

文章编号:1671-251X(2019)01-0070-06

DOI:10.13272/j.issn.1671-251x.2018060051

矿用动力电池荷电状态预测

谈发明¹, 王琪²

(1. 江苏理工学院 信息中心, 江苏 常州 213001;
2. 江苏理工学院 电气信息工程学院, 江苏 常州 213001)

摘要:针对最小二乘支持向量机(LSSVM)用于预测矿用动力电池荷电状态(SOC)时正则化参数和核函数参数难以优化选择,灰狼优化(GWO)算法在单独求解约束优化问题时出现早熟、稳定性差、易陷入局部最优等问题,在差分进化灰狼优化(DE-GWO)算法的基础上,采用指数函数形式的非线性收敛因子对DE-GWO算法进行改进。该非线性收敛因子在迭代过程前段衰减速率低,能更好地寻找全局最优解,在迭代过程后段衰减速率高,能更精确地寻找局部最优解,有效平衡全局搜索能力和局部搜索能力。实验结果表明,利用改进DE-GWO算法优化LSSVM参数后建立的矿用动力电池SOC预测模型最大绝对误差为3.7%,最大相对误差为5.3%。

关键词:矿用动力电池; 荷电状态; 灰狼优化算法; 差分进化; 最小二乘支持向量机; 收敛因子
中图分类号:TD611 **文献标志码:**A
网络出版地址:<http://kns.cnki.net/kcms/detail/32.1627.TP.20181227.1736.006.html>

State of charge prediction for mine-used power battery

TAN Faming¹, WANG Qi²

(1. Information Center, Jiangsu University of Technology, Changzhou 213001, China; 2. School of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China)

Abstract: It was difficult to optimize parameters of regularization and kernel function when least squares support vector machine(LSSVM) was used to predict state of charge(SOC) of mine-used power battery, and grey wolf optimization(GWO) algorithm was prone to early maturity, poor stability and local optimization when solving constraint optimization problem alone. In view of above problems, on the basis of differential evolution GWO (DE-GWO) algorithm, non-linear convergence factor in the form of exponential function is used to improve the DE-GWO algorithm. The non-linear convergence factor has low attenuation rate in the early stage of iterative process and the global optimal solution can better be found, while it has high attenuation rate at the end of iterative process and the local optimal solution can be found more accurately, which effectively balances global search ability and local search ability. The experimental results show that the maximum absolute error and the maximum relative error of SOC prediction model for mine-used power battery are 3.7% and 5.3% respectively after LSSVM parameters are optimized by the improved DE-GWO algorithm.

Key words: mine-used power battery; state of charge; grey wolf optimization algorithm; differential evolution; least squares support vector machine; convergence factor

收稿日期:2018-06-26;**修回日期:**2018-12-10;**责任编辑:**盛男。
基金项目:江苏省高等学校自然科学研究面上项目(17KJB470003)。
作者简介:谈发明(1981—),男,江苏扬州人,实验师,硕士,主要研究方向为电子与通信,E-mail:tfm@jsut.edu.cn。
引用格式:谈发明,王琪. 矿用动力电池荷电状态预测[J]. 工矿自动化,2019,45(1):70-75.

TAN Faming, WANG Qi. State of charge prediction for mine-used power battery[J]. Industry and Mine Automation, 2019, 45 (1):70-75.

0 引言

精确预测矿用动力电池荷电状态(State of Charge,SOC)是动力电池管理系统的核心功能之一。最小二乘支持向量机(Least Squares Support Vector Machine,LSSVM)用等式约束将求解二次规划问题转化为求解线性方程组问题,提高了预测速度和精度,非常适用于动力电池SOC的预测。但LSSVM的参数选择对LSSVM性能的影响在理论上很难找到必然的对应关系,实际应用时参数的调节没有一个准确可行的方法,需要在不同的应用场合对参数进行优化选择^[1]。

