

式中, X 为随机变量, σ 为标准差, μ 为数学期望。由公式可以看出当 $\epsilon = 5\sigma$ 时,数据分布在 $(\epsilon - 5\sigma, \epsilon + 5\sigma)$ 之间的概率为 96%,因此可以将互相关能比值大于 $\epsilon + 5\sigma$ 的视为故障点,通过此方式判断故障样本。

2.2 BiGRU-GRU 网络结构

BiGRU 可以在预测过程中可以同时考虑过去和将来的时序信息,但其运算速度较慢,而 GRU 网络由于只是单向进行运算,具有较快的速度。一般在深度学习做回归或者分类中,单一层的网络不能提取出数据之间的非线性特征,并且如果数据量较小非常容易造成过拟合线性。增加网络深度能增加模型的非线性特征提取能力,可以更好地提取出数据之间的相关信息。在考虑运行速度的同时,本文选择采用两层循环神经网络。如果两层都只用 GRU 网络,则不能同时考虑过去和未来的信息,而只用 Bi-GRU 网络,

由于每一层都要经过双向运算，则速度不如只用 GRU 网络。因此本文考虑将 BiGRU 网络和 GRU 网络进行结合，即使得在运算过程中同时考虑过去和将来的时序信息，又使得网络有较快的处理速度，可以满足对轧机轴承的运行状态实时预测。具体做法为在数据经过 BiGRU 运算后输出的数据再输入到单向 GRU 网络结构中，最后预测出互相关能比熵。网络运算过程如图 4 所示。

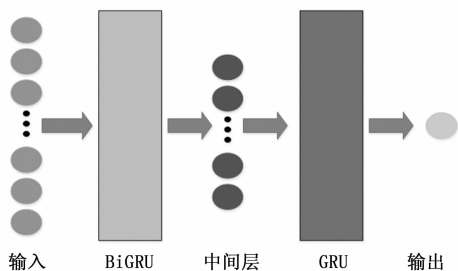


图 4 网络结构

2.3 早期故障诊断流程

首先对采集的轧机轴承信号进行小波变换降噪处理，之后构建 2.1 所提的互相关能比熵，本文所提互相关能比熵只需一个样本即可求得每个此样本的退化指标值，无需与其它样本进行运算，简单高效。所以可利用初期采集到的正常振动信号进行阈值划定；然后对后面每次采集到的振动信号样本计算阈值，当计算出的退化大于所设定阈值时，可判定此时轴承的内圈，外圈或者滚动体某处已经出现了一定的磨损退化，即已经出现了早期故障，性能退化指标最主要的价值就是监测处早期故障位置，以便于后期运行维护。

在监测到早期故障时刻之后，通过对之后的振动数据进行指标计算，可以观察处轴承的性能退化趋势。通过将这些指标数据进行一定重采样及维度变换输入到 GRU 网络进行训练，使网络能够提取到指标数据之间的非线性关系，在网络模型训练达到一定精度之后，再将当前采集数据的指标输入到网络模型中实现对轴承退化趋势的实时预测。整体早期故障诊断及轴承性能退化趋势过程如图 5 所示。

3 实验及结果分析

3.1 实验数据介绍

本文实验数据选用辛辛那提大学所公开的轴承全

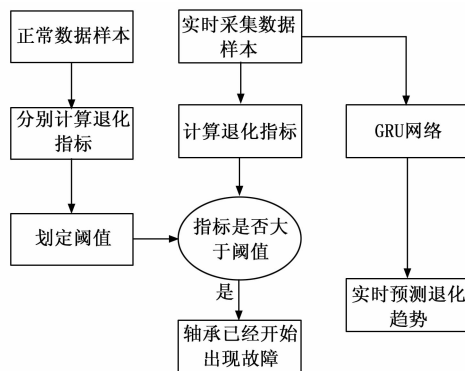


图 5 整体流程

寿命数据集，采集试验台如图 6 所示，一个轴上安装 4 个轴承，一共进行了 3 次实验，实验采集频率是 20 Hz，采集的每个数据文件中有 20 480 个数据点。本文选择第二次实验的第一个轴承进行方法验证，其中一共有 984 个数据文件。并且最后在第 3 次实验的第 3 个轴承上进行了泛化性能验证。

