

改进灰狼优化算法医疗锂电池剩余寿命预测*

何成¹, 刘长春², 武洋², 吴涛², 陈童³

(1. 上海第二工业大学 智能制造与控制工程学院;
2. 上海第二工业大学 环境与材料工程学院, 上海 201209; 3. 上海市第一人民医院, 上海 200080)

摘要:【目的】通过改进灰狼优化算法对医疗锂电池进行剩余寿命预测,从而保障抢救时机并减少医疗事故的目的。【方法】运用小波核极限学习机(Wavelet kernel extreme learning machine, WKELM)与小生境灰狼算法(Niche grey wolf optimization, NGWO)相融合的算法形成改进灰狼优化算法 WKELM-NGWO 算法。采用 NGWO 算法对 WKELM 参数进行优化处理,并将最大化训练集的分类准确度作为目标函数,得到寻优过程的数学模型。采用差分方式对医疗电子设备锂电池容量的时间序列进行处理,得到多维时间序列特征向量,归一化处理获得特征向量,并将其分为训练集和测试集。计算得出每只灰狼个体的适应度值 f_i ,并对适应度值 f_i 进行排序,适应度值 f_i 排在前三的个体位置分别记为 $X_\alpha, X_\beta, X_\delta$ 。选择最优的灰狼个体位置作为 WKELM 参数对数据进行训练后,对心脏起搏器用锂电池和心脏除颤仪用锂电池两种锂电池测试样本进行剩余寿命预测操作。【结果】在相同的预测起始点下, WKELM-NGWO 算法的均方根误差(RMSE)误差低于 WKELM 和 NGWO 算法,基于融合算法 WKELM-NGWO 的医疗电子设备锂电池剩余寿命(Remaining useful life)预测曲线更接近电池的退化曲线。【结论】WKELM-NGWO 融合算法增强了对不同数据的适应能力,既克服了小波核极限学习机(WKELM)学习速度慢、结构不稳定的问题,也克服了小生境灰狼算法(NGWO)求解精度低、收敛速度慢从而导致跳不出局部最优解的问题。

关键词: 医疗锂电池; 剩余寿命预测; 小波核极限学习机; 小生境灰狼算法; 改进灰狼优化算法 WKELM-NGWO

中图分类号: TP206+.3

文献标志码: A

文章编号: 1672-6693(2019)03-0021-08

1 研究背景

锂离子电池正广泛应用于医疗系统,然而一个不可避免的问题是随着循环使用和材质老化电池性能会不断下降直到废弃。另外电池性能的退化无法直接测量,往往需要提前对其进行估计,从而决定是否更换医疗设备中的锂电池,以避免一些不必要的医疗事故。因此,对于医疗设备锂电池而言,准确的剩余寿命预测可以有效的评估医疗设备锂电池的健康状态,保障医疗电子设备的可靠性和安全性^[1]。

文献[2-3]灰狼优化算法(Grey wolf optimizer, GWO)是一种模拟灰狼捕食行为的群体智能算法,该算法最先由澳大利亚学者 Mirjalili 于 2014 年提出,根据灰狼的社会等级将包围、追捕、攻击等捕食任务分配给不同等级的灰狼群来完成捕食行为,从而实现全局优化的过程。GWO 算法具有操作简单、调节参数少、编程易实现等特点。在函数优化方面,与其他群智能优化算法相比有明显的优越性。但同时也存在着易陷入局部最优、求解精度不高、收敛速度慢等缺点。根据算法存在的缺点,本文提出了一种小生境灰狼优化算法(Niche grey wolf optimization, NGWO)。该算法利用基本 GWO 算法计算各灰狼的适应度值,当灰狼间的距离小于小生境半径时,比较灰狼个体的适应度值,通过对适应度值较差的灰狼个体施以罚函数,来提高全局搜索能力。通过对 5 个基准函数的测试,将结果与基本 GWO 算法和 PSO 算法进行比较,表明了该算法的优越性。

文献[4-5]将高斯核函数引入极限学习机中,提高了 ELM 的分类精度,但是高斯核函数的性能会受到参数的影响。文献[6-8]采用冯诺依曼结构改进的鲸鱼算法(Von neumann whale optimization algorithm, VN-

