

DOI: 10.13382/j.jemi.B2306217

集成自适应变异混沌松鼠搜索和 LSTM 算法的 RUL 预测方法及应用*

何 静 高 见 张昌凡
(湖南工业大学电气与信息工程学院 株洲 412007)

摘 要:针对松鼠搜索算法(SSA)优化长短期记忆人工神经网络(LSTM)时,存在优化参数易陷入局部最优以及 LSTM 预测效率下降的问题,提出一种自适应变异混沌松鼠搜索算法(AMCSSA)优化 LSTM 学习率及其下降因子的预测模型。通过计算 AMCSSA 的时间复杂度证明其在未增加算法复杂度的前提下提高寻优效率,AMCSSA 采用切比雪夫混沌映射生成混沌初始种群,并将捕食者概率改为非线性递减模式,利用位置贪婪选择策略使其在算法迭代过程中不断更新并保留更优个体,引入自适应 T 变异策略提高 SSA 在搜索空间中的勘探能力。通过 AMCSSA 对 LSTM 的学习率及其下降因子进行参数寻优,进一步提高 LSTM 的预测能力。对滚动轴承的剩余使用寿命(RUL)进行实验验证,结果表明所提方法相较于传统 SSA、粒子群算法(PSO)、蝙蝠算法(BAT)以及萤火虫算法(FA)优化 LSTM 后,在预测中的精度分别提高了 1.05%、7.61%、8.4%以及 7.73%,并且使优化后的 LSTM 在完成收敛所需要的迭代次数减少,从而提高预测效率。

关键词: 松鼠搜索算法;长短期记忆人工神经网络;切比雪夫混沌映射;自适应 T 变异;时间复杂度;剩余使用寿命

中图分类号: TH133.33;TN06 **文献标识码:** A **国家标准学科分类代码:** 460.25;510.4

Prediction of RUL and application of the integrated squirrel search algorithm with adaptive mutation chaos for LSTM

He Jing Gao Jian Zhang Changfan
(College of Electrical and Information Engineering, Hunan University of Technology, Zhuzhou 412007, China)

Abstract: A squirrel search algorithm with adaptive mutation chaos (AMCSSA) is proposed in this paper to improve the learning rate of LSTM and the prediction pattern of its decay factor. This is to solve issues of the tendency of local optimal for optimized parameters and the decay of LSTM prediction efficiency during the optimization of LSTM with SSA. By calculating its time complexity, AMCSSA is proved to be able to increase the searching efficiency without increasing the complexity of the algorithm. AMCSSA adopts Chebyshev chaotic map to generate the chaotic initial population, and switches to use a nonlinear decreasing for the predator probability. The positional greedy selection strategy is used to continuously update and keep individuals of more advantages during the iteration of algorithms, then the adaptive T mutant is introduced to improve SSA's exploration capabilities in searching space. AMCSSA optimizes the parameters for the learning rate of LSTM and their decay factors, thus the predictive ability of LSTM is further improved. This is verified by experiments on the remaining useful life of rolling bearing. The results show that the prediction accuracy of LSTM optimized by AMCSSA increased by 1.05%, 7.61%, 8.4%, and 7.73%, respectively, compared to those optimized by traditional SSA, particle swarm optimization (PSO), bat algorithm (BAT), and firefly algorithm (FA). With the proposed algorithm, the number of iteration required for the optimized LSTM to complete the convergence is also reduced, so that the prediction efficiency is increased.

Keywords: squirrel search algorithm; long short-term memory; Chebyshev chaotic map; adaptive T mutation; time complexity; remaining useful life

0 引言

目前,各类旋转机械中都有着滚动轴承的身影,对滚动轴承的故障发生进行预测能够保证机械设备的可靠运行^[1]。剩余使用寿命(remaining useful life, RUL)作为故障预测的重要一环,对滚动轴承的剩余使用寿命进行预测能够提高工业生产中机械设备的工作效率以及运行的安全性,因此研究人员对轴承的剩余使用寿命预测愈发关注,使其不断发展^[2-4]。

长短期记忆人工神经网络(long short-term memory, LSTM)由于在时间序列数据建模有着很强大的优势,使其在预测机械零部件的 RUL 中越来越受到重视。Yang 等^[5]建立了一种基于不确定性量化的 LSTM 模型来预测轴承的 RUL。Zhu 等^[6]建立了一种基于 AdaBoost 回归模型和 LSTM 结合的 RUL 预测方法。