S. Mirjalili 于 2014 年提出的新型智能灰狼优化(Grey Wolf Optimization,GWO)算法^[2]被广泛应用于神经网络的寻优领域,但在单独求解约束优化问题时容易出现早熟、稳定性差、陷入局部最优等缺点^[3]。文献[4-6]在 GWO 算法的基础上引入差分进化,提出了差分进化灰狼优化(Differential Evolution-Grey Wolf Optimization,DE-GWO)算法,提高了收敛速度、求解精度及稳定性。文献[7-9]将灰狼群体的寻优过程分为全局搜索和局部搜索两类操作,采用不同函数类型的非线性收敛因子来平衡、协调这两类操作,减少陷入局部最优的概率。本文在以上研究的基础上,采用指数函数形式的非线性收敛因子对 DE-GWO 算法进行改进,可提高全局搜索能力,有效避免早熟停滞、陷入局部最优的问题;利用改进 DE-GWO 算法对 LSSVM 的参数进行优化选择,在此基础上建立的矿用动力电池 SOC 预测模型在精度方面取得良好效果。

1 基于 LSSVM 的矿用动力电池 SOC 预测模型

依据 LSSVM 基本理论,将采集的矿用动力电池样本数据集 $S=\{(\mathbf{x}_1,\mathbf{y}_1),(\mathbf{x}_2,\mathbf{y}_2),\cdots,(\mathbf{x}_l,\mathbf{y}_l)\}$ ($\mathbf{x}_i$ 为由电池的电压、电流、温度及内阻组成的 4 维输入向量, $\mathbf{y}_i$ 为电池 SOC 构成的 1 维输出向量, $i=1,2,\cdots,l$, l 为样本数)映射到高维特征空间,在高维特征空间中寻找输入向量和输出向量之间的模型^[10]。

根据结构风险最小化原则确定模型参数,可等效于求解以下优化问题^[11]:

$$\begin{aligned} \min J &= \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{\gamma}{2} \sum_{i=1}^l e_i^2 \\ \text{s. t. } \mathbf{y}_i &= \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i \end{aligned} \quad (1)$$

式中: J 为结构风险函数; $\mathbf{w}$ 为高维特征空间权值向量; γ 为正则化参数; e_i 为预测误差; $\varphi(\mathbf{x}_i)$ 为输入样本空间到高维特征空间的非线性映射; b 为偏置量。

引入 Lagrange 函数:

$$L = J - \sum_{i=1}^l \alpha_i (\mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i - \mathbf{y}_i) \quad (2)$$

式中 α_i 为 Lagrange 乘子。

根据 KKT(Karush Kuhn Tucher)条件,得

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 \\ \frac{\partial L}{\partial b} = 0 \\ \frac{\partial L}{\partial e_i} = 0 \\ \frac{\partial L}{\partial \alpha_i} = 0 \end{cases} \rightarrow \begin{cases} \mathbf{w} = \sum_{i=1}^l \alpha_i \mathbf{y}_i \varphi(\mathbf{x}_i) \\ \sum_{i=1}^l \alpha_i \mathbf{y}_i = 0 \\ \alpha_i = \gamma e_i \\ \mathbf{y}_i = \mathbf{w}^T \varphi(\mathbf{x}_i) + b + e_i \end{cases} \quad (3)$$

根据式(3)可得线性方程组:

$$\begin{bmatrix} 0 & \boldsymbol{\xi}^T \\ \boldsymbol{\xi} & \mathbf{K} + \mathbf{I}/\gamma \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix} \quad (4)$$

式中: $\boldsymbol{\xi}=[1,1,\cdots,1]_{1\times l}^T$; $\mathbf{K}$ 为核函数矩阵; $\mathbf{I}$ 为单位矩阵; $\mathbf{y}=[\mathbf{y}_1,\mathbf{y}_2,\cdots,\mathbf{y}_l]$; $\boldsymbol{\alpha}=[\alpha_1,\alpha_2,\cdots,\alpha_l]$ 。