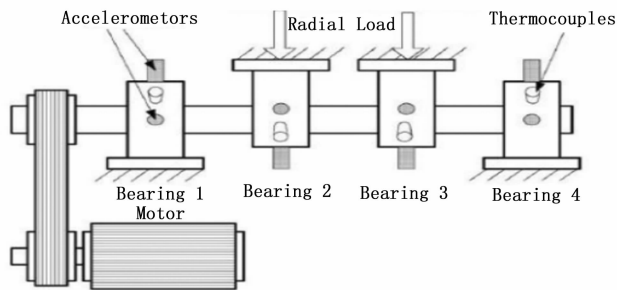


图 6 数据采集试验台

3.2 退化指标验证

按 2.1 节所提指标构建方式对所选用数据集进行性能指标计算，其中一个样本文件中有 20 480 个数据点，将前 10 240 个时序数据与后 10 240 个时序数据进行互相关运算，之后计算极大值点能量与极小值点能量的比值，最后带入求熵公式，求得互相关能比熵。一共 984 个文件，总共计算出 984 个熵值。其结果如图 7 所示。

由图中可以看出，轴承在第 533 个样本处互相关能比熵大于所设定阈值，之后便突增，表明轴承从此时已经开始出现故障，而后出现过下降，分析其原因可能因为在旋转过程中由于不断磨损出现了自愈合现象。虽然出现了自愈合现象但在采集第 533 个样本时间之后其互相关能比熵值已经不能恢复到正常运行时的数值，体

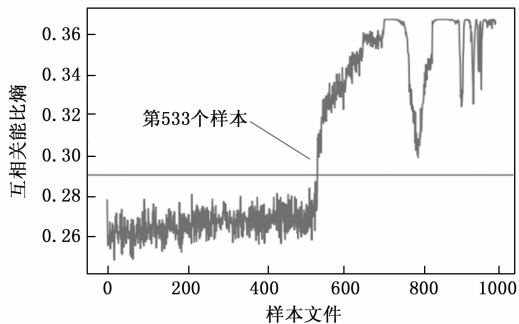


图 7 互相关能比熵

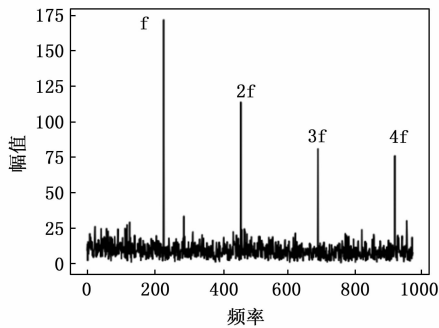


图 9 第 600 个样本的包络谱

现了本文所提性能退化指标的有效性。在第 533 个样本之后由于轴承已经出现故障，此时需要适时更换轴承，所提的性能退化指标可以通过对故障的早期判断，预防了因为轴承故障而产生的较大损失。

并且由图 7 可以看出，轴承大概经历了 4 中退化趋势，分别使前 533 个样本之前的正常运行期，第 533 样本之后的到指标达到第一个极大值之间的轻度退化期，之后指标值下降的自愈合期以及最后的迅速退化至失效期。

3.2.1 包络谱验证

包络谱是一种信号解调方法，广泛应用于机械系统故障诊断，特别是滚动轴承。轴承在运行过程中会由于故障引起的周期性脉冲，这些低频冲击信号会与高频振动发生调制，对其进行包络和低通滤波会得到相应的共振解调波形。

所选用的第二次实验第一个轴承的最终故障类型为外圈损坏，通过理论公式及轴承参数计算外圈故障频率为 236 Hz。对其第 532, 533, 600 个样本进行包络谱解调，结果如图 8 和 9 所示。

