

• 机械工程 •

DOI:10.15961/j.jsuese.202200709



本刊网刊

基于改进麻雀搜索算法优化LSTM的滚动轴承故障诊断

周 玉, 房 倩, 裴泽宣, 白 磊

(华北水利水电大学 电气工程学院, 河南 郑州 450045)

摘 要: 为了对滚动轴承的工作状态及故障类别进行准确的诊断, 本文采用长短时记忆(LSTM)神经网络作为分类器对滚动轴承数据集进行分类诊断。首先, 从滚动轴承原始运行振动信号中提取时域和频域特征参数, 组成具有高维特征参数的数据集; 使用核主成分分析(KPCA)方法对高维特征集进行降维处理, 选取重要性程度高的特征构成输入特征向量。然后, 针对LSTM神经网络在滚动轴承故障诊断中存在的超参数难以确定的问题, 提出一种基于自适应t分布策略的麻雀搜索算法优化LSTM神经网络的故障诊断方法(tSSA-LSTM)。最后, 使用凯斯西储大学滚动轴承数据中心的数据进行故障诊断精度测试、泛化性能测试及噪声环境下故障诊断性能测试等多个仿真实验, 并将本文提出的诊断模型与麻雀搜索算法优化长短时记忆神经网络(SSA-LSTM)、遗传算法优化长短时记忆神经网络(GA-LSTM)、粒子群算法优化长短时记忆神经网络(PSO-LSTM)及传统LSTM诊断模型进行对比。结果表明: tSSA可以更有效地对LSTM的隐含层神经元数量、周期次数、学习率等超参数进行合理优化; 所提方法的平均诊断准确率达到98.86%, 交叉验证平均诊断结果为98.57%; 所提方法在噪声干扰下的故障诊断准确率也优于对比方法。因此, 本文提出的tSSA-LSTM模型不仅可以更精准地诊断滚动轴承故障状态, 而且具有更强的泛化能力及抗干扰能力, 有效地提高了滚动轴承故障诊断的性能。

关键词: 麻雀搜索算法; 故障诊断; 长短时记忆神经网络; 特征提取; 滚动轴承

中图分类号: TH17; TP277

文献标志码: A

文章编号: 2096-3246(2024)02-0289-10

工业现代化时代, 人工智能的快速发展使得机械设备中的结构越来越庞大和复杂, 且被广泛地应用于涉及国计民生的重要领域, 例如高铁、航空航天发动机等^[1-3]。如果不能及时、准确地诊断出机械设备的故障, 将会带来一些难以估量的严重后果。滚动轴承作为机械设备中重要的传动元件, 同时也是易损坏部件, 其工作状态的好坏直接影响到机械设备整体的运行^[4-5]。

近年来, 国内外有关滚动轴承的故障诊断研究取得了一些进展。陈剑等^[6]提出利用改进的固有尺度分解(IITD)和模糊熵(FE)提取轴承信号中的故障特征信息来构造特征向量, 之后输入随机森林(RF)完成故障识别诊断, 这种方法可以用来改善轴承故障特征提取后难以识别的缺点。徐卓飞等^[7]将经验模

态分解与多元统计相结合提出新的轴承故障诊断方法, 主要分为两步: 首先, 对轴承的振动信号使用Hilbert-Huang变换提取故障特征; 然后, 使用主成分分析(KPCA)对故障特征集做降维处理, 获取主元特征集作为特征向量, 输入到支持向量机中完成故障诊断。郑小霞等^[8]对轴承运行振动信号完成变分模态分解后计算本征模态分量模糊熵, 并将其构成特征作为输入向量, 使用经过灰狼算法优化之后的极限学习机作为故障诊断模型进行故障诊断。Deng等^[9]对振动信号进行经验模态分解后提取特征作为支持向量机的输入向量, 并用改进的粒子群优化算法优化参数。上述浅层神经网络故障诊断方法在处理大数据方面效果不明显, 且获得的样本特征相对比较简单。

深度学习具有很强的特征学习和处理复杂数据

收稿日期: 2022-08-07

修回日期: 2022-09-12 网络出版日期: 2024-03-01

基金项目: 国家自然科学基金项目(U1504622; 31671580); 河南省高等学校青年骨干教师培养计划项目(2018GGJS079)

作者简介: 周 玉(1979—), 男, 副教授, 博士。研究方向: 智能控制与决策; 模式识别; 智能计算等。E-mail: zhouyu_beijing@126.com