求解式(4)可得基于 LSSVM 的矿用动力电池 SOC 预测模型:

$$\mathbf{y} = \sum_{i=1}^l \alpha_i K(\mathbf{x}_i, \mathbf{x}) + b \quad (5)$$

式中 $K(\mathbf{x}_i, \mathbf{x})$ 为核函数, $\mathbf{x}=[\mathbf{x}_1,\mathbf{x}_2,\cdots,\mathbf{x}_l]$ 。

本文选用径向基函数作为核函数:

$$K(\mathbf{x}_i, \mathbf{x}) = \exp(-|\mathbf{x} - \mathbf{x}_i|^2 / \sigma^2) \quad (6)$$

式中 σ 为核函数参数。

SOC 预测模型的精度主要受 LSSVM 的正则化参数 γ 和核函数参数 σ 的影响^[12],利用改进 DE-GWO 算法优化这 2 个参数。

2 改进 DE-GWO 算法

2.1 GWO 算法

在设定的 D 维搜索空间中,灰狼种群规模为 N ,根据每只灰狼的当前位置计算其目标函数值,选出目标函数值最优的为 α 狼,分列第 2 和第 3 的分别为 β 、 δ 狼,群内剩余个体为 ω 狼。狩猎行为过程由 α 、 β 、 δ 狼负责引导, ω 狼追随其进行包围狩猎。GWO 算法具体实现步骤如下。

(1) 在 D 维搜索空间内随机生成 N 只灰狼个体位置。

(2) 依据每只灰狼个体当前位置计算目标函数值并排序,依据数值从大到小选出 α 、 β 、 δ 狼, α 、 β 、 δ 狼在当前迭代次数为 t 时的位置分别为 $Z_\alpha(t)$ 、 $Z_\beta(t)$ 、 $Z_\delta(t)$,将 $Z_\alpha(t)$ 记为当前最优解。

(3) 根据式(7)确定猎物所在位置 $Z_P(t)$:

$$Z_P(t) = (Z_\alpha(t) + Z_\beta(t) + Z_\delta(t))/3 \quad (7)$$

(4) 更新当前代收收敛因子 a , a 随着迭代次数增

加从 2 线性递减到 0。

(5) 除 α, β, δ 狼外, 剩余的 ω 狼根据式(8)更新自身位置 $Z_{\omega}(t)$, 向猎物方向靠近, 对猎物实施包围行为。

$$Z_{\omega}(t+1) = Z_p(t) - A|CZ_p(t) - Z_{\omega}(t)| \quad (8)$$

式中: $A|CZ_p(t) - Z_{\omega}(t)|$ 为包围步长, $A=2ar_2 - a$, $C=2r_1$ (r_1, r_2 为 $[0, 1]$ 区间的随机数)。

(6) 跳至步骤(2), 直到计算达到最大迭代次数 $t_{\max}$ 。

(7) 输出 α 狼的位置, 即寻优得到的全局最优解。

2.2 DE-GWO 算法

GWO 算法在寻优到后期阶段, 部分灰狼容易在局部极值附近聚集, 因差异性减小导致寻优进展缓慢, 甚至难以跳出局部最优^[13]。因此引入差分进化策略构成 DE-GWO 算法, 利用差分进化的变异、交叉和选择 3 种操作对灰狼个体位置和目标函数进行迭代更新, 维持种群的多样性, 使 GWO 算法跳出局部最优, 提高寻优性能。差分进化策略实现步骤如下。