* 收稿日期:2018-10-19 修回日期:2019-04-23 网络出版时间:2019-05-09 19:29

资助项目:上海第二工业大学研究生项目基金(No. EGD18YJ0003)

第一作者简介:何成,男,副教授,研究方向为故障预测与健康管管理, E-mail: hecheng@sspu.edu.cn; 通信作者:陈童,男,经济师, E-mail: 651979759@qq.com

网络出版地址: <http://kns.cnki.net/kcms/detail/50.1165.N.20190509.1929.004.html>

WOA)优化 WKELM 的参数,在一定程度上降低了 WKELM 对参数的依赖性,但存在收敛速度慢、分类精度不高的问题。小波核极限学习机在算法执行过程中,不需要调整隐藏层的参数^[9-10]。因此,ELM 的学习速度更快,泛化性能更优。

2 WKELM-NGWO 预测原理

2.1 医疗锂电池剩余寿命预测的概念

医疗锂电池剩余寿命预测即根据医疗电子设备锂电池的运行状态,如果医疗电子设备锂电池系统由当前时刻 t_1 到重新充满电状态下锂电池系统性能特征低于容量阈值时刻 t_2 即额定容量的 70% 时,即认为医疗电子设备锂电池报废失效,这段 t_1 到 t_2 称为医疗锂电池剩余寿命^[11]。在时刻 t_i 内,医疗电子设备锂电池的剩余寿命可以定义用维纳过程 $\{Y(t), t \geq 0\}$ 通过阈值 ω 的首达时间进行描述:

$$X_{t_i} = \inf\{x_{t_i} : Y(t_i + x_{t_i}) \geq \omega | Y(t_i) < \omega\}。 \quad (1)$$

2.2 小生境灰狼优化算法原理

把小生境这种生物学概念的思想提炼出来,运用到灰狼算法的优化上来,其核心要点是:当两个个体的海明距离小于预先指定的某个值时,惩罚其中适应值较小的个体。个体间的欧式距离能反映出个体间的疏散程度,对于 D 维空间灰狼 i 的位置为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})^T$, 灰狼 j 的位置为 $X_j = (x_{j1}, x_{j2}, \dots, x_{jD})^T$, 那么灰狼 i 与灰狼 j 之间的欧式距离为^[12]:

$$d_{ij} = \|X_i - X_j\|, i, j = 1, 2, \dots, N。 \quad (2)$$

给出指定参数(σ_{share} 为小生境半径),如果 $d_{ij} < \sigma_{\text{share}}$, 则该个体加入到小生境群体 X_p 。

小生境灰狼优化算法步骤如下:

步骤 1, 初始化 N, D, t, P 等参数以及灰狼群体 $X = (X_1, X_2, \dots, X_N)$, 每个灰狼的位置 $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})^T, (i=1, 2, \dots, N)$ 。

步骤 2, 计算每个灰狼个体的适应度值 f_i , 将排列前三的 f_i 值的灰狼个体的位置分别记为 $X_\alpha, X_\beta, X_\delta$, 并将适应度值最好即 f_i 值最大的 X_α 记为最优解。

步骤 3, 按照(3)式计算剩余个体 ω 与 $X_\alpha, X_\beta, X_\delta$ 的距离:

$$\begin{cases} D_\alpha = |C_1 X_\alpha(t) - X(t)| \\ D_\beta = |C_2 X_\beta(t) - X(t)|, \\ D_\delta = |C_3 X_\delta(t) - X(t)| \end{cases} \quad (3)$$

并根据(4)式和(5)式更新灰狼 α, β, δ 和猎物的位置:

$$\begin{cases} X_1 = X_\alpha(t) - A_1 D_\alpha \\ X_2 = X_\beta(t) - A_2 D_\beta, \\ X_3 = X_\delta(t) - A_3 D_\delta \end{cases} \quad (4)$$

$$X_p(t+1) = \frac{(X_1 + X_2 + X_3)}{3}。 \quad (5)$$

步骤 4, 小生境原理:根据(2)式计算灰狼个体间的距离 d_{ij} , 当 $d_{ij} < \sigma_{\text{share}}$ 时, 比较灰狼 i 与灰狼 j 的适应度值 f_i, f_j 的大小, 并对其中适应度值较小的灰狼施以罚函数。即若 $d_{ij} < \sigma_{\text{share}}$, 则 $\min(f_i, f_j) = Q$ (Q 函数的惩罚力度由所求函数解值的大小决定)。