但是由于 LSTM 的超参数众多,且参数的选择对于 LSTM 模型的预测精度有着非常显著的影响,如果人工对 LSTM 进行超参数的调试会加大人力的需求,同时浪费作业时间,因此 Hu 等^[7]采用一种改进的粒子群算法(improved particle swarm optimization algorithm, IPSO)对 LSTM 模型参数进行优化。Raghavendra Kumar 等提出了一种结合人工蜂群算法(artificial bee colony algorithm, ABC)和 LSTM 的预测模型^[8]。Lv 等^[9]提出了通过 lightgbm 优化 LSTM 的时间序列模型。

无论是何种优化算法的加入,必然会使得原模型的预测效率下降,如何能够在预测精度变化不大的前提下对预测效率的提高是提升工业生产效率的重要手段。为了提高在优化算法加入模型后的效率,需要从优化算法的内部结构进行调整,使得优化算法能够更好更高效地对原模型进行参数寻优。郁书好等^[10]通过引入切比雪夫映射策略改进萤火虫优化算法(glowworm swarm optimization, GSO),提高了 GSO 的求解精度与全局搜索能力。高晨峰等^[11]提出了一种融合黄金正弦和曲线自适应的多策略麻雀搜索算法,有效地提高了算法的收敛速度与收敛精度。Zhang 等^[12]通过引入入侵杂草算法(invasive weed optimization, IWO)的繁殖行为以及自适应步长策略来提高松鼠搜索算法(squirrel search algorithm, SSA)的探索与开发能力。Wang 等^[13]通过引入跳跃搜索方法和渐进搜索方法以及线性回归选择策略来提高 SSA 的探索能力以及鲁棒性。Zheng 等^[14]在 SSA 中引入自适应捕食者概率策略、标准云模型、连续位置间的选择策略以及维度搜索增强策略 4 种改进方法,效果较好。Luo 等^[15]将 PSO 的社会性部分引入 SSA 中,同时增加了新的位置更新条件以及自适应的最小季节常数策略,提高了 SSA 的平均收敛值与收敛速度。

本文对 LSTM 的学习率以及学习率下降因子进行优化时所采用的优化算法为 SSA,虽然标准的 SSA 被不同领域所应用,但是仍然有着以下几个问题:在种群初始化过程中,由于种群的生成位置是随机分布的,这将会导致搜索空间没有被充分利用并充分搜寻有效信息;在搜寻过程中由于捕食者策略 P_{dp} 是一个固定的常数值,而搜寻过程是包括局部搜寻和全局搜寻两个方向,这使得局部搜寻与全局搜寻无法很好地进行平衡,导致某一方面过于优势,使得算法容易陷入局部最优;在 SSA 每一次迭代的过程中松鼠的位置存在不确定性,这将会导致前一次迭代所生成的松鼠位置要比后一次迭代所生成的松鼠位置更好,使得位置较好的优势个体没有被保留下来,SSA 的寻优速度也会因此减慢;在迭代后期,由于松鼠个体的同化现象,导致种群多样化的特性下降,使得算法更加容易陷入局部最优。

针对上述问题,本文提出了一种基于切比雪夫混沌映射、非线性递减的捕食者概率、位置贪婪选择以及自适应 T 分布策略的松鼠搜索算法优化 LSTM 的滚动轴承 RUL 预测模型。本文的贡献为:

1) 为了使标准 SSA 种群均匀分布、提高其在全局与局部最优之间的平衡能力、在迭代过程保留更优个体以及在迭代过程中的收敛性与种群多样性,分别引入切比雪夫混沌映射、非线性递减的捕食者概率、位置贪婪选择以及自适应 T 分布策略来改进标准的 SSA,提高 SSA 的寻优效率。

2) 通过改进的 SSA(AMCSSA)对 LSTM 的学习率及其下降因子进行寻优,提高模型的预测精度,并计算 AMCSSA 的时间复杂度,确保其没有增加算法复杂度。通过对滚动轴承 RUL 进行预测,证明模型的有效性。

1 基于集成算法的 RUL 预测

本文所提出的基于 AMCSSA-LSTM 的滚动轴承 RUL 预测技术框架如图 1 所示。首先通过切比雪夫混沌映射、非线性递减的捕食者概率、位置贪婪选择以及自适应 T 分布策略对 SSA 进行改进,然后利用改进后的 SSA,即 AMCSSA 对 LSTM 的学习率及其下降因子进行参数寻优,最后,在辛辛那提大学的 IMS 轴承数据集上验证该方法的有效性。在本节中,以上 4 种改进策略将具体描述。

1.1 数据预处理

通过构建合适的健康指标(health indicator, HI),能够解决滚动轴承原始振动信号无法清晰描绘退化趋势的问题。在时域特征中,峭度与均方根(root mean square, RMS)被广泛运用^[16]。由于峭度值对早期故障表现出较高的敏感性,且稳定性不好,在轴承的早期故障中所能反应的信息非常少,而均方根值对早期故障不敏感,稳定