的能力,逐渐被应用于故障诊断中^[10-11]。长短时记忆(LSTM)神经网络^[12]是经过发展的循环神经网络(RNN)的改进变体,已经在语音识别^[13]、声学建模^[14]、轨迹预测^[15]、句子嵌入^[16]及相关性分析^[17]等方面得到了普遍的应用,但到目前为止还没有在故障诊断领域中得到充分的研究。振动信号是序列数据,和音频信号一样具有时序关联特性,因此LSTM在滚动轴承故障诊断领域非常具有研究潜力。LSTM的诊断准确率与其所选取的超参数有关,因此,许多学者通过智能优化算法对LSTM的超参数进行优化选取。郑直等^[18]针对鲸鱼算法(WOA)寻优范围宽泛所引起的优化效果不佳的问题,使用改进鲸鱼算法(IWOA)优化LSTM的超参数,提出IWOA-LSTM故障诊断模型,可以高效地完成故障诊断与分析。孙毅刚等^[19]通过粒子群算法(PSO)对长短时记忆神经网络中的关键参数进行迭代优化,最后依据优化参数建立PSO-LSTM故障诊断模型并进行故障率时间序列预测。石怀涛等^[20]使用贝叶斯优化算法去优化滑动窗堆叠去噪自编码器(SWDAE)和LSTM网络模型的超参数,解决滚动轴承前期故障特征不明显、不容易在强噪声背景下准确诊断故障的问题。但同时上述这些优化算法有着一些本身自带的缺点,如:不能快速收敛、不易跳出局部最优等。因此,可以使用新的智能优化算法解决这些问题。

基于此,本文对使用自适应t分布策略麻雀搜索算法优化LSTM的滚动轴承故障诊断方法(tSSA-LSTM)进行研究。首先,使用核主成分分析(KPCA)方法对高维滚动轴承特征数据集进行非线性降维,去除对分类器重要性和敏感性较低的特征。然后,用经过自适应t分布改进的麻雀搜索算法(tSSA)优化LSTM的超参数,从而提高LSTM的分类性能。最后,设计实验将提出的基于自适应t分布策略的麻雀搜索算法优化长短时记忆神经网络(tSSA-LSTM)与麻雀搜索算法优化长短时记忆神经网络(SSA-LSTM)、粒子群算法优化长短时记忆神经网络(PSO-LSTM)、遗传算法优化长短时记忆神经网络(GA-LSTM)进行对比。

1 改进的麻雀搜索算法

1.1 自适应t分布策略改进麻雀搜索算法

2020年,Xue等^[21]从麻雀寻觅食物并躲避追捕者的行为特性中得到启发,研究出麻雀搜索算法(SSA)。和其他群智能优化算法相比,SSA具有寻优能力强、快速收敛、高稳定性、鲁棒性强等特点^[22]。在该算法中,麻雀寻觅食物的行为可以看作是在特定范围空间内寻找最优解的过程,麻雀搜索的目标则是在这

个过程中搜索到全局的最优值。

在SSA中,如果发现者拥有良好的适应度值,那么它会更快地获得优质食物。发现者的觅食空间要比追随者更加宽泛,这是因为它需要寻觅食物然后给追随者提供可以觅食的方向。

发现者在每次迭代期间的迭代公式如下:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} \mathbf{X}_{i,j}^t \cdot \exp\left(\frac{-i}{\alpha \cdot T_{\max}}\right), R_2 < S_T; \\ \mathbf{X}_{i,j}^t + Q \cdot \mathbf{L}, R_2 \geq S_T \end{cases} \quad (1)$$

式中: t 为当前时刻迭代次数; $T_{\max}$ 为最大迭代次数; $\mathbf{X}_{i,j}^t$ 为第*i*只麻雀在第*j*维中所占据的位置; α 为随机数, $\alpha \in (0, 1]$; R_2 和 S_T 分别为预警值和安全值,其中, $R_2 \in [0, 1]$, $S_T \in [0.5, 1]$; Q 为服从正态分布的随机数; $\mathbf{L}$ 为矩阵内全部元素均为1的 $1 \times d$ 的矩阵。

加入者位置更新如下:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{\mathbf{X}_{\text{worst}}^t - \mathbf{X}_{i,j}^t}{i^2}\right), i > n/2; \\ \mathbf{X}_p^{t+1} + |\mathbf{X}_{i,j}^{t+1} - \mathbf{X}_p^{t+1}| \cdot \mathbf{A}^+ \cdot \mathbf{L}, \text{其他} \end{cases} \quad (2)$$

式中: $\mathbf{X}_p$ 为发现者所拥有的最优位置; $\mathbf{X}_{\text{worst}}$ 为全局最差位置; n 为麻雀种群数量; $\mathbf{A}$ 为矩阵内元素会随机赋值为1或-1的 $1 \times d$ 的矩阵, $\mathbf{A}^+ = \mathbf{A}^T(\mathbf{A}\mathbf{A}^T)^{-1}$ 。

在麻雀种群中有一部分麻雀会察觉到危险发生,称其为警戒者。警戒者最初在种群中的位置是随机分布的,其位置更新按照如下公式更新:

$$\mathbf{X}_{i,j}^{t+1} = \begin{cases} \mathbf{X}_{\text{best}}^t + \beta \cdot |\mathbf{X}_{i,j}^t - \mathbf{X}_{\text{best}}^t|, f_i > f_g; \\ \mathbf{X}_{i,j}^t + K \cdot \left(\frac{|\mathbf{X}_{i,j}^t - \mathbf{X}_{\text{worst}}^t|}{(f_i - f_w) + \varepsilon} \right), f_i = f_g \end{cases} \quad (3)$$