步骤 5, 按照(6)式和(7)式更新参数 a, A, C 的值:

$$A = 2a \cdot r_1 - a, \quad (6)$$

$$C = 2 \cdot r_2, \quad (7)$$

其中: a 随着迭代次数的增加从 2 到 0 呈线性递减, r_1, r_2 为 $[0, 1]$ 间的随机数。

步骤 6, 若算法达到最大迭代次数 t , 那么算法结束并输出最优解 X_α ; 否则, 返回步骤 2。

2.3 小波核极限学习机

极限学习机在算法执行过程中,不需要调整隐藏层的参数,因此,ELM 的学习速度更快,泛化性能更优^[13]。

ELM 的目标为最小化输出权值及误差。根据 KKT 条件,引入 Lagrange 函数后的目标函数为:

$$\min L_{\text{ELM}} = \frac{1}{2} \|\beta\|^2 + C \frac{1}{2} \sum_{i=1}^N \gamma_i^2 - \sum_{i=1}^N \alpha_i (h(x_i)\beta - t_i + \gamma_i)。 \quad (8)$$

其中: β 为输出权值, x_i 为训练样本, t_i 为目标输出值, $h(x_i)$ 为隐藏层的核映射, C 为正则化系数, r_i 为训练误差, α_i 为 Lagrange 算子。

ELM 输出函数可以表示为:

$$f(x) = h(x)\beta = h(x)\mathbf{H}^T \left(\frac{1}{C} + \mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{T}。 \quad (9)$$

其中: \mathbf{I} 为单位矩阵, \mathbf{H} 为隐层输出矩阵, \mathbf{T} 为输出层矩阵。

为了进一步提高 ELM 的分类能力,将核函数引入 ELM。根据核函数的相关理论,隐层节点数可以通过核函数的形式确定,不需要人为设定。核函数矩阵具体表达式为:

$$\mathbf{H}\mathbf{H}^T(i, j) = h(x_i) \times h(x_j) = K(x_i, x_j)。 \quad (10)$$

其中: $K(x_i, x_j)$ 为核函数, $i, j \in (1, 2, \dots, N)$ 。

因此,核极限学习机的输出函数可以表示为:

$$f(x) = h(x)\mathbf{H}^T \left(\frac{1}{C} + \mathbf{H}\mathbf{H}^T \right)^{-1} \mathbf{T} = \begin{bmatrix} K(x, x_1) \\ \dots \\ K(x, x_N) \end{bmatrix} \left(\frac{1}{C} + \Omega \right)^{-1} \mathbf{T}。 \quad (11)$$

小波核函数可以实现逼近任意函数,在非线性分类平面上效果较好,泛化能力强。因此,本文选用 Morlet 小波函数作为 ELM 的核函数,小波核函数的具体数学表达式为:

$$K(x, x') = \cos \left[a \frac{\|x_i - x'_i\|}{b} \right] \exp \left[- \frac{\|x_i - x'_i\|^2}{c} \right]。 \quad (12)$$

其中: a 为系数因子, b 为尺度因子, c 为平移因子。

3 WKELM-NGWO 剩余寿命预测算法

3.1 WKELM 参数选择

极限学习机中的正则化系数 C 及小波核函数中的参数会影响 WKELM 的分类效果。若是随机选择参数,会降低 WKELM 的分类精度。因此在医疗电子设备锂电池剩余寿命预测过程中, WKELM 最优参数组合的选择极其关键。本文采用 NGWO 算法对 WKELM 参数进行优化处理,并将最大化训练集的分类准确度作为目标函数,寻优过程的数学模型为:

$$\begin{cases} \max f = \text{accuracy}(C, a, b, c) \\ \text{s. t. } C, a, b, c \in (l_{C, a, b, c}, u_{C, a, b, c}) \end{cases} \quad (13)$$