图 1 集成算法技术框架

Fig. 1 Technical framework of the integrated algorithm

性很好^[16]。因此这里选择 RMS 作为健康指标。 y_{RMS} 如式(1)所示^[17]:

$$y_{RMS} = \sqrt{\frac{1}{T} \sum_{i=1}^T (x_i)^2} \quad (1)$$

式中: x_i 为初始数据; T 为 RMS 的计算周期; y_{RMS} 为 RMS 值。

1.2 松鼠搜索算法

学习率和学习率下降因子是 LSTM 的重要参数,学习率作为控制网络学习速率的超参数,若设置过小,模型的收敛速度会非常缓慢,若设置过大,引起的振荡则会使网络无法完全收敛。而学习率下降因子的作用就是让学习率不断衰减,从而减缓震荡。因此,学习率与学习率下降因子对 LSTM 预测结果有着决定性的影响。

SSA 属于群体智能算法的一种,通过模拟飞行松鼠的觅食行为来实现解的搜寻过程^[18]。相较于目前的群体智能算法,如粒子群优化算法、萤火虫优化算法等,由于引入了多种搜寻策略以及引入季节变化条件,松鼠搜索算法能够更精确的搜寻最优解以及更好地解决陷入局部最优的情况。具体过程为:

步骤 1) 用学习率与学习率下降因子作为松鼠位置,并根据式(2)进行随机初始化^[18]:

$$FS_{i,j} = FS_{i,L} + U(0,1) \times (FS_{i,U} - FS_{i,L}) \quad (2)$$

式中: $FS_{i,U}$ 、 $FS_{i,L}$ 为第 j 维的上、下界; $U(0,1)$ 为均匀分布在 0~1 之间的值。

步骤 2) 确定松鼠搜索算法的种群数目、最大迭代次数、滑行距离参数以及捕食者出现的概率。将决策变量的值放入自定义的适应度函数中,计算每只松鼠的位置适应度,每只松鼠的位置适应度描述了山核桃树和橡树的位置,即全局最优解和局部最优解的位置信息。

步骤 3) 使未找到食物源的松鼠分别向山核桃树和橡树靠近从而生成新的位置。引入季节变化条件,计算

其值,并与当前迭代下的最小季节常数对比。最小季节常数定义如下^[18]:

$$S_c^t = \sqrt{\sum_{z=1}^3 \sum_{k=1}^d (FS_{at,k}^{t,z} - FS_{ht,k})^2} \quad (3)$$

若 $S_c^t < S_{\min}$,则通过 Lévyflight 随机更新普通树上的松鼠位置。

$S_{\min}$ 定义如下^[18]:

$$S_{\min} = \frac{10E^{-6}}{(365)^{\frac{2.5r}{t_m}}} \quad (4)$$

步骤 4) 重复步骤 2)、3),迭代完成后,全局最优解为山核桃树上松鼠的位置,得到最优的学习率与学习率下降因子。

1.3 切比雪夫混沌映射

由于标准的 SSA 存在着种群多样性在搜索过程中下降过快,且初始种群分布不平衡的问题,混沌序列有着分布均匀,搜索的遍历性的特点,这些特点能够很好地解决上述问题。目前 logistic 映射、Tent 映射和切比雪夫映射等,是常用的混沌映射策略。切比雪夫混沌映射相较于 logistic 混沌映射,能够使种群分布更广、更均匀,相较于 Tent 混沌映射,不需要设置系统参数,初始值的设置影响较小,稳定性更强。

切比雪夫混沌映射的公式如式(5)所示^[11]:

$$Z_{k+1} = \cos(k \cos^{-1}(Z_k)) \quad Z_k \in [0,1] \quad (5)$$

式中: Z_i 为均匀分布的随机数。

1.4 非线性递减的捕食者概率

捕食者概率 P_{dp} 会影响松鼠更新位置的适应度值,使用非线性递减的 P_{dp} 能够使得算法的全局搜索和局部搜索得到平衡,这样能够使算法搜索前期与后期的搜索方式合理分配。如式(6)所示^[19]:

$$P_{dp} = (P_{\max} - P_{\min}) \times \left(1 - \frac{t}{t_{\max}}\right)^5 + P_{\min} \quad (6)$$

其中, $P_{\max}$ 和 $P_{\min}$ 分别是捕食者概率的最大值和最小值, 取值分别为 0.15 和 0.02。

1.5 位置贪婪选择

在松鼠更新位置时, 新旧位置的食物品质有着非常大的随机性, 可能新位置的食物品质更好, 也有可能旧位置的食物品质更好。位置贪婪选择策略的加入能够使松鼠的位置总在食物品质更好位置上。如式(7)所示^[19]:

$$FS_i^{t+1} = \begin{cases} FS_i^{new}, & f_i^{new} < f_i^{old} \\ FS_i^{old}, & f_i^{new} > f_i^{old} \end{cases} \quad (7)$$