式中: $\mathbf{X}_{\text{best}}$ 为全局最优位置; β 和 K 为步长控制参数, β 为服从正态分布的随机数, K 为随机数, $K \in [-1, 1]$; f_i 为第*i*只麻雀个体的适应度值; f_g 和 f_w 分别为全局最佳和最差的适应度值; ε 为最小的常数,旨在避免分母变成0。

在文献[21]中,对麻雀搜索算法性能进行了测试,分析之后可知:当 R_2 大于 S_T 时,发现者将按正态分布随机移动到当前位置附近(即其值收敛于最优位置);当 R_2 小于 S_T 时,麻雀的每一维都在变小(即其值收敛于0),这不是一个好的策略。因此,该算法在求解有离原点较近的最优解的函数时,麻雀搜索算法比其他群智能优化算法的性能优越很多;反之,麻雀搜索算法的性能稍有下降。由于不能肯定最优解在实际全局寻找最优解过程中存在的位置,所以本文采用如式(4)所示方法去除向原点收敛,从而改善麻雀搜索算法在最优解远离原点时寻优精度不高的

问题,进一步整体提高算法的全局寻优能力。发现者位置更新更正公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \cdot (1 + Q), R_2 < S_T; \\ X_{i,j}^t + Q \cdot L, R_2 \geq S_T \end{cases} \quad (4)$$

已有研究证明:高斯分布(GD)可以增强个体在最优解附近的搜索能力,加快算法的收敛速度。柯西分布(CD)能够提高个体在全部解空间内的探索能力,增加群体多样性。两者都可以有效地提升算法的优化能力。而t分布同时具有GD和CD这两者的优点。因此,本文使用自适应t分布策略对麻雀搜索算法进行改进。同时,少量的离群点对于t分布的影响要远远小于高斯分布,让回归模型基于一个长拖尾的概率分布,可以得到一个更具有鲁棒性的模型。设置随机数 r 和概率 p ,若 r 小于 p ,则采用以迭代次数 T 为t分布自由度参数的变异算子对麻雀最优位置进行扰动,可以使算法在迭代前期具有较好的全局开发能力,在迭代后期具有良好的局部探索能力。则更新后的麻雀位置描述为:

$$X_{i,j}^{t+1} = X_{i,j}^t + X_{i,j}^t \cdot t_D(T) \quad (5)$$

所提更新公式在 $X_{i,j}^t$ 的基础上增加了随机干扰项 $t_D(T)$,既充分利用了当前位置信息,又增加了随机干扰信息,有利于算法跳出局部最优。

1.2 改进麻雀搜索算法的时间复杂度分析

时间复杂度分析通常依赖于3个规则:种群初始化、计算适应度函数和更新解。假设种群数量为 N , $O(N)$ 为种群初始化过程的计算复杂性,则解的更新过程的计算复杂度为 $O(T \times N) + O(T \times N \times D)$,其中, T 为总迭代次数, D 为空间维度。因此,原始SSA总的时间复杂度为 $O(N \times (T \times D + 1))$ 。

由原始SSA的复杂度可知,tSSA仅添加了自适应t分布策略,计算复杂度为 $O(T \times N)$ 。因此,tSSA总的时间复杂度为 $O(N \times (T \times (D + 1) + 1))$ 。

由以上分析可知,在原始麻雀搜索算法中引入自适应t分布策略后并没有增加额外的计算阶数,与原始SSA的时间复杂度属于同一量级。

2 基于改进麻雀算法优化LSTM的故障诊断模型

2.1 LSTM神经网络原理

LSTM网络是Graves设计的一种目前常用的使用特殊方式把循环神经网络改良的神经网络,具备处理长时间储存信息的功能,可以有效克服普通循环神经网络(RNN)存在的信息过度依赖、易梯度消失和爆炸等问题。

LSTM的优势在于其对信息的长期过度依赖具备很强的建模和分析能力。目前,比较常见的LSTM结构如图1所示。LSTM中使用了一种新的存储单元 C_t ,类似于一条传输带,可以用线性循环的方式传输信息,同时将信息输出(以非线性方式)到隐藏层 h_t 的外部状态。信息的传输路径主要经过输入门 i_t 、遗忘门 f_t 和输出门 o_t 控制。遗忘门的作用是帮助确定需要忘记的所有信息,同时辨别隐含层在上一时刻的状态 h_{t-1} ,然后查看当前时刻的输入 x_t ,读取完成后输出结果,最后再为 C_{t-1} 赋值,这个结果的输出数值保持在0~1之间,两个端点分别表示信息的全数抛弃和信息的全数保留,具体算法如下:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (6)$$

式中, f_t 为遗忘门的输出值, σ 为Sigmoid函数, W_f 为遗忘门的权重矩阵, b_f 为遗忘门的偏置项。




图1 LSTM网络单元结构图

Fig. 1 LSTM network unit structure diagram

输入门的作用是指定新的信息保存到存储单元中。输入门由两部分构成,一部分是根据Sigmoid函数来计算输入值,另一部分是添加新的候选值向量。新的候选值向量遵循tanh层的规则重新计算得来,具体计算方法如下:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (7)$$

式中, W_i 、 b_i 分别为输入门的权重和偏置项。对存储单元的新贡献见式(8):