3.2 灰狼优化算法的改进

医疗电子设备锂电池容量是一组由充放电实验采集数据并分析得到的时间序列数据。医疗电子设备锂电池容量具有明显的非线性特征。采用 NGWO 算法对 WKELM 的参数优化过程如下:

步骤 1,采用差分方式对医疗电子设备锂电池容量的时间序列进行处理,得到多维时间序列特征向量,归一化处理获得特征向量,并将其分为训练集和测试集。

步骤 2,初始化 WKELM 参数 $[C, a, b, c]$ 的取值范围,设置 WKELM-NGWO 算法中的相关参数。

步骤 3,计算得出每只灰狼个体的适应度值 f_i ,并对适应度值 f_i 进行排序,适应度值 f_i 排在前三的个体位置分别记为 $X_\alpha, X_\beta, X_\delta$ 。

步骤 4,根据(3)式,(4)式和(5)式更新其他个体的位置。

步骤 5,判断当前是否达到最大迭代次数,未达到,继续重复执行步骤 3 到步骤 5;否则,跳出算法循环,并输出最佳适应度值及最优灰狼个体位置。

步骤 6,选择最优的灰狼个体位置作为 WKELM 参数对数据进行训练后,对测试样本进行剩余寿命预测操作。

3.3 WKELM-NGWO 算法性能评估

为验证 WKELM-NGWO 算法的优越性,本文采用 WKELM, NGWO 和 WKELM-NGWO 这 3 种算法对测

试函数进行仿真实验。实验中选取了 Sphere 和 Griewank 两种典型测试函数,其中 Sphere 为测试算法的收敛速度的单峰函数,Griewank 为验证算法跳出局部最优能力的多峰函数。仿真实验参数设置如下:种群个体数为 50,最大迭代次数为 600,种群规模为 50。对 3 种算法分别运行 10 次后,得到的测试函数结果对比如表 1 所示。

表 1 测试函数优化值比较

Tab. 1 Test Function Optimization Value Comparison

函数名	优化值分类	WKELM	NGWO	WKELM-NGWO
Sphere 函数	最优值	$2.034e^{-29}$	$5.315e^{-156}$	$2.012e^{-218}$
Sphere 函数	平均值	$7.817e^{-28}$	$1.342e^{-128}$	$1.186e^{-204}$
Sphere 函数	标准差	$1.083e^{-27}$	$1.465e^{-130}$	$1.532e^{-200}$
Griewank 函数	最优值	0	0	0
Griewank 函数	平均值	0	$5.5e^{-3}$	0
Griewank 函数	标准差	0	$1.22e^{-3}$	0

从表 1 中可以看出,与其他两种算法相比,WKELM-NGWO 算法综合了 NGWO 算法的收敛速度快以及 WKELM 算法跳出局部最优能力强的特点,因而用于医疗电子设备锂电池剩余寿命预测的 WKELM-NGWO 算法的优化效果更佳,稳定性更强。

4 仿真实验分析

为定量评估各算法的医疗电子设备锂电池剩余寿命预测精度,可以用 RUL 预测的绝对误差(Δ_{RUL_ae})和相对误差($\delta_{RUL_re(\%)}$)进行分析。

$$\Delta_{RUL_ae} = |L_{EOP} - L_{EOL}|, \quad (14)$$

$$\delta_{RUL_re(\%)} = \frac{|L_{EOP} - L_{EOL}|}{L_{EOL}} \times 100\%。 \quad (15)$$

(14)式和(15)式中: L_{EOL} (End of life, EOL)表示医疗电子设备中锂电池寿命真实的结束点对应的值, L_{EOP} (End of prediction, EOP)表示医疗电子设备中锂电池寿命进行算法预测的结束点对应的值, $C_{real}(i)$ 为从预测起始点开始 i 时刻后医疗电子设备锂电池的真实容量值, $C_{pre}(i)$ 为从预测起始点开始 i 时刻医疗电子设备锂电池的预测容量值。为了保证实验结果更加真实可靠,选择两组医疗电子设备锂电池 B1,B2 进行 3 种算法的剩余寿命预测(B1 为额定容量 1.44 Ah 的心脏起搏器用锂电池,B2 为额定容量 1.82 Ah 的心脏除颤仪用锂电池,电池数据来源自上海市第一人民医院设备保全处)。