1.6 自适应 T 分布变异

在 SSA 的搜索过程中, 松鼠的位置总会朝着最优的位置移动, 但是当松鼠达到最优的位置时将不会再变化, 剩下的松鼠就都会朝着最优位置的松鼠前进, 而最优位置附近可能还存在更优的位置, 为了充分利用所有有价值的信息, 需要使到达最优位置的松鼠再进行局部勘探, 使其能够找到更优的位置。因此本文对从橡树飞向山核桃树的松鼠个体位置采取自适应 T 分布变异策略, 如式(8)所示^[20]:

$$X_i^* = X_i + X_i \times t(M) \quad (8)$$

其中, X_i^* 为变异后的松鼠位置; X_i 为第 i 个松鼠个体的位置; $t(M)$ 是以 SSA 迭代次数为自由度的 T 分布。含有自由度参数 m 的概率密度函数为^[20]:

$$p(x) = \frac{\Gamma(\frac{m+1}{2})}{\sqrt{m\pi} \Gamma(\frac{m}{2})} (1 + \frac{x^2}{2})^{-\frac{m+1}{2}} \quad (9)$$

其中, $\Gamma(\frac{m+1}{2}) = \int_0^{+\infty} x^{\frac{m+1}{2}-1} e^{-x} dx$ 为第二型欧拉积分, m 的具体公式为^[20]:

$$t(m \rightarrow \infty) \rightarrow N(0, 1), t(m \rightarrow 1) = C(0, 1) \quad (10)$$

其中, $N(0, 1)$ 为高斯分布; $C(0, 1)$ 为柯西分布。

1.7 时间复杂度计算

时间复杂度能够很好的评价算法效率。SSA 与 AMCSSA 都可以分成两个阶段来计算时间复杂度: 种群初始化阶段与算法迭代阶段。

1) SSA 的时间复杂度计算

假设松鼠种群的总数为 z , 搜索空间的维度为 u , 迭代所需的总次数为 $t_{\max}$ 。

初始化阶段:

$$X_i = O(z \times u) \quad (11)$$

假设 z_1 为松鼠从橡树到山核桃树移动的总数, z_2, z_3 为松鼠从普通树到橡树移动的总数和从普通树到山核桃树移动的总数, 加入季节监测后的迭代次数为 t_1 。

迭代阶段:

$$X_2 = O[(z_1 + z_2 + z_3) \times t \times u + (z_2 + z_3) \times t_1 \times u] = O(n \times t \times u) \quad (12)$$

根据时间复杂度计算原则省略低阶项后:

$$X = O(z \times u) + O(z \times t \times u) = O(z \times t \times u) \quad (13)$$

2) AMCSSA 的时间复杂度计算

假设产生一个维度为 u 的随机数所需的时间为 ω_1 , 产生切比雪夫混沌映射初始松鼠种群的时间为 ω_2 。

初始化阶段:

$$X_3 = O(z \times (\omega_1 + \omega_2) u) = O(z \times u) \quad (14)$$

假设通过自适应 T 分布变异山核桃树上松鼠个体所需要的时间为 ω_3 , 通过非线性递减策略更新 P_{dp} 的时间为 ω_4 , 位置贪婪选择的时间为 ω_5 。

迭代阶段:

$$X_4 = O[(\omega_5 z \times \omega_4 t) \times u + (\omega_5(z_2 + z_3) \times \omega_4 t_1 \times u + (\omega_3 u \times \omega_4 t))] \quad (15)$$

根据时间复杂度计算原则省略低阶项后:

$$X_4 = O(z \times t \times u) \quad (16)$$

因此 AMCSSA 的时间复杂度为:

$$X' = O(z \times u) + O(z \times t \times u) = O(z \times t \times u) \quad (17)$$

通过计算分析可以得到, AMCSSA 与标准的 SSA 的时间复杂度一致, 因此以上 4 种改进策略的加入并没有让算法在时间上更加复杂。

1.8 RUL 预测

利用历史的全寿命周期数据对将来的寿命数据进行预测是 RUL 预测常见的方法^[21]。在确定预测起始点之后, 利用式(18)进行计算^[17]:

$$\widehat{RUL} = \varphi \times \Delta t \quad (18)$$

其中, φ 为预测起始点与失效阈值之间的距离, Δt 为一个 RMS 的采样周期。

1.9 集成算法建模流程

首先通过切比雪夫混沌映射策略对 SSA 进行种群初始化, 然后引入非线性递减的捕食者概率策略对 P_{dp} 进行改进, 随后引入位置贪婪选择策略对每一次生成的新的松鼠位置进行比较, 保留优势个体, 最后通过自适应 T 分布变异对最优松鼠个体进行优化选择。在计算加入 4 种改进策略的时间复杂度之后, 利用 AMCSSA 对 LSTM 的学习率及其下降因子进行寻优。在最后阶段, 可以根据 AMCSSA-LSTM 对滚动轴承的 RUL 进行预测。具体的流程如图 2 所示。