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (8)$$

式中, W_c 、 b_c 分别为单元状态的权重和偏置项。输入门会刷新存储单元状态,将 C_{t-1} 更新为 C_t 。为限制前面的记忆对后面的影响,将前一刻的记忆 C_{t-1} 与遗忘门输出 f_t 做乘积运算,然后再将其与 $i_t \cdot \tilde{C}_t$ 相加:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (9)$$

输出门主要基于存储单元当前时刻的状态经由滤波器进行过滤后输出。首先,利用Sigmoid函数计算出存储单元状态中将要输出的值;然后,利用tanh函数计算存储单元状态中将要输出的值;最后,把两个计算结果相乘,得到最终要输出的值。具体计算方法为:

$$\boldsymbol{O}_t = \sigma(\boldsymbol{W}_o \cdot [\boldsymbol{h}_{t-1}, \boldsymbol{x}_t] + \boldsymbol{b}_o)$$

(10)

$$\boldsymbol{h}_t = \boldsymbol{O}_t \cdot \tanh \boldsymbol{C}_t$$

(11)

式中, $\boldsymbol{W}_o$ 、 $\boldsymbol{b}_o$ 为输出门的权重和偏置项。

2.2 tSSA-LSTM模型

Greff等^[23]探索了LSTM相关超参数的设置。实验

结果表明,学习率是LSTM最关键的超参数,其次是网络规模,而动量梯度对最终结果影响不大。为了使LSTM结构与滚动轴承的数据特征相匹配,构建了tSSA-LSTM故障诊断模型,隐含层神经元的数量、周期次数、学习率和批量大小值这些超参数作为tSSA优化算法的优化对象。tSSA-LSTM流程如图2所示。




图 2 tSSA-LSTM滚动轴承故障诊断流程

Fig. 2 tSSA-LSTM rolling bearing fault diagnosis flow chart

tSSA-LSTM模型的具体建模步骤如下:

- 1) 数据处理,明确tSSA-LSTM故障诊断模型的输入和输出。在滚动轴承运行振动数据中提取特征参数作为模型的输入,把滚动轴承的故障类别作为输出。不同输入数据的维数不同,数值的差异可能很大,会影响模型的训练速度。因此,有必要对采集的数据样本进行归一化,本文中,首先使用数据归一化函数mapminmax将数据映射到[-1, 1]。然后,将归一化的实验数据分为训练集和测试集。
- 2) 设置tSSA算法相应的参数:种群个数*N*、发现者比例*P_D*、警戒者比例*S_D*、预警值*R₂*、总迭代次数*T*;根据初始化函数得到初始麻雀种群;构造LSTM故障

- 诊断模型,确定待优化超参数的取值范围。
- 3) 利用tSSA算法优化LSTM超参数。把实验样本输入到故障诊断模型中进行分类训练,把LSTM对训练集和测试集的分类错误率作为优化过程中的适应度函数值*S_{fitness}*,如式(12)所示。最终,经过*T*次迭代后获得最优的LSTM超参数。
- $$S_{\text{fitness}} = e_{\text{train}} + e_{\text{test}} \tag{12}$$
- 式中, *e_{train}*、*e_{test}*分别为模型在训练集和测试集上的分类错误率。
- 4) 使用优化后的模型进行故障诊断。样本的标签为滚动轴承的故障类型,通过对比模型预测输出结果与期望输出结果判断模型的适应性与有效性。

3 基于tSSA-LSTM的滚动轴承故障诊断分析

3.1 实验数据分析及故障特征提取

所使用的实验数据均来自美国凯斯西储大学滚动轴承数据中心^[24], 实验目的是测试tSSA算法优化LSTM的故障诊断模型的性能。

轴承故障类型可分为3种, 包括滚动体故障、内圈故障和外圈故障; 每一种故障主要有4种故障尺寸: 1.788、3.556、5.364、7.142 cm。实验数据主要为12 kHz采样频率、0负载下的正常状态驱动端数据, 以及故障直径分别为1.788和3.556 cm的内圈故障、外圈故障和滚动体故障状态驱动端数据, 共有7种不同的状态, 因此, 可分为7个不同的类别标签, 即每种状态分别对应一个标签, 详细的轴承故障数据见表1。其中, 不同轴承状态各取100组数据(共700个样本), 每个样本中包含1 024个数据点。从这700个样本中随机选取

560个当作训练样本, 余下的140个作为测试样本。

表 1 轴承故障数据

Tab. 1 Bearing fault data

轴承状态	类别标签	损伤直径/cm
正常状态(N)	1	0
外圈故障 (IR)	2	1.778
	3	3.556
内圈故障 (OR)	4	1.778
	5	3.556
滚动体故障 (B)	6	1.778
	7	3.556

图3为故障原始振动信号图。由图3可知, 不同的滚动轴承故障之间有一定的差别, 但仅凭原始振动信号判断轴承的故障种类远远不够。因此, 为了提升轴承故障诊断效率, 需要提取出更深层次的特征信息。