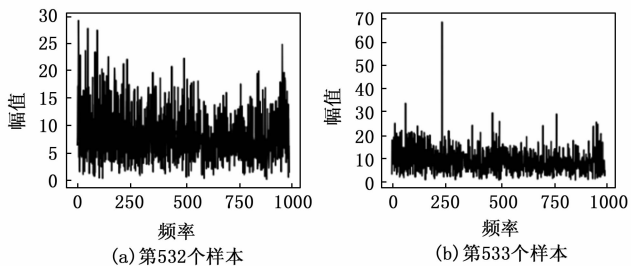


图 8 第 532 个和 533 个样本的包络谱

由图 7~9 可以看出，所测试轴承的包络谱在第 532 个样本时其故障频率处还没有较明显的幅值，而到了第 533 个样本的时候，其故障频率一倍频附近已

经有较高的幅值出现，表明轴承在此时已经开始出现了故障，与所提出的互相关能比熵相对应，证明了指标的有效性。之后对第 600 个样本继续进行包络谱分析，可以看出此时轴承在其一倍频，二倍频及其三、四倍频处皆以出现较明显的幅值，说明此时轴承已经出现严重故障，需尽快更换轴承。

3.2.2 与常用指标对比

为了证明本文所提互相关能比熵退化指标的优越性，将其与常用指标进行对比。选择均方根和峭度值进行对比，均方根和峭度值都经用来检测数据混乱程度和时间序列突变，将其对选用轴承数据进行计算，结果如图 10 和 11 所示。

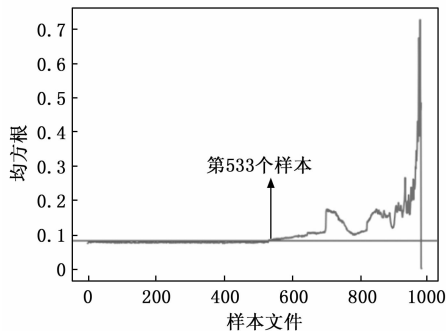


图 10 均方根指标

由图中可以看出，均方根值虽然可以检测到轴承出现早期故障的样本点，但是在出现故障处均方根值上升不明显，一旦设定的阈值出现轻微误差便会造成判断失误行为，可能过早判断出故障出现点，也可能过晚判断处故障出现位置。一旦过晚判断便很有可能造成严重损失。而峭度值判断出的故障出现位置在第 646 个样本处，跟实际出现故障位置相差了 113 个样本，由上述包络谱分析可知，此时轴承已经出现了严重的故障，未能监测出早期故障点位置。所以无论均

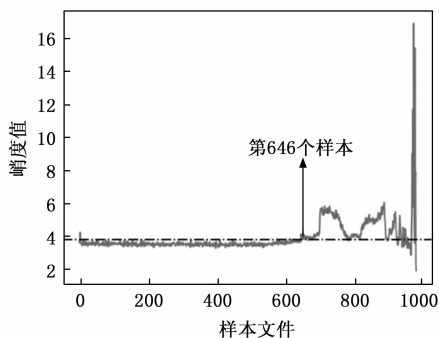


图 11 峭度值指标

方根还是峭度值对轴承的早期诊断效果都不如所提的互相关能比熵。

3.2.3 在其他数据效果

本节对第 3 次采集实验采集的第 3 个轴承进行，此轴承最后在运行最后出现了内圈损坏故障。采集到的数据文件一共有 6 324 个，对其分别计算互相关能比熵，结果如图 12 所示。可以看出轴承在第 5 976 个样本处的互相关能比熵大于所设定的阈值，此时轴承已经出现早期故障。可以看出其指标退化趋势与实验一差距较大，既不属于同一种失效形式。但指标同样能监测处早期故障点，表明了所提方法具有一定泛化能力。