(1) 产生变异种群。对所有灰狼个体重新排序, 在其中随机选择除当前灰狼个体位置 $Z_k(t)$ 外的 3 个不同灰狼个体位置 $Z_{k1}(t), Z_{k2}(t), Z_{k3}(t)$, 利用式(9)进行变异操作。

$$Z_k(t+1) = Z_{k1}(t) + F(Z_{k2}(t) - Z_{k3}(t)) \quad (9)$$

式中 F 为 $[0, 1]$ 区间的缩放比例因子。

(2) 产生子代种群交叉操作。初始化 1 个新的个体, 产生 1 个 $[0, 1]$ 区间均匀分布的伪随机数, 即选取待交换的维度编号, 遍历每个维度, 如果当前维度是待交换维度或随机概率小于设定的 $[0, 1]$ 区间的交叉概率 C_R , 新个体当前维度等于中间体对应维度, 否则等于当前个体维度。交叉后更新个体位置及目标适应度函数值。

(3) 选择更新父代种群。如果子代个体优于父代个体, 则更新父代个体的最优解。

在 GWO 算法搜索行为中引入上述 3 个步骤, DE-GWO 算法实现流程如图 1 所示。

2.3 非线性收敛因子

当 $|A| > 1$ 时, 狼群为了找到更好的猎物将扩大包围圈, 此时 DE-GWO 算法具有较强的全局搜索能力; 当 $|A| < 1$ 时, 狼群为了完成最后的攻击行为将收缩包围圈, 此时 DE-GWO 算法具有较强的局部搜索能力^[14]。参数 A 调节 DE-GWO 算法的寻优性能取决于收敛因子 a , a 采用非线性形式能更有效地平衡 DE-GWO 算法的全局搜索和局部搜索能力, 体现实际寻优过程, 提高算法求解精度。因此,




图 1 DE-GWO 算法实现流程

Fig. 1 Implementation flow of DE-GWO algorithm

本文对 DE-GWO 算法的收敛因子进行改进, 提出一种指数函数形式的非线性收敛因子:

$$a = 2 - 2[(\exp(t/t_{\max}) - 1)/(\exp(1) - 1)]^2 \quad (10)$$

该非线性收敛因子在迭代过程前段衰减速率低, 能更好地寻找全局最优解; 在迭代过程后段衰减速率高, 能更精确地寻找局部最优解。

3 算法性能测试

为验证改进 DE-GWO 算法的有效性, 从稳定性、求解精度和收敛速度 3 个方面对 GWO 算法、DE-GWO 算法、采用文献[7]中收敛因子的 DE-GWO 算法(记为 DE-GWO-1 算法)、采用文献[9]中收敛因子的 DE-GWO 算法(记为 DE-GWO-2 算法)和改进 DE-GWO 算法进行对比。

算法参数设置: 种群规模 $N=10$, 最大迭代次数 $t_{\max}=200$, 交叉概率 $C_R=0.02$, 缩放比例因子 F 取值范围为 $[0.05, 0.10]$ 。为避免单次寻优结果的偶然性, 对标准测试函数(表 1)分别执行 30 次寻优测试。

表 1 标准测试函数

Table 1 Standard test functions

函数	维度	搜索范围	理论最优解
$f_1(x) = \sum_{k=1}^n x_k^2$	30	$[-100, 100]$	0
$f_2(x) = \sum_{k=1}^n x_k + \prod_{k=1}^n x_k $	30	$[-10, 10]$	0
$f_3(x) = \sum_{k=1}^n (\sum_{j=1}^k x_j)^2$	30	$[-100, 100]$	0
$f_4(x) = \max\{ x_k , 1 \leq k \leq n\}$	30	$[-100, 100]$	0

根据 30 次寻优测试结果计算标准差、平均值和最优解,见表 2。标准差反映数据离散程度,可用来衡量算法的稳定性,标准差越小,表示算法越稳定;平均值和最优解反映算法的求解精度,平均值和最