图 3 不同故障直径的原始振动信号

Fig. 3 Raw vibration signals of different fault diameters

利用时域特性参数可以对滚动轴承是否存在故障进行判定。然而, 当滚动轴承真的发生故障, 要准确地判断出故障的详细信息, 如类别、部位和严重程度等, 就必须对滚动轴承的频率特性进行分析。因此综合选取了时域和频域混合参数作为故障特征参数用于滚动轴承故障诊断, 特征参数表达式如附录A所示。

选取的特征参数共24个。其中: $P_1 \sim P_{11}$ 为时域特征参数, P_1 和 $P_3 \sim P_5$ 表示时域振动幅值和能量大小, P_2 和 $P_6 \sim P_{11}$ 表示时域信号的时间序列分布情况; $P_{12} \sim P_{24}$ 为频域特征参数, P_{12} 表示频域振动能量的大小, $P_{13} \sim P_{15}$ 、 P_{17} 及 $P_{21} \sim P_{24}$ 表示频谱的分散或集中程度, P_{16} 和 $P_{18} \sim P_{20}$ 表示主频带位置的变化^[25]。

通常情况下, 不相关特征可能会降低故障诊断

的性能。因此,需要把故障特征中的有用信息提取出来,与此同时,对无用的和含噪声的信息进行剔除。本文采用 KPCA方法对高维特征进行非线性降维,提高了模型的准确率。

经过KPCA方法分解后,各主成分的累计贡献率见表2。输入特征过多会导致过多的计算时间,反之会使故障诊断效率下降。因此,需要进行合理的降维,本文选取贡献率在85%以上的主元个数,据表2可选择前16个维度。

表 2 主成分贡献率

Tab. 2 Principal component contribution rates

维度编号	累计贡献率	维度编号	累计贡献率
1	0.138 4	13	0.807 0
2	0.262 1	14	0.828 9
3	0.376 7	15	0.850 3
4	0.484 1	16	0.870 6
5	0.535 2	17	0.890 4
6	0.579 5	18	0.907 6
7	0.622 0	19	0.924 6
8	0.663 3	20	0.941 0
9	0.702 6	21	0.956 8
10	0.730 8	22	0.972 2
11	0.757 3	23	0.986 8
12	0.782 6	24	1.000 0

3.2 算法寻优比较

本文以诊断分类错误率为适应度函数,输入特征均为经过KPCA方法降维之后的特征。分别用tSSA、SSA、PSO、遗传算法(GA)对LSTM超参数进行优化,对得到的寻优结果进行对比。不同优化算法可以得到不同的超参数组合。LSTM中原始隐含层神经元个数为100,周期次数为100,学习率为0.01,批量大小值为27。待优化超参数:隐含层神经元个数 L , $L \in [50, 200]$;周期次数 e , $e \in [100, 150]$;学习率 L_r , $L_r \in [0.000\ 1, 0.300\ 0]$;批量大小值 b , $b \in [10, 200]$ 。经过算法优化之后的超参数取值见表3。图4为各算法模型(tSSA-LSTM、SSA-LSTM、GA-LSTM、PSO-LSTM)的寻优迭代曲线。

表 3 超参数优化结果

Tab. 3 Hyperparameter optimization results

模型	隐含层神经元数量	周期次数	学习率	批量大小值
tSSA-LSTM	137	121	0.175 8	127
SSA-LSTM	118	133	0.099 3	136
GA-LSTM	141	148	0.147 2	107
PSO-LSTM	132	108	0.145 9	37




图 4 4种优化算法寻优迭代曲线

Fig. 4 Iterative curves of four optimization algorithms

由图4可见:与 PSO 与 GA这两个优化算法相比,SSA 和 tSSA 拥有良好的寻优能力;GA 算法在优化过程中不容易跳过局部最优;PSO因为自身对离散的优化问题处理不佳而不易得到较好的诊断准确率;tSSA算法加入了自适应t分布可以增大种群多样性,提高样本的分类准确率。根据以上分析可知,用tSSA优化LSTM超参数从而建立滚动轴承故障诊断模型具有高可行性。

3.3 测试样本诊断结果分析

实验1 诊断精度测试

将tSSA算法优化后的最优参数输入到LSTM中用测试样本进行实验,将预测轴承状态与实际轴承状态对比,验证其诊断准确性。表4为PSO-LSTM、GA-LSTM、SSA-LSTM、tSSA-LSTM和LSTM 5种算法模型对滚动轴承进行故障诊断的结果对比,结果均为10次实验结果的平均值。图5为以上5种算法模型最优结果的预测输出与期望输出对比。

表 4 5种算法模型诊断效果对比

Tab. 4 Comparison of diagnostic effects of five algorithm models

分类算法	平均诊断准确率/%	最高诊断准确率/%
PSO-LSTM	96.36	97.14
GA-LSTM	97.29	98.57
SSA-LSTM	97.00	98.57
tSSA-LSTM	98.86	99.29
LSTM	95.22	95.71

对比表4和图5中结果可知,tSSA-LSTM 的分类结果较好,最优分类准确率可达到99.29%,且平均分类准确率也达到了98.86%,相比于PSO-LSTM、GA-LSTM、SSA-LSTM及LSTM算法模型,其准确率都有所提高。