2 实验结果与分析

2.1 实验介绍

这里通过美国辛辛那提大学 IMS 轴承全寿命周期振




图 2 集成算法建模流程

Fig. 2 Modeling procedure of the integrated algorithm

动数据集进行分析验证,一共 3 个数据集^[22]。轴承的滚动体直径为 8.4 mm,角度为 15.171°,单节圆直径为 71.5 mm,滚动体数量为 16 个。滚动轴承具体信息如表 1 所示。

表 1 中,I 为内圈故障;B 为滚动体故障;O 为外圈故障。这里选择数据集 2 作为实验数据。

2.2 实验步骤

将数据集的原始轴承全寿命周期振动数据进行时域信号 RMS 提取,RMS 的采样周期为 10 min,采样个数为 984 个,即总采样时间为 9 840 min。如图 3 所示,图中故障轴承为 W5 号轴承,正常轴承为 W6 号轴承。图 3 反应出 RMS 值会随着轴承的故障趋势进行变化,可以观察出

表 1 轴承全寿命周期振动数据具体信息

Table 1 Specific information of bearing Life-Cycle vibration data

	数据集 1	数据集 2	数据集 3
通道数	8	4	4
采样次数	2 156	984	4 448
轴承编号	W1、W2、W3、W4	W5、W6、W7、W8	W9、W10、W11、W12
故障类型	W3-I、W4-B	W5-O	W11-O

在正常运作时期、早期故障时期、中期故障时期以及晚期故障时期中,RMS 的变化有着显著不同。预测起始点为 5 000 min,即第 500 个数据点,RMS 为 0.060 459 5,这里将轴承的失效阈值设定在第 500 个数据点的 RMS 值的 3 倍处左右,即第 9 640 min 处,此处为第 964 个数据点,RMS 值为 0.182 316。




图 3 滚动轴承振动数据 RMS 曲线

Fig. 3 RMS curve chart of rolling bearing vibration data

第 1 步将切比雪夫混沌映射策略、非线性捕食者概率率递减策略、位置贪婪选择策略以及自适应 T 分布变异策略导入 SSA 中,并计算时间复杂度,确保模型的时间复杂度不变。

第 2 步设置好优化算法迭代次数、优化算法种群数目、优化参数数量、优化参数上界、优化参数下界以及 LSTM 迭代次数、学习率下降周期和隐含单元数目。AMCSSA-LSTM 所设置的各项参数,如表 2 所示。

第 3 步输入预处理之后的轴承 RMS 数据,通过 AMCSSA-LSTM 对其进行预测。

2.3 实验结果分析

1) 对比实验

对比实验具体采用以下 4 种模型:PSO(粒子群优化算法)-LSTM、BAT(蝙蝠优化算法)-LSTM、SSA(标准松鼠搜索算法)-LSTM、FA(萤火虫优化算法)-LSTM。

以上内容均在显卡为 1070,内存 16 G 双通道,CPU 为 Intel(R) Core(TM) i7-8750H CPU@2.20 GHz,Win10 操作系统,MATLAB R2021a 仿真软件下运行。

表 2 AMCSSA-LSTM 各项参数
Table 2 Parameters of AMCSSA-LSTM

	优化算法 迭代次数	优化算法 种群数目	优化参数 数目	优化参数 上界	优化参数 下界	LSTM 迭 代次数	初始学 习率	学习率 下降因子	学习率 下降周期	LSTM 隐含 单元数目
AMCSSA-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256

平均相对百分比误差(mean relative percentage error, MRPE)作为评价指标能够更清晰地反映出模型的效果,定义如下^[17]:

$$MRPE = \frac{1}{T} \sum_{k=1}^T \frac{|\widehat{RUL_k} - RUL_k|}{RUL_k} \times 100\%$$


(19)

各模型的参数设置,如表 3 所示,其预测结果与同一

适应度值开始迭代至收敛所需迭代次数,如图 4 和 5 所示,其中,数据集前 90%的数据点作为训练集,后 10%的数据点作为测试集,通过对比测试数据在达到失效阈值时所对应的 RMS 值与实际 RMS 值来判断模型预测的准确率。各模型的预测结果,如表 4 所示。可以观察出,AMCSSA 算法在优化 LSTM 后预测精度以及预测效率要明显好于另外 4 种算法。