优解越接近理论最优解,表示算法求解精度越高。从表 2 可看出,在相同维度和固定搜索范围条件下,改进 DE-GWO 算法的稳定性和求解精度均优于其他算法。

表 2 标准测试函数测试结果

Table 2 Test results of standard test functions

函数	GWO 算法	DE-GWO 算法	DE-GWO-1 算法	DE-GWO-2 算法	改进 DE-GWO 算法
$f_1(x)$	标准差: $6.893\ 3\times10^{-9}$	标准差: $2.546\ 2\times10^{-9}$	标准差: $1.756\ 1\times10^{-8}$	标准差: $2.807\ 0\times10^{-11}$	标准差: $3.509\ 7\times10^{-12}$
	平均值: $7.332\ 8\times10^{-9}$	平均值: $3.296\ 8\times10^{-9}$	平均值: $1.964\ 2\times10^{-8}$	平均值: $2.420\ 2\times10^{-11}$	平均值: $1.683\ 4\times10^{-12}$
	最优解: $6.802\ 2\times10^{-10}$	最优解: $5.544\ 5\times10^{-10}$	最优解: $5.842\ 6\times10^{-10}$	最优解: $7.352\ 0\times10^{-13}$	最优解: $2.895\ 2\times10^{-14}$
$f_2(x)$	标准差: $2.192\ 7\times10^{-6}$	标准差: $4.284\ 8\times10^{-6}$	标准差: $1.433\ 3\times10^{-5}$	标准差: $2.871\ 6\times10^{-7}$	标准差: $9.696\ 5\times10^{-8}$
	平均值: $5.135\ 8\times10^{-6}$	平均值: $6.826\ 2\times10^{-6}$	平均值: $2.229\ 1\times10^{-5}$	平均值: $3.564\ 6\times10^{-7}$	平均值: $9.514\ 0\times10^{-8}$
	最优解: $2.450\ 7\times10^{-6}$	最优解: $7.380\ 6\times10^{-7}$	最优解: $5.284\ 1\times10^{-6}$	最优解: $7.673\ 3\times10^{-8}$	最优解: $7.245\ 9\times10^{-9}$
$f_3(x)$	标准差: $5.196\ 2\times10^0$	标准差: $2.669\ 9\times10^{-1}$	标准差: $2.497\ 8\times10^0$	标准差: $4.883\ 4\times10^{-2}$	标准差: $6.779\ 9\times10^{-2}$
	平均值: $5.383\ 1\times10^0$	平均值: $2.192\ 0\times10^{-1}$	平均值: $1.618\ 4\times10^0$	平均值: $6.240\ 4\times10^{-2}$	平均值: $3.468\ 3\times10^{-2}$
	最优解: $2.914\ 4\times10^{-1}$	最优解: $1.297\ 3\times10^{-2}$	最优解: $3.305\ 4\times10^{-2}$	最优解: $6.344\ 7\times10^{-3}$	最优解: $1.192\ 8\times10^{-3}$
$f_4(x)$	标准差: $3.411\ 7\times10^{-2}$	标准差: $8.724\ 7\times10^{-3}$	标准差: $1.264\ 5\times10^{-2}$	标准差: $1.355\ 7\times10^{-3}$	标准差: $1.241\ 5\times10^{-3}$
	平均值: $4.189\ 6\times10^{-2}$	平均值: $1.359\ 7\times10^{-2}$	平均值: $2.007\ 9\times10^{-2}$	平均值: $2.409\ 3\times10^{-3}$	平均值: $1.768\ 7\times10^{-3}$
	最优解: $8.513\ 9\times10^{-3}$	最优解: $4.347\ 0\times10^{-3}$	最优解: $4.963\ 1\times10^{-3}$	最优解: $6.585\ 2\times10^{-4}$	最优解: $2.440\ 6\times10^{-4}$

为直观说明改进 DE-GWO 算法收敛速度和求解精度,从 30 次寻优测试过程中随机选取 1 次标准测试函数进化曲线,如图 2 所示。可看出改进 DE-GWO 算法在前 100 次迭代的收敛速度和其他算法

相比不占优势,主要是为了更好地寻找全局最优解,避免陷入局部最优;在后 100 次迭代的收敛速度加快,以最快速度靠近理论最优解;改进 DE-GWO 算法在收敛速度和求解精度方面明显优于其他算法。