实验2 泛化性能测试

泛化性能在故障诊断中的含义是通过训练数据集训练得到的故障诊断模型对于未知数据的预测能力,是诊断方法的本质特性^[26]。如果一个模型经过训练数据训练之后,不能很好地拟合训练数据以外的数据,那么就出现过拟合现象。如果模型在训练集

上表现不好,而在测试集表现一般或更好,这可能是欠拟合导致。因此,要评价经过特定数据集训练之后的算法模型的泛化性能好坏,可以对每一种算法模型进行5折交叉验证,表5为每种算法模型的平均识

别率结果。从表5中可以看出,tSSA-LSTM模型的平均诊断精度结果最好,可以达到98.57%,其诊断准确率较原始LSTM模型有较大的提高,有着较好的泛化性能,证明了本文所用优化算法的可行性。




图 5 不同算法模型最优诊断结果

Fig. 5 Optimal diagnosis results of different algorithm models

表 5 5种算法模型交叉验证诊断结果

Tab. 5 Diagnostic results of cross-validation of five algorithm models

类别标签	PSO-LSTM		GA-LSTM		SSA-LSTM		tSSA-LSTM		LSTM	
	正确样本数	测试准确率/%	正确样本数	测试准确率/%	正确样本数	测试准确率/%	正确样本数	测试准确率/%	正确样本数	测试准确率/%
1	104	100.00	103	100.00	105	97.22	105	98.13	115	98.29
2	113	100.00	109	100.00	103	100.00	101	100.00	85	100.00
3	98	86.96	86	88.23	90	95.74	89	92.71	98	83.05
4	95	100.00	100	100.00	93	98.94	93	100.00	106	98.15
5	101	94.44	107	100.00	92	95.83	100	100.00	85	96.59
6	100	100.00	88	100.00	88	100.00	103	100.00	90	100.00
7	68	100.00	93	100.00	117	100.00	99	99.00	94	96.81
总样本	679	97.00	686	98.00	688	98.28	690	98.57	670	95.71

3.4 噪声环境下故障诊断性能分析

3.4.1 噪声问题描述

在实际的滚动轴承故障诊断中,由于传感器测出的轴承信号存在一定的噪声,所以有必要对模型进行抗干扰能力分析。实验中,训练数据是原始数据

(没有噪声存在),测试数据是含噪声的数据(在原始数据中添加不同信噪比的高斯白噪声),用以模拟振动信号存在噪声的实际工作环境。信噪比(SNR)是用于评估一个信号中所包含噪声强度的重要指标,记为 S_{SNR} ,其公式如下所示:

$$S_{\text{SNR}} = 10 \cdot \lg(P_{\text{signal}}/P_{\text{noise}}) \tag{13}$$

式中, P_{signal} 为信号功率, P_{noise} 为噪声功率。 S_{SNR} 设置为-2~18 dB, 信噪比越小, 噪声功率越大。在原始信号加入噪声后, 噪声会覆盖原始信号的特征。图6为原始信号及含信噪比为-2的信号。从图6中可以看出, 原始信号加噪声之后就不能根据其故障特征频率判断其是否为原始信号所属的故障类别。




图 6 原始信号及含信噪比为-2的信号

Fig. 6 Original signal and the signal with a signal-to-noise ratio of -2

3.4.2 噪声环境下故障诊断实验

在抗噪实验中, 选择上述的700个样本来进行实验, 不同算法模型在含不同信噪比的噪声环境下的诊断结果见表6。

表 6 4种算法模型在不同信噪比下的识别准确率

Tab. 6 Recognition accuracy of four algorithm models under different signal-to-noise ratios

算法模型	S_{SNR}					
	-2	2	6	10	14	18
tSSA-LSTM	72.14	79.29	87.86	89.29	95.00	97.86
SSA-LSTM	67.86	70.00	83.57	86.43	94.29	97.14
GA-LSTM	58.57	68.57	80.71	82.86	93.57	95.71
PSO-LSTM	56.43	65.00	77.14	82.14	90.00	94.29

分析可知: 噪声环境下tSSA-LSTM的识别准确率要明显高于SSA-LSTM、GA-LSTM以及PSO-LSTM; 在信噪比低于6的环境下, 这4种模型的识别准确率都有明显下降; 在信噪比为18时, SSA-LSTM、GA-LSTM以及PSO-LSTM的准确率分别为97.14%、95.71%和94.29%, 而tSSA-LSTM的识别准确率提升到了97.86%。因此, tSSA-LSTM的抗噪性相比其他模型更好。

4 结 论

针对滚动轴承故障诊断研究, 本文在可行性的

基础上提出一种新的滚动轴承故障诊断方法——改进麻雀搜索算法优化LSTM神经网络的故障诊断模型。通过采用自适应t分布策略, 改善原始麻雀搜索算法后期种群多样性不足导致不能跳出局部最优的缺点, 进而利用tSSA优化LSTM超参数并建立tSSA-LSTM故障诊断模型, 在凯斯西储大学的滚动轴承数据集上进行对比仿真实验, 分析证明: 与PSO-LSTM、GA-LSTM以及SSA-LSTM相比, tSSA-LSTM故障诊断精度更高, 泛化能力更强, 且在噪声环境下依然拥有良好的故障诊断性能, 可以对滚动轴承故障进行初步判定, 提升了诊断效率。本文所提方法对一些不同领域的故障诊断也有借鉴意义。

附录见本刊网络版, 扫描标题旁的二维码可阅读网络全文。

参考文献:

[1] Zhong Jianhua, Wong P K, Yang Zhixin. Fault diagnosis of rotating machinery based on multiple probabilistic classifiers[J]. *Mechanical Systems and Signal Processing*, 2018, 108: 99-114.