表 3 各模型参数设置
Table 3 Parameter setup of each model

模型	优化算法 迭代次数	优化算法 种群数目	优化参 数数目	优化参 数上界	优化参 数下界	LSTM 迭 代次数	初始学 习率	学习率下 降因子	学习率下 降周期	LSTM 隐 含单元
AMCSSA-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256
SSA-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256
PSO-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256
BAT-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256
FA-LSTM	10	10	2	0.8	0.000 1	500	—	—	75	256






图 4 各模型预测结果

Fig. 4 Prediction results of each model




图 5 各模型从相同适应度值迭代至收敛所需迭代次数

Fig. 5 The number of iterations required for each model from the same fitness value to convergence

从图 4 和表 4 可以观察到,AMCSSA 的预测精度比其他算法的预测精度都要高,这证明 AMCSSA 有着更强的寻优性能。并且 RMSE 更低,这能够证明 AMCSSA 算法的鲁棒性和稳定性都要优于其他 4 种算法。从运行时间上来看,由于不同的寻优机制导致不同算法之间的运行时间差异比较大,总体上 PSO 和 BAT 的运行时间最少,FA 的运行时间最长,AMCSSA 的运行时间比 SSA 稍大,这是因为改进策略的引入适当增加了算法的运行时间,它们之间的差异在实际应用中可以忽略不计。这也验证了 AMCSSA 和标准的 SSA 相比,并没有增加过多的计算开销,进一步体现了 AMCSSA 的优越性。

从图 5 中能观察到,同一适应度值开始迭代时,AMCSSA 算法所需要的迭代次数是最少的。这是由于算法在寻优时,通过切比雪夫混沌映射策略初始化种群能

表 4 各模型预测结果比较

Table 4 Comparison of prediction results of various models

算法名称	RMSE	MRPE/%	算法精度/%	完成收敛所需迭代次数	迭代一次所需时间/s
AMCSSA-LSTM	0.054 592	1.67	98.33	6 次	0.042
SSA-LSTM	0.057 984	2.72	97.28	8 次	0.040
PSO-LSTM	0.067 008	9.28	90.72	8 次	0.025
BAT-LSTM	0.068 922	10.07	89.93	7 次	0.025
FA-LSTM	0.067 259	9.40	90.60	7 次	0.088

够使种群分布平均,以至于加速算法对最优解的搜寻。通过将捕食者出现的概率 P_{dp} 由常数转变为非线性递减的策略,能够使算法在局部开发与局部勘探中得到平衡,从而增强了搜索算法的寻优能力。通过引入位置贪婪选择策略,将每一次迭代所产生的松鼠位置进行比较,保留更具优势的个体,从而提高了算法的寻优效率。SSA、PSO、FA、BAT 的收敛曲线随着迭代次数的增加逐渐平缓,有的甚至存在停滞,陷入局部最优,而 AMCSSA 的收敛曲线不断的阶梯式下降,表明自适应 T 分布变异策略能够帮助算法有效的跳出局部最优状态,继续搜索更精确的结果。

综上,AMCSSA 的寻优结果明显优于其他算法,证明 AMCSSA 有着更为强大的寻优能力,并且有着更高效的收敛效率。因此,能够证明该模型在滚动轴承 RUL 预测中是有重要意义的

2) 消融实验

消融实验具体采用分别去除改进策略的方法进行比较:(1)去掉切比雪夫混沌映射策略,(2)去掉非线性递减的捕食者概率策略,(3)去掉自适应 T 分布变异策略,

表 5 去掉不同改进策略后的预测性能比较

Table 5 Comparison of prediction abilities after removing different optimization strategies

算法名称	RMSE	MRPE/%	算法精度/%	完成收敛所需迭代次数	迭代一次所需时间/s
AMCSSA	0.054 592	1.67	98.33	6	0.042
去掉切比雪夫混沌映射策略	0.054 218	1.94	98.06	9	0.055
去掉非线性递减的捕食者概率策略	0.059 414	2.74	97.26	9	0.047
去掉自适应 T 分布变异策略	0.060 653	3.13	96.87	7	0.048
去掉位置贪婪选择策略	0.060 748	3.12	96.88	7	0.046

在去掉切比雪夫混沌映射策略之后,完成收敛所需迭代次数明显增加,预测精度略微下降,这说明采用切比雪夫混沌映射策略初始化种群会使寻优算法的性能有略微提升,收敛速度有很大提升。去掉非线性递减的捕食者概率策略后,完成收敛所需的迭代次数明显增加,预测精度有所下降,这说明非线性递减策略能够使 SSA 的优化性能提高,并且收敛速度有着很大的提升,这是因为使用非线性递减的捕食者概率策略使算法在寻优前期更多地进行全局搜索,使得算法更全面地搜索整个解空间,提高算法的收敛速度,在寻优后期松鼠个体都处在最优解附近,此时算法更多的进行局部开发,可以使得松鼠个体