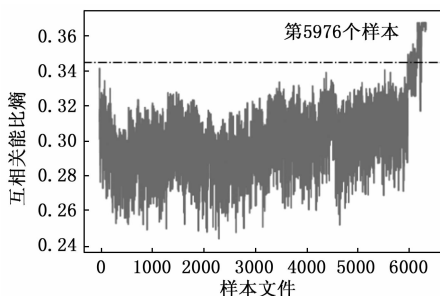


图 12 轴承 3-3 的互相关能比熵

3.3 退化趋势预测

在对采集到的样本数据计算出其互相关能比熵之后，再对其进行趋势预测，可以反应轴承的退化过程，了解到它的运行状态。选用计算出的第二次实验第一个轴承的互相关能比熵进行预测。由于指标数据较少，所以首先需要通过重叠采样对数据进行扩充。以第 400 个到第 700 个互相关能比熵的值作为训练集进行训练，其中训练数据采集方式为每 50 个指标点为一个样本，之后将指标点后移一位构成下一个样本

的数据，依次类推，最后第 400 个指标值到第 700 个指标值一共可以构成 250 个训练样本。第 700 个值之后的数据作为测试集对模型进行测试，按照构造训练集样本的方法构造测试集，一共可构成 234 个测试集样本。训练参数中时间步设置为 50，优化器选用 Adam，损失函数选择均方误差。模型训练介绍后测试结果如图 13 所示，可以看出所提 BiGRU-GRU 网络能很好地预测出轴承的退化趋势。

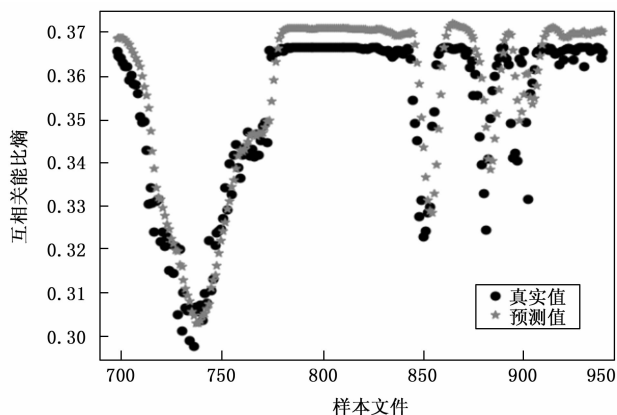


图 13 Bi-GRU 预测效果

为了验证本文所提 BiGRU-GRU 网络的有效性，将其与常用的两类预测网络 LSTM 和 GRU 进行对比，实验对以上网络选取同样的网络参数，选择均方误差和平均绝对误差作为对比准则，最后实验结果如表 1 所示，可以看出 BiGRU-GRU 网络的两类误差值均小于单独的 LSTM 和 GRU 网络。

表 1 与其他网络对比结果

	LSTM	GRU	BiGRU-GRU
均方误差	0.009 27	0.007 73	0.007 69
平均绝对误差	0.006 55	0.005 16	0.005 06

实际应用中可以先对加速度传感器采集的实时轴承信号计算出互相关能比熵，然后通过上述所提出的退化预测网络进行预测下一时刻轴承的性能退化指标，进而实现对轴承运行状态的实时预测，防止因轴承损坏而引起重大损失。

4 结束语

1) 对于轧机系统中关键零部件的早期故障诊断问题，本文以轴承为例，在对采集到的数据进行小波降噪之后，构建了互相关能比熵，将其作为轴承性能

退化的标准, 用来判断轴承出现早期故障的初始时间, 并通过包络谱分析验证了所提性能退化指标的有效性, 也与常用的均方根指标和峭度值指标对比, 结果表明所提指标效果最好。

2) 通过 Bi-GRU 和单项 GRU 结合, 提出了 BiGRU-GRU 网络, 通过次网络模型来对样本数据计算出的退化指标值进行预测, 结果显示网络能很好地跟踪轴承的退化趋势。

3) 在轧机实际工作过程中, 互相关能比熵通过对轴承振动的数据的计算, 可以对轴实现早期故障诊断, BiGRU-GRU 网络可以实现对退化趋势的预测, 具有一定实用性。

参考文献:

- [1] 王少伟, 徐 锋, 晁海涛, 等. 基于支持向量机的纺织热轧机故障分类的研究 [J]. 现代制造工程, 2021 (6): 116-121.
- [2] 彭 艳. 冶金轧制设备技术数字化智能化发展综述 [J]. 燕山大学学报, 2020, 44 (3): 218-237.
- [3] YUAN J, HE Z J, ZI Y Y. Gear fault detection using customized multiwavelet lifting schemes [J]. Mechanical System and Signal Processing, 2010, 24 (5): 1509-1528.
- [4] LI N P, LEI Y G, LIN J, et al. An improved exponential model for predicting remaining useful life of rolling element bearings [J]. IEEE Trans. Industry Electron., 2015, 62: 7762-7773.
- [5] ZHANG X Y, LIANG Y T, ZHOU J Z, et al. A novel bearing fault diagnosis model integrated permutation entropy, ensemble empirical mode decomposition and optimized SVM [J]. Measurement, 2015, 69: 164-179.
- [6] BOSKOSKI P, GASPERIN M, PETELIN D, et al. Bearing fault prognostics using Renyientropy based features and Gaussian process models [J]. Mechanical Systems and Signal Processing, 2015 (52/53): 327-337.
- [7] 朱文昌, 罗梦婷, 倪广县, 等. 随机矩阵理论和主成分分析融合的滚动轴承性能退化评估方法 [J]. 西安交通大学学报, 2021, 55 (2): 55-63.
- [8] 肖顺根, 马善红, 宋萌萌, 等. 基于 EEMD 和 PCA 滚动轴承性能退化指标的提取方法 [J]. 江南大学学报 (自然科学版), 2015, 14 (5): 572-579.
- [9] ZHAO H M, LIU H D, XU J J, et al. Performance

prediction using high-order differential mathematical morphology gradient spectrum entropy and extreme learning machine [J]. IEEE Transaction on Instrumentation and Measurement, 2020, 69 (7): 4165-4172.

- [10] CHEN X F, SHEN Z J, HE Z J, et al. Remaining life prognostics of rolling bearing based on relative features and multivariable support vector machine [J]. Proceedings of the Institution of Mechanical Engineers Part C-Journal of Mechanical Engineering Science, 2013, 272 (12): 2849-2860.
- [11] 郑小霞, 钱铁群, 王 帅. 基于优选小波包与马氏距离的滚动轴承性能退化 GRU 预测 [J]. 振动与冲击, 2020, 39 (17): 39-46, 63.
- [12] 于重重, 宁亚倩, 秦 勇, 等. 基于 T-SNE 样本熵和 TCN 的滚动轴承状态退化趋势预测 [J]. 仪器仪表学报, 2019, 40 (8): 39-46.
- [13] 李志农, 朱 明, 褚福磊, 等. 基于经验小波变换的机械故障诊断方法研究 [J]. 仪器仪表学报, 2014, 35 (11): 2423-2432.
- [14] 李树勋, 王志辉, 康云星, 等. 基于改进小波阈值函数的安全阀排放声信号降噪 [J]. 振动与冲击, 2021, 40 (12): 143-150.
- [15] 霍林生, 李 旭, 李宏男, 等. 基于互相关函数幅值和 SVM 的输电塔损伤识别 [J]. 振动·测试与诊断, 2017, 37 (3): 495-500.
- [16] 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.
- [17] 杨 丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述 [J]. 计算机应用, 2018, 38 (s2): 1-6.
- [18] ZHANG B, ZHANG S H, LI W H. Bearing performance degradation assessment using long short-term memory recurrent network [J]. Computers in Industry, 2019, 106: 14-29.
- [19] TAO Y, WANG X D, SANCHEZ R V, et al. Multi-layer gated recurrent unit for spur gear fault diagnosis [J]. Prognostics and System Health Management Conference, 2019, 90-95.
- [20] DENG Y P, WANG L, JIA H, et al. A sequence-to-sequence deep learning architecture based on bidirectional GRU for type recognition and time location of combined power quality disturbance [J]. IEEE Transactions on Industrial Informatics, 2019, 15 (8): 4481-4493.