[2] Xia Min, Li Teng, Xu Lin, et al. Fault diagnosis for rotating machinery using multiple sensors and convolutional neural networks[J]. *IEEE/ASME Transactions on Mechatronics*, 2018, 23(1): 101-110.

[3] Guo Lei. Research on fault diagnosis of rolling bearings based on the fusion of SDAE and LSTM[D]. Shenyang: Shenyang Jianzhu University, 2020. [郭磊. 基于SDAE和LSTM融合的滚动轴承故障诊断研究[D]. 沈阳: 沈阳建筑大学, 2020.]

[4] He Zhijing. Research on fault diagnosis method of rolling bearings based on feature selection and optimization LSSVM[D]. Taiyuan: Taiyuan University of Science and Technology, 2021. [贺之靖. 基于特征选择与优化LSSVM的滚动轴承故障诊断方法研究[D]. 太原: 太原科技大学, 2021.]

[5] Kumar A, Kumar R. Role of signal processing, modeling and decision making in the diagnosis of rolling element bearing defect: A review[J]. *Journal of Nondestructive Evaluation*, 2018, 38(1): 5.

[6] Chen Jian, Cai Kunqi, Tao Shanyong, et al. Fault diagnosis method of rolling bearing based on IITD fuzzy entropy and random forest[J]. *Acta Metrologica Sinica*, 2021, 42(6): 774-779. [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.]

[7] Xu Zhuofei, Liu Kai, Zhang Haiyan, et al. A fault diagnosis method for rolling bearings based on empirical mode decomposition and principal component analysis[J]. *Journal of*

- Vibration and Shock*,2014,33(23):133–139.[徐卓飞,刘凯,张海燕,等.基于经验模式分解和主元分析的滚动轴承故障诊断方法研究[J].*振动与冲击*,2014,33(23):133–139.]
- [8] Zheng Xiaoxia,Jiang Haisheng,Liu Jing,et al.Fault diagnosis for rolling bearings based on variational mode decomposition and GWO-ELM[J].*Bearing*,2021(9):48–53.[郑小霞,蒋海生,刘静,等.基于变分模态分解与灰狼算法优化极限学习机的滚动轴承故障诊断[J].*轴承*,2021(9):48–53.]
- [9] Deng Wu,Yao Rui,Zhao Huimin,et al.A novel intelligent diagnosis method using optimal LS-SVM with improved PSO algorithm[J].*Soft Computing*,2019,23(7):2445–2462.
- [10] Li Siyu,Huang Shaoluo,Zhang Yangyang,et al.Deep learning in fault diagnosis of complex mechanical equipment[J].*International Journal of Performability Engineering*,2020,16(10):1548–1555.
- [11] Hoang D T,Kang H J.A survey on Deep Learning based bearing fault diagnosis[J].*Neurocomputing*,2019,335:327–335.
- [12] Qu Zhongdi,Haghani P,Weinstein E,et al.Syllable-based acoustic modeling with CTC-SMBR-LSTM[C]//*Proceedings of the 2017 IEEE Automatic Speech Recognition and Understanding Workshop(ASRU)*.Okinawa: IEEE,2017:173–177.
- [13] Althché F,de La Fortelle A.An LSTM network for highway trajectory prediction[C]//*Proceedings of the 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*.Yokohama:IEEE,2017:353–359.
- [14] Palangi H,Deng Li,Shen Yelong,et al.Deep sentence embedding using long short-term memory networks:Analysis and application to information retrieval[J].*IEEE/ACM Transactions on Audio,Speech,and Language Processing*,2016,24(4):694–707.
- [15] Wu Pengcheng,Luo Liang.Prediction of ship motion trajectory based on RNN-LSTM[J].*Shipbuilding Technology*,2021,49(3):11–16.[吴鹏程,罗亮.基于RNN-LSTM的船舶运动轨迹预测[J].*造船技术*,2021,49(3):11–16.]
- [16] Du Xiaolei,Chen Zhigang,Xu Xu,et al.Fault diagnosis of bearing based on wavelet convolutional auto-encoder and LSTM network[J].*Journal of Mechanical & Electrical Engineering*,2019,36(7):663–668.[杜小磊,陈志刚,许旭,等.基于小波卷积自编码器和LSTM网络的轴承故障诊断研究[J].*机电工程*,2019,36(7):663–668.]
- [17] Zhao Jianpeng,Zhou Jun.State prognosis of rotary machines based on long/short term memory recurrent neural network[J].*Noise and Vibration Control*,2017,37(4):155–159.[赵建鹏,周俊.基于长短时记忆网络的旋转机械状态预测研究[J].*噪声与振动控制*,2017,37(4):155–159.]
- [18] Zheng Zhi,Zhang Huaqin,Pan Yue.Rolling bearing fault diagnosis based on IWOA-LSTM[J].*Journal of Vibration and Shock*,2021,40(7):274–280.[郑直,张华钦,潘月.基于改进鲸鱼算法优化LSTM的滚动轴承故障诊断[J].*振动与冲击*,2021,40(7):274–280.]
- [19] Sun Yigang,Liu Kaijie.Failure rate of avionics system forecasting based on PSO-LSTM network[J].*Aeronautical Science & Technology*,2021,32(5):17–22.[孙毅刚,刘凯捷.基于PSO-LSTM网络的航电系统故障率预测研究[J].*航空科学技术*,2021,32(5):17–22.]
- [20] Shi Huaitao,Shang Yajun,Bai Xiaotian,et al.Early fault prediction method combining SWDAE and LSTM for rolling bearings based on Bayesian optimization[J].*Journal of Vibration and Shock*,2021,40(18):286–297.[石怀涛,尚亚俊,白晓天,等.基于贝叶斯优化的SWDAE-LSTM滚动轴承早期故障预测方法研究[J].*振动与冲击*,2021,40(18):286–297.]
- [21] Xue Jiankai,Shen Bo.A novel swarm intelligence optimization approach:Sparrow search algorithm[J].*Systems Science & Control Engineering*,2020,8:22–34.
- [22] Lv Xin,Mu Xiaodong,Zhang Jun,et al.Chaos sparrow search optimization algorithm[J].*Journal of Beijing University of Aeronautics and Astronautics*,2021,47(8):1712–1720.[吕鑫,慕晓冬,张钧,等.混沌麻雀搜索优化算法[J].*北京航空航天大学学报*,2021,47(8):1712–1720.]
- [23] Greff K,Srivastava R K,Koutnik J,et al.LSTM:A search space odyssey[J].*IEEE Transactions on Neural Networks and Learning Systems*,2017,28(10):2222–2232.
- [24] Case Western Reserve University Bearing Data Center[EB/OL].[2022–08–17].http://csegroups.case.edu/bearing_data_center/pages/download-data-file.
- [25] Lei Yaguo,He Zhengjia,Zi Yanyang.Fault diagnosis based on novel hybrid intelligent model[J].*Journal of Mechanical Engineering*,2008,44(7):112–117.[雷亚国,何正嘉,訾艳阳.基于混合智能新模型的故障诊断[J].*机械工程学报*,2008,44(7):112–117.]
- [26] 周志华.机器学习[M].北京:清华大学出版社,2016.