(4)去掉位置贪婪选择策略。其同一适应度值开始迭代,完成收敛所需迭代次数与预测性能比较,如图 6 和表 5 所示。




图 6 去掉不同改进策略后从相同适应度值迭代至收敛所需迭代次数

Fig. 6 Number of iterations required from the same fitness value to convergence after removing different improvement strategies

在自身附近继续去探寻更优的解,增加了算法的收敛精度。去掉位置贪婪选择策略之后,预测精度大幅下降,完成收敛所需迭代次数略微增加,这说明位置贪婪选择这一策略能够更好地在收敛速度不会下降太多的前提下,高效提高预测精度,这是因为位置贪婪选择策略的引入,在迭代的过程中不断保留高质量的松鼠个体,从而产生使预测结果更加拟合的优化结果。去掉自适应 T 分布变异策略之后,与去掉位置贪婪选择类似,预测精度大幅下降,完成收敛所需迭代次数略微增加,这同样说明自适应 T 分布变异这一策略能够更好地在收敛速度不会下降太多的前提下,高效提高预测精度,这是因为自适应 T 分布

变异的加入,使得算法在寻优后期出现停滞时能够更快跳脱出局部最优,去寻找更精确的寻优结果,从而提高了算法的收敛精度。

综上,在 SSA 中分别引入的 4 种改进策略,在预测结果、完成收敛所需迭代次数上都存在不同程度的提升,但是单一策略对于 SSA 的提升是有限的,不符合实际工程中复杂多变的情况,而结合了 4 种改进策略的 AMCSSA 算法在实验中表现出更加优秀和稳定的寻优性能以及更高的寻优效率。

3 结 论

本文针对 SSA 优化 LSTM 时,存在优化参数易陷入局部最优以及 LSTM 预测效率下降的问题,提出一种自适应变异混沌松鼠搜索算法 (AMCSSA),优化 LSTM 学习率及其下降因子的预测模型。通过在传统 SSA 中引入切比雪夫混沌映射使初始种群分布平均、引入非线性递减的捕食者概率提升算法全局搜索的能力、引入位置贪婪选择策略保留更优个体、引入自适应 T 分布变异策略提高 SSA 的勘探能力以及跳出局部最优的能力。AMCSSA 在引入多个改进策略之后,提升了传统 SSA 优化 LSTM 时跳出局部最优的能力以及整体预测模型的预测效率。通过不同优化算法的对比实验以及改进策略的消融实验证明,AMCSSA 优化 LSTM 的预测模型有着更高的收敛效率, RMSE 最小与 MRPE 最大,表明本文模型在滚动轴承 RUL 预测任务中都优于其余模型,证明了本文提出方法的有效性。在滚动轴承 RUL 的预测过程中,健康指标的选择也会影响其预测的准确性,未来对于如何构建更为贴合工程实际的健康指标需要进一步深入研究。

参考文献


- [1] LEI Y, LI N, GONTARZ S, et al. A model-based method for remaining useful life prediction of machinery[J]. IEEE Transactions on Reliability, 2016, 65(3):1314-1326.
- [2] 张昌凡,刘佳峰,何静,等. 基于改进卷积双向门控循环网络的轴承故障诊断[J]. 电子测量与仪器学报, 2021, 35(11):61-66.
ZHANG CH F, LIU J F, HE J, et al. Improved CNN-BIGRU method for bearing fault diagnosis[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(11):61-66.
- [3] 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, 2019, 38(1):5.
- [4] WANG D, TSUI K, MIAO Q. Prognostics and health