4.1 基于 3 种算法的 B1 电池 RUL 预测

由表 2 数据以及图 1~图 3 可以得出:对于心脏起搏器用的锂电池,在相同预测的起始点的情况下,融合算法 WKELM-NGWO 的医疗锂电池寿命预测更加接近真实结束寿命 100 次,同时融合算法 WKELM-NGWO 的医疗锂电池剩余寿命预测结果的相对误差和绝对误差均明显低于 WKELM 算法和 NGWO 算法单独作用时的医疗锂电池剩余寿命预测结果的相对误差和绝对误差。因此,对于心脏起搏器用的锂电池而言,融合算法 WKELM-NGWO 的医疗锂电池剩余寿命预测精度明显优于 WKELM 算法和 NGWO 算法单独作用时的预测精度,且随着预测的起始点的后推,预测结果更加接近真实值。

4.2 基于 3 种算法的 B2 电池 RUL 预测

由表 3 数据以及图 4~图 6 可以得出:对于心脏除颤仪用的锂电池,在相同预测的起始点的情况下,融合算法 WKELM-NGWO 的医疗锂电池寿命预测更加接近真实结束寿命 129 次,同时融合算法 WKELM-NGWO 的医疗锂电池剩余寿命预测结果的相对误差和绝对误差均明显低于 WKELM 算法和 NGWO 算法单独作用时的医疗锂电池剩余寿命预测结果的相对误差和绝对误差。因此,对于心脏除颤仪用的锂电池而言,融合算法

WKELM-NGWO 的医疗锂电池剩余寿命预测精度明显优于 WKELM 算法和 NGWO 算法单独作用时的预测精度,且随着预测的起始点的后推,预测结果更加接近真实值。

表 2 B1 心脏起搏器用锂电池在不同算法下的 RUL 预测结果

Tab. 2 RUL prediction results of B1 cardiac pacemaker Lithium battery under different algorithms

预测的起始点	预测算法	L_{EOL}	L_{EOP}	$\Delta_{RUL_{ae}}$	$\delta_{RUL_{re}}(\%)$
前期 $T_1=40$	WKELM	100	63	37	37
前期 $T_1=40$	NGWO	100	71	29	29
前期 $T_1=40$	WKELM-NGWO	100	90	10	10
中期 $T_2=60$	WKELM	100	76	24	24
中期 $T_2=60$	NGWO	100	88	12	12
中期 $T_2=60$	WKELM-NGWO	100	96	4	4
后期 $T_3=80$	WKELM	100	92	8	8
后期 $T_3=80$	NGWO	100	97	3	3
后期 $T_3=80$	WKELM-NGWO	100	103	3	3




图 1 B1 电池以 $T_1=40$ 为起始点的预测曲线图

Fig. 1 Predicted graph of B1 battery starting from $T_1=40$




图 2 B1 电池以 $T_2=60$ 为起始点的预测曲线图

Fig. 2 Predicted graph of B1 battery starting from $T_2=60$




图 3 B1 电池以 $T_3=80$ 为起始点的预测曲线图

Fig. 3 Predicted graph of B1 battery starting from $T_3=80$

表 3 B2 心脏除颤仪用锂电池在不同算法下的 RUL 预测结果

Tab. 3 RUL prediction results of Lithium batteries in B2 cardiac defibrillator under different algorithms