图 2 标准测试函数进化曲线

Fig. 2 Evolution curves of standard test functions

4 SOC 预测实验

4.1 样本数据采集与处理

实验研究对象为 25 节 12 V/24 A·h 矿机设备




图 3 电池组样本数据

Fig. 3 Sample data of battery pack

电池电压、电流、温度和内阻等样本数据单位不同,在数量级上存在很大差异,对算法收敛速度有影响^[15],需将这些数据处理为均值为 0、均方差为 1 的归一化数据。

4.2 实验结果分析

利用改进 DE-GWO 算法优化基于 LSSVM 的矿用动力电池 SOC 预测模型的正则化参数 γ 和核函数参数 σ ,算法基本参数设置:种群规模 $N=10$,搜索空间维度 $D=2$,最大迭代次数 $t_{max}=50$,交叉概率 $C_R=0.2$,缩放比例因子 F 取值范围为 $[0.2, 0.8]$,待优化参数 γ 和 σ 的取值范围为 $[0.01, 1\ 000]$ 。为验证 SOC 预测模型的有效性,将电池样本数据集中的奇数项数据用于 SOC 预测模型训练,偶数项数据用于预测,并和 SOC 实测值进行比较,如图 4 所示。可看出预测前半段小幅电池能量回馈波动较多,SOC 预测值能紧密贴合实测值,未出现明显过拟合现象;预测后半段出现电池能量回馈波动幅度较大区域,但仍能保持较强的跟踪响应能力;SOC 预测值和实测值基本一致。

SOC 预测模型误差如图 5 所示,可看出最大绝对误差为 3.7%,最大相对误差为 5.3%,说明该模

常用的磷酸铁锂动力电池串联构成的电池组,应用多种典型测试工况组成的复合工况进行实验,以 1 Hz 频率采集电池工作时的电压、电流、温度、内阻和 SOC,共获取 2 370 组样本数据,如图 3 所示。

型预测精度高。




图 4 SOC 预测值和实测值比较

Fig. 4 Comparison between prediction value and measurement value of SOC




图 5 SOC 预测模型误差

Fig. 5 Error of SOC prediction model

5 结语

改进 DE-GWO 算法在 DE-GWO 算法的基础上引入指数函数形式的非线性收敛因子,平衡了全局搜索能力和局部搜索能力,提高了算法稳定性、求

解精度、收敛速度;应用改进 DE-GWO 算法优化 LSSVM 的正则化参数和核函数参数,基于优化后 LSSVM 建立的矿用动力电池 SOC 预测模型精度高。不足之处在于预测结果在一定程度上依赖离线训练数据量,下一步研究方向是简化算法复杂度,实现在线采集及精确预测同时进行。

参考文献(References):

[1] 陈健美,钱承,李玉强,等. 基于 LS-SVM 的混合动力镍氢电池组 SOC 预测[J]. 中南大学学报(自然科学版),2013,44(1):135-139.
CHEN Jianmei,QIAN Cheng,LI Yuqiang,et al. SOC prediction of MH/Ni battery in hybrid vehicle based on LS-SVM[J]. Journal of Central South University (Science and Technology),2013,44(1):135-139.

[2] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey wolf optimization [J]. Advances in Engineering Software,2014,69(7):46-61.

[3] 龙文,赵东泉,徐松金. 求解约束优化问题的改进灰狼优化算法[J]. 计算机应用,2015,35(9):2590-2595.
LONG Wen, ZHAO Dongquan, XU Songjin. Improved grey wolf optimization algorithm for constrained optimization problem [J]. Journal of Computer Applications,2015,35(9):2590-2595.

[4] 金星,邵珠超,王盛慧. 一种基于差分进化和灰狼算法的混合优化算法[J]. 科学技术与工程,2017,17(16):266-269.
JIN Xing, SHAO Zhuchao, WANG Shenghui. A hybrid optimization algorithm based on differential evolution and grey wolf optimizer [J]. Science Technology and Engineering,2017,17(16):266-269.