- management: A review of vibration based bearing and gear health indicators [J]. IEEE Access, 2018, 6: 665-676.
- [5] YANG J, PENG Y, XIE J, et al. Remaining useful life prediction method for bearings based on LSTM with uncertainty quantification [J]. Sensors, 2022, 22(12):4549.
- [6] ZHU X, ZHANG P, XIE M. A joint long short-term memory and AdaBoost regression approach with application to remaining useful life estimation [J]. Measurement: Journal of the International Measurement Confederation, 2021, 170:108707.
- [7] HU Y, WEI R, YANG Y, et al. Performance degradation prediction using LSTM with optimized parameters[J]. Sensors, 2022, 22(6):2407.
- [8] KUMAR R, KUMAR P, KUMAR Y. Integrating big data driven sentiments polarity and ABC-optimized LSTM for time series forecasting [J]. Multimedia Tools and Applications, 2022, 81(24):34595-34614.
- [9] LV J, WANG C, GAO W, et al. An economic forecasting method based on the light GBM-optimized LSTM and time-series model [J]. Computational Intelligence and Neuroscience, 2021, 2021:1-10.
- [10] 郁书好,苏守宝. 混沌萤火虫优化算法的研究及应用[J]. 计算机科学与探索, 2014, 8(3):352-358.
YU SH H, SU SH B. Research and application of chaotic glowworm swarm optimization algorithm[J]. Journal of Frontiers of Computer Science and Technology, 2014, 8(3):352-358.
- [11] 高晨峰,陈家清,石默涵. 融合黄金正弦和曲线自适应的多策略麻雀搜索算法[J]. 计算机应用研究, 2022, 39(2):491-499.
GAO CH F, CHENG J Q, SHI M H. Multi-strategy sparrow search algorithm integrating golden sine and curve adaptive[J]. Application Research of Computers, 2022, 39(2):491-499.
- [12] ZHANG X, ZHAO K, WANG L, et al. An improved squirrel search algorithm with reproductive behavior[J]. IEEE Access, 2020, 8:101118-101132.
- [13] WANG Y, DU T. An improved squirrel search algorithm for global function optimization[J]. Algorithms, 2019, 12(4):80.
- [14] ZHENG T, LUO W. An improved squirrel search algorithm for optimization[J]. Complexity, 2019:1-31.
- [15] LUO W, ZHENG T. An improved squirrel search algorithm for optimization[J]. Complexity, 2019.
- [16] RAI A, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling

- element bearings[J]. Tribology International, 2016, 96: 289-306.
- [17] GUO R, WANG Y. Remaining useful life prognostics for the rolling bearing based on a hybrid data-driven method[J]. Proceedings of the Institution of Mechanical Engineers, Part I: Journal of Systems and Control Engineering, 2021, 235(4): 517-531.
- [18] JAIN M, SINGH V, RANI A. A novel nature-inspired algorithm for optimization: Squirrel search algorithm[J]. Swarm and Evolutionary Computation, 2019, 44: 148-175.
- [19] 冯增喜,何鑫,崔巍,等. 混合随机反向学习和高斯变异的混沌松鼠搜索算法[J]. 计算机集成制造系统, 2023, 29(2): 604-615.
FENG Z X, HE X, CUI W, et al. Hybrid random opposition-based learning and Gaussian mutation of chaotic squirrel search algorithm[J]. Computer Integrated Manufacturing Systems, 2023, 29(2): 604-615.
- [20] 李楠,薛建凯,舒慧生. 基于自适应 t 分布变异麻雀搜索算法的无人机航迹规划[J]. 东华大学学报(自然科学版), 2022, 48(3): 69-74.
LI N, XUE J K, SHU H SH. A sparrow search algorithm with adaptive t distribution mutation-based path planning of unmanned aerial vehicles [J]. Journal of Donghua University (Natural Science), 2022, 48(3): 69-74.
- [21] AHMAD W, KHAN S A, KIM J. A hybrid prognostics technique for rolling element bearings using adaptive predictive models[J]. IEEE Transactions on Industrial Electronics, 2018, 65(2): 1577-1584.
- [22] 苏文胜. 滚动轴承振动信号处理及特征提取方法研究[D]. 大连:大连理工大学, 2010.
SU W SH. Research on rolling element bearing vibration signal processing and feature extraction method [D].

Dalian; Dalian University of Technology, 2010.

作者简介



何静, 2002 年于中南林业科技大学获得硕士学位, 2009 年于国防科技大学获得博士学位, 现为湖南工业大学教授, 主要研究方向为机电系统故障诊断等。

E-mail: hejing@263.net

He Jing received M. Sc. from Central South University of Forestry and Technology in 2002 and Ph. D. from National University of Defense Technology in 2009, respectively. Now she is a professor at Hunan University of Technology. Her main research interest includes electromechanical system fault diagnosis.



高见(通信作者), 2019 年于安徽信息工程学院获得学士学位, 现为湖南工业大学硕士研究生, 主要研究方向为电机牵引与故障诊断。

E-mail: gj22548922010@126.com

Gao Jian (Corresponding author) received B.Sc. degree from Anhui Institute of Information Technology in 2019. Now he is a M. Sc. candidate at Hunan University of Technology. His main research interests include motor traction and fault diagnosis.



张昌凡, 1989 年于西南交通大学获得硕士学位, 2001 年于湖南大学获得博士学位, 现为湖南工业大学教授, 主要研究方向为非线性控制及应用等。

E-mail: zhangchangfan@263.net

Zhang Changfan received M. Sc. from Southwest Jiaotong University in 1989 and Ph. D. from Hunan University in 2001, respectively. Now he is a professor at Hunan University of Technology. His main research interests include nonlinear control and applications.