预测起始点	预测方法	L_{EOL}	L_{EOP}	$\Delta_{RUL_{ae}}$	$\delta_{RUL_{re}}(\%)$
前期 $T_1=70$	WKELM	129	86	43	33.33
前期 $T_1=70$	NGWO	129	103	26	20.16
前期 $T_1=70$	WKELM-NGWO	129	151	22	17.05
中期 $T_2=90$	WKELM	129	109	20	15.50
中期 $T_2=90$	NGWO	129	115	12	9.30
中期 $T_2=90$	WKELM-NGWO	129	134	5	3.88
后期 $T_3=110$	WKELM	129	116	13	10.08
后期 $T_3=110$	NGWO	129	123	6	4.65
后期 $T_3=110$	WKELM-NGWO	129	131	2	1.55

4.3 B1 和 B2 电池 3 种算法预测结果对比

由 4.1 和 4.2 的六幅基于 3 种算法的 B1 和 B2 电池 RUL 预测结果图可以看出, WKELM-NGWO 融合算法 B1 电池预测结果基本略微小于 B1 电池的真实寿命值, 而 WKELM-NGWO 融合算法 B2 电池预测结果略微大于 B2 电池的真实寿命值, 这也是选择两种电池进行对比试验的目的所在, 使得实验结果更加真实可靠。但是总体而言, WKELM-NGWO 算法所预测出的 B1 和 B2 电池剩余使用寿命预测结果更符合医疗电子设备锂电池容量的实际退化情况。同时, 无论是 B1 还是 B2 电池, 3 种算法的误差都在随着预测起始点的后推而减小, 预测结果也越来越接近电池的失效阈值。




图 4 B2 电池以 $T_4=70$ 为起始点的预测曲线图

Fig. 4 Predicted graph of B2 battery starting from $T_4=70$




图 5 B2 电池以 $T_5=90$ 为起始点的预测曲线图

Fig. 5 Predicted graph of B2 battery starting from $T_5=90$




图 6 B2 电池以 $T_6=110$ 为起始点的预测曲线图

Fig. 6 predicted graph of B2 battery starting from $T_6=110$

为进一步评估基于 WKELM, NGWO, WKELM-NGWO 医疗电子设备锂电池 RUL 的预测结果的准确度, 可以根据均方根误差 (Root mean square error, RMSE) 对 WKELM, NGWO, WKELM-NGWO 这 3 种算法的医疗电子设备锂电池 RUL 预测结果进行量化分析。可以定义如下:

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_k^n [C_{\text{real}(k)} - C_{m(k)}]^2}, \quad (16)$$

其中: n 代表数据的长度, $C_{\text{real}(k)}$ 和 $C_{m(k)}$ 分别为在 k 时刻时的医疗电子设备锂电池真实容量和预测容量。这 3 种算法对 B1 电池和 B2 电池的 RUL 预测结果 δ_{RMSE} 值如表 2 所示:

表 4 B1 电池和 B2 电池的 RUL 预测结果 δ_{RMSE} 值

Tab. 4 RUL prediction results δ_{RMSE} values for B1 and B2 batteries

预测起始点	B1 电池			B2 电池		
	$T_1=40$	$T_2=60$	$T_3=80$	$T_4=70$	$T_5=90$	$T_6=110$
WKELM	0.294 73	0.373 86	0.681 23	0.240 15	0.231 04	0.237 51
NGWO	0.234 75	0.248 06	0.426 83	0.173 61	0.146 97	0.113 23
WKELM-NGWO	0.160 64	0.105 17	0.091 93	0.126 12	0.085 28	0.041 39

由表中电池 B1 和 B2 的 δ_{RMSE} 值可知, 在相同的预测起始点下, WKELM-NGWO 算法的 δ_{RMSE} 误差低于 WKELM 和 NGWO 算法, 这意味着基于融合算法 WKELM-NGWO 的医疗电子设备锂电池 RUL 预测曲线更接近电池的退化曲线, 进一步验证了融合算法 WKELM-NGWO 即改进灰狼算法的医疗电子设备锂电池 RUL 预测精度更高, 可靠性更强。WKELM-NGWO 算法预测结果与医疗电子设备锂电池真实的退化趋势曲线相同, 表明融合算法增强了对不同数据的适应能力, 既克服了小波核极限学习机 (WKELM) 学习速度慢、结构不稳定的问题, 也克服了小生境灰狼算法 (NGWO) 求解精度低、收敛速度慢从而导致跳不出局部最优解的问题。