Fault Diagnosis of Rolling Bearing Based on Improved Sparrow Search Algorithm Optimized LSTM

ZHOU Yu, FANG Qian, PEI Zexuan, BAI Lei

(School of Electrical Eng., North China Univ. of Water Resources and Electric Power, Zhengzhou 450045, China)

Abstract: In order to precisely diagnose the operational status and fault categories of rolling bearings, this paper employs a long short-term memory (LSTM) neural network as a classifier to categorize and diagnose the rolling bearing dataset. Initially, time-domain and frequency-domain characteristic parameters are derived from the raw vibration signals of rolling bearings, creating a dataset with high-dimensional characteristic parameters. The Kernel Principal Component Analysis method is utilized to reduce the dimensionality of the high-dimensional characteristic set. The features with a high degree of significance are then selected to compose the input characteristic vector. Addressing the challenge of determining hyperparameters for the LSTM neural network in rolling bearing fault diagnosis research, a fault diagnosis model (tSSA-LSTM) is proposed based on the adaptive t-distribution sparrow search algorithm (tSSA) to optimize the LSTM neural network. Finally, several simulation experiments, including fault diagnosis accuracy tests, generalization performance tests, and fault diagnosis performance tests in noisy environments, are conducted using data from the Rolling Bearings Data Center at Case Western Reserve University. The proposed diagnostic model is experimentally compared with SSA-LSTM, GA-LSTM, PSO-LSTM, and traditional LSTM diagnostic models. The experimental results demonstrate that tSSA can more effectively optimize the hyperparameters of LSTM, such as the number of neurons in the hidden layer, the number of cycles, and the learning rate. The proposed method achieves an average diagnostic accuracy of 98.86% and a cross-validation result of 98.57%. Furthermore, the fault diagnosis accuracy of the proposed method under noisy interference surpasses that of the compared methods. Consequently, the tSSA-LSTM model not only accurately diagnoses the state of rolling bearing faults but also exhibits stronger generalization and anti-interference capabilities, effectively enhancing the performance of rolling bearing fault diagnosis.

Key words: sparrow search algorithm; fault diagnosis; long short-term memory neural network; feature extraction; rolling bearing

(编辑 吴芝明)

引用格式: Zhou Yu,Fang Qian,Pei Zexuan,et al.Fault diagnosis of rolling bearing based on improved sparrow search algorithm optimized LSTM[J].Advanced Engineering Sciences,2024,56(2):289-298.[周玉,房倩,裴泽宣,等.基于改进麻雀搜索算法优化LSTM的滚动轴承故障诊断[J].工程科学与技术,2024,56(2):289-298.]