[5] 张新明,涂强,康强,等. 灰狼优化与差分进化的混合算法及函数优化[J]. 计算机科学,2017,44(9):93-98.
ZHANG Xinming, TU Qiang, KANG Qiang, et al. Hybrid optimization algorithm based on grey wolf optimization and differential evolution for function optimization[J]. Computer Science, 2017, 44 (9): 93-98.

[6] 孙闽红,邵章义,秦源,等. 基于差分进化狼群算法的 GNSS 欺骗干扰检测[J]. 计算机工程,2016,42(9):89-93.
SUN Minhong, SHAO Zhangyi, QIN Yuan, et al. GNSS spoofing jamming detection based on differential evolution-wolf pack algorithm [J]. Computer Engineering,2016,42(9):89-93.

[7] 郭振洲,刘然,拱长青,等. 基于改进灰狼算法的 RBF 神经网络研究[J]. 微电子学与计算机,2017,34(7):7-10.
GUO Zhenzhou, LIU Ran, GONG Changqing, et al.

Study on RBF neural network based on gray wolf optimization algorithm [J]. Microelectronics & Computer,2017,34(7):7-10.

[8] 罗佳,唐斌. 基于收敛因子非线性动态变化的灰狼优化算法[J]. 中国科技论文,2016,11(17):1991-1997.
LUO Jia, TANG Bin. Grey wolf optimization algorithm based on nonlinear convergence factor dynamic changing [J]. China Sciencepaper, 2016, 11 (17):1991-1997.

[9] 郭振洲,刘然,拱长青,等. 基于灰狼算法的改进研究[J]. 计算机应用研究,2017,34(12):3603-3606.
GUO Zhenzhou, LIU Ran, GONG Changqing, et al. Study on improvement of gray wolf algorithm [J]. Application Research of Computers, 2017, 34 (12): 3603-3606.

[10] 于洋,纪世忠,魏克新. 基于 LS-SVM 算法动力电池 SOC 估计方法的研究[J]. 电源技术,2012,36(3):349-351.
YU Yang, JI Shizhong, WEI Kexin. Estimating method for power battery state of charge based on LS-SVM[J]. Chinese Journal of Power Sources,2012, 36(3):349-351.

[11] 吕鹏飞,陈学华. 基于 PSO 优化 LSSVM 模型的回采巷道顶底板移近量预测[J]. 安全与环境学报,2017,17(6):2045-2049.
LYU Pengfei, CHEN Xuehua. PSO optimized LSSVM model by predicting the convergence between the roof and the floor in the gateways[J]. Journal of Safety and Environment,2017,17(6):2045-2049.

[12] 童刘伟. 基于 LS-SVM 的蓄电池荷电状态监测方法的研究与设计[D]. 南宁:广西大学,2013.

[13] 牛家彬,王辉. 一种基于混合策略的灰狼优化算法[J]. 齐齐哈尔大学学报(自然科学版),2018,34(1):16-19.
NIU Jiabin, WANG Hui. A hybrid strategy-based grey wolf optimization algorithm[J]. Journal of Qiqihar University(Natural Science Edition),2018,34 (1):16-19.

[14] 杨红光,刘建生. 一种结合灰狼优化和 K-均值的混合聚类算法[J]. 江西理工大学学报,2015,36(5):85-89.
YANG Hongguang, LIU Jiansheng. A hybrid clustering algorithm based on grey wolf optimizer and K-means algorithm[J]. Journal of Jiangxi University of Science and Technology,2015,36(5):85-89.

[15] 王琪,孙玉坤,倪福银,等. 混合动力汽车电池内部状态预测的贝叶斯极限学习机方法[J]. 中国机械工程,2016,27(22):3118-3123.
WANG Qi, SUN Yukun, NI Fuyin, et al. Prediction of internal states of battery in HEV by BELM[J]. China Mechanical Engineering,2016,27(22):3118-3123.