5 结束语

医疗电子设备锂电池剩余寿命预测对医疗电子设备的发展有着十分重要的意义。为了提高医疗电子设备锂电池剩余寿命预测的准确度以及收敛速度,将基于 WKELM,NGWO,WKELM-NGWO 3 种算法的剩余寿命预测结果进行对比分析,并考虑到电池自身因素的影响,选择了 B1(心脏起搏器用锂电池)和 B2(心脏除颤仪用锂电池)两种典型的医疗电子设备锂电池来进行实验对比。实验结果表明 WKELM-NGWO 算法所预测出的 B1 和 B2 电池剩余使用寿命预测结果更符合医疗电子设备锂电池容量的实际退化情况,3 种算法的误差都在随着预测起始点的后推而减小,预测结果也越来越接近电池的失效阈值。

WKELM-NGWO 算法的均方根误差 δ_{RMSE} 值仅为 WKELM 算法的 $1/6$, δ_{RMSE} 值为 NGWO 算法的 $2/3$ 。既克服了小波核极限学习机(WKELM)学习速度慢、结构不稳定的问题,也克服了小生境灰狼算法(NGWO)求解精度低、收敛速度慢从而导致跳不出局部最优解的问题。WKELM-NGWO 算法对医疗电子设备锂电池剩余寿命预测的方法可以作为心脏起搏器、心脏除颤仪等小容量医疗电子设备锂电池的剩余寿命预测手段,对寿命即将殆尽锂电池及时更换,从而把握住救治的关键时间,有效的减少医疗事故的发生。医疗锂电池剩余寿命预测对保障抢救时机并减少医疗事故具有重要意义。

参考文献:

- [1] 彭宇,刘大同.数据驱动故障预测和健康管理综述[J].仪器仪表学报,2014,35(3):481-495.
PENG Y,LIU D T. Overview of data-driven fault prediction and health management[J]. Journal of Scientific Instrument,2014,35(3):481-495.
- [2] MIRJALILI S,MIRJALILI S M,LEWIS A. Grey wolf optimizer[J]. Advances in Engineering Software,2014,69:46-61.
- [3] 秦波,王祖达,孙国栋,等. VMD 能量熵与核极限学习机在滚动轴承故障诊断中的应用[J]. 中国测试,2017,43(5):91-95.
QIN B,WANG Z D,SUN G D, et al. Application of VMD and hierarchical extreme learning machine in rolling bearing fault diagnosis[J]. China Measurement & Test,2017,43(5):91-95.
- [4] 徐继亚,王艳,纪志成. 基于鲸鱼算法优化 WKELM 的滚动轴承故障诊断[J]. 系统仿真学报,2017,29(9):2189-2197.
XU J Y,WANG Y,JI Z C. Fault diagnosis method of rolling bearing based on WKELM optimized by whale optimization algorithm[J]. Journal of System Simulation,2017,29(9):2189-2197.
- [5] TANG J,DENG C,GUANG G B. Extreme learning machine for multilayer perceptron[J]. IEEE Transactions on Neural Networks & Learning Systems (S2162-237X),2016,27(4):809-821.
- [6] 周建宝,王少军,马丽萍,等. 可重构卫星锂离子电池剩余寿命预测系统研究[J]. 仪器仪表学报,2013,34(9):2034-2044.
ZHOU J B,WANG S J,MA L P, et al. Residual life prediction system for reconfigurable satellite lithiumion batteries [J]. Journal of Scientific Instrument,2013,34(9):2034-2044.
- [7] 王常虹,董汉成,凌明祥,等. 车用锂离子电池剩余使用寿命预测方法[J]. 汽车工程,2015,37(4):476-479.
WANG C H,DONG H C,LING M X, et al. Prediction method for remaining service life of lithium-ion batteries for vehicles[J]. Automotive Engineering,2015,37(4):476-479.
- [8] 王苏湘,彭驭风,赵有璠. 医用电子设备传统电池升级为锂离子电池的可行性研究[J]. 医疗卫生装备,2014,35(9):46-48.
WANG S X,PENG Y F,ZHAO Y F. Feasibility study on upgrading traditional battery of medical electronic equipment to lithium-ion battery[J]. Medical Medical Equipment,2014,35(9):46-48.
- [9] 武兴亮,丁根宏. 改进小生境遗传算法求解多峰函数优化问题[J]. 信息技术,2011(8):73-74.
WU X L,DING G H. Improved niche genetic algorithm for solving multimodal function optimization problems[J]. Information Technology,2011(8):73-74.
- [10] 罗佳,唐斌. 新型灰狼优化算法在函数优化中的应用[J]. 兰州理工大学学报,2016,6(3):97-101.
LUO J,TANG B. Application of new grey wolf optimization algorithm in function optimization [J]. Journal of Lanzhou University of Technology,2016,6(3):97-101.
- [11] 陈晓青,陆慧娟,关伟,等. 基于探测粒子群的小波核极限学习机算法[J]. 计算机科学,2016,43(6A):77-80.
CHEN X Q,LU H J,GUAN W, et al. The algorithm of wavelet kernel limit learning machine based on particle swarm detection [J]. Computer Science,2016,43(6A):

77-80.

- [12] ZHOU L N, LIU Y Q, RONALD W, et al. Toroidal plasma response based ELM control coil design for EU DEMO[J]. Nuclear Fusion, 2018, 58(7):0706025.

- [13] HATTA N M, ZAIN A M, SALLEHUDDIN R, et al. Recent studies on optimisation method of grey wolf optimiser (GWO): a review(2014—2017) [EB/OL]. (2018-05-22) [2018-10-03]. <https://link.springer.com/article/10.1007/s10462-018-9634-2>.

Operations Research and Cybernetics

Improved Grey Wolf Optimization Algorithm for Life Prediction of Medical Lithium Batteries

HE Cheng¹, LIU Changchun², WU Yang², WU Tao², CHEN Tong³

(1. School of Intelligent Manufacturing and Control Engineering, Shanghai Polytechnic University;

2. School of Environmental and Material Engineering, Shanghai Polytechnic University, Shanghai 201209;

3. Shanghai First People's Hospital, Shanghai 200080, China)

Abstract: [Purposes] To improve the life expectancy of medical lithium batteries by improving the gray wolf optimization algorithm, so as to ensure the rescue timing and reduce the purpose of medical accidents. [Methods] The improved gray wolf optimization algorithm WKELM-NGWO algorithm was formed by the algorithm of wavelet kernel learning machine (WKELM) and niche grey wolf algorithm (NGWO). The NGWO algorithm is used to optimize the WKELM parameters, and the classification accuracy of the training set is maximized as the objective function to obtain the mathematical model of the optimization process. The time series of the lithium battery capacity of the medical electronic device is processed by differential method, and the multi-dimensional time series feature vector is obtained, and the feature vector is obtained by normalization, and is divided into a training set and a test set. The fitness value of each gray wolf individual is calculated, and the fitness value is sorted. The individual positions of the fitness value ranked in the first three are respectively recorded as . After selecting the optimal gray wolf individual position as the WKELM parameter to train the data, the remaining life prediction operation is performed on the lithium battery B1 of the cardiac pacemaker and the lithium battery test sample for the cardiac defibrillator. [Findings] Under the same prediction starting point, the root mean square error (RMSE) error of the WKELM-NGWO algorithm is lower than that of the WKELM and NGWO algorithms, and the remaining life of the medical electronic device based on the fusion algorithm WKELM-NGWO (Remaining Useful Life) The prediction curve is closer to the degradation curve of the battery. [Conclusions] The WKELM-NGWO fusion algorithm enhances the adaptability to different data, overcomes the problem of slow learning and structural instability of the wavelet kernel limit learning machine (WKELM), and overcomes the niche grey wolf algorithm (NGWO). Low precision and slow convergence result in the problem of not jumping out of the local optimal solution.

Keywords: medical lithium battery; remaining useful life prediction; wavelet kernel extreme learning machine; niche grey wolf optimization; improved grey wolf optimization algorithm WKELM-NGWO

(责任编辑 陈 乔)