

基于强化学习与变权组合模型的EV充电需求功率预测方法

宋宗仁¹, 葛泉波^{2,3,4}, 李春喜⁵

(1. 上海海事大学物流工程学院, 上海 201306; 2. 南京信息工程大学自动化学院, 南京 210044; 3. 大数据分析 & 智能系统江苏省高校重点实验室, 南京 210044; 4. 大气环境与装备技术协同创新中心, 南京 210044; 5. 浙江经济职业技术学院汽车技术学院, 杭州 310018)

摘要: 当电动汽车(Electric vehicle, EV)与充电桩连接时, 精确预测电动汽车动力电池组的充电需求功率, 对于防止电池组过充至关重要。由于电池组物理模型的复杂性使基于其充电需求功率预测方法通常难以构建, 且实时性不高。此外, 单一预测模型的预测精度偏低。针对上述问题, 结合充电数据与机器学习, 提出一种基于强化学习与变权组合模型的EV充电需求功率预测方法。在传统灰狼优化算法的基础上, 将混沌映射、精英反向学习策略相结合以提高初始种群的质量, 利用强化学习的动态权重策略更新灰狼个体位置来优化最小二乘支持向量机(Least square support vector machine, LSSVM)算法中的参数; 通过基于时变权重分配的变权组合方法合理分配极限学习机预测模型与改进LSSVM预测模型的权重, 解决单一预测模型方法的不足; 采用电动汽车的实际充电数据对所提预测算法进行验证, 新方法相较于其他3种传统方法在预测精度上分别提高了4.75%、3.84%和0.38%。

关键词: 充电需求功率; 变权组合; 强化学习; 灰狼优化算法; 最小二乘支持向量机

中图分类号: U491

文献标志码: A

Prediction Method of EV Charging Demand Power Based on Reinforcement Learning and Variable Weight Combination Model

SONG Zongren¹, GE Quanbo^{2,3,4}, LI Chunxi⁵

(1. Logistics Engineering College, Shanghai Maritime University, Shanghai 201306, China; 2. College of Automation, Nanjing University of Information Science and Technology, Nanjing 210044, China; 3. Jiangsu Provincial University Key laboratory of Big Data Analysis and Intelligent Systems, Nanjing 210044, China; 4. Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology (CICAET), Nanjing 210044, China; 5. School of Automotive Technology, Zhejiang Technical Institute of Economics, Hangzhou 310018, China)

Abstract: When an electric vehicle (EV) is connected to a charging pile, it is very important to accurately predict the charging demand power of the battery pack of the EV to prevent the battery pack from being overcharged. Due to the complexity of the physical model of battery pack, it is usually difficult to build a power prediction method based on it, and its real-time performance is not high. In addition, the prediction accuracy of a single prediction model is low. Aiming at the above problems, combining charging data with machine learning, this paper proposes an EV charging demand power prediction method based on reinforcement learning (RL) and variable weight combination model. Firstly, based on the traditional grey

wolf optimization (GWO) algorithm, chaos mapping and elite reverse learning strategy are combined to improve the quality of the initial population, and the dynamic weight strategy of reinforcement learning is used to update the individual position of grey wolf to optimize the parameters in the least square support vector machine (LSSVM) algorithm. Then, the weights of the extreme learning machine prediction model and the improved LSSVM prediction model are reasonably distributed by the variable weight combination method based on time-varying weight distribution, so as to solve the shortcomings of the single prediction model method. Finally, the actual charging data of electric vehicles are used to verify the proposed prediction algorithm. Compared with the other three traditional methods, the prediction accuracy of the new method is improved by 4.75%, 3.84% and 0.38%, respectively.

Key words: charging demand power; variable weight combination; reinforcement learning (RL); grey wolf optimization (GWO) algorithm; least square support vector machine (LSSVM)

引 言

随着电动汽车的普及,动力电池的充电安全已引起学术界和工业界的广泛关注。实际应用中,电动汽车(Electric vehicle, VE)的电池管理系统(Battery management system, BMS)主要负责动力电池的数据采集、状态监测、充电策略管理以及信息管理,其中状态监测能够反映电池在充电过程中工作状态,充电策略管理能够实时对充电电流、充电电压或充电功率进行合理控制。针对电动汽车动力电池组的充电安全,研究人员从荷电状态(State of charge, SOC)及健康状态(State of health, SOH)这两个方面进行研究, SOC反映电动汽车充电进度的快慢,但衡量电池组是否发生过充上有所欠缺; SOH表示电池组的健康情况,其值主要与电池的老化以及温度相关,而电池的老化通常难以定量分析,导致系统难以判断电池组是否发生过充。防止电池组发生过充的关键在于合理控制电动汽车的充电功率,而充电功率是由BMS中的充电需求功率所决定,因此充电需求功率是充电安全问题的源头,从问题的源头出发更有利于防止因过充造成电池组损伤。

针对电动汽车充电安全问题,通过比较充电需求功率预测值与BMS提供的值,选取最佳充电功率值来提升充电安全策略,可确保动力电池组在充电时处于安全稳定的状态。由于电池高度非线性特征,电池充电工况中的复杂变化以及容量的衰减、环境温度等不确定因素,使得准确预测电池的充电功率具有较大的挑战性^[1]。

目前,大多数研究人员从电池单体或由少量电池单体组成的电池组的充电功率角度出发,得出准确的充电功率进而确定安全充电策略,其研究内容主要集中在两个方面:一方面是提高电池自身模型构建的准确性,另一方面是改进电池充电功率的智能预测方法^[2]。文献[3-5]通过利用等效电路或电化学模型与约束条件建立动态电池充电功率估计模型。基于物理或电化学的电池模型能够有效模拟电池的稳态和动态响应特性,但通常计算量较大无法满足电动汽车BMS的实时性要求^[6]。文献[7-11]提出利用数据驱动模型估计动力电池组的充电功率,但仅考虑了影响电池充电功率的单一因素。文献[12]通过利用灰狼优化(Grey wolf optimization, GWO)算法对电池充电功率进行预测,有效得出较为准确的充电功率值,但该方法仅考虑了温度与充电功率之间的关系,忽略了其他因素对充电功率的影响。文献[13-14]将电池电压、电流、温度作为神经网络模型的输入参数,充电功率作为输出参数构建预测模型;文献[15]使用长短期时间记忆网络建立电池功率的预测模型,选取温度、SOC以及内阻为模型输入量,充电功率为预测模型的输出量,得出误差较小的充电功率预测模型,但训练时间过长,对此提出多对一结构的长短期时间记忆网络。通过数据驱动方法建立动力电池最佳充电功率模型时,需要从两个

方面进行:(1)选取影响充电功率的主要因素;(2)选取合适的模型以提高充电功率预测精度。

通过分析现有文献可知,现有方法对影响充电功率的因素考虑不够全面,缺乏从充电需求功率的角度制定合理的充电安全策略。虽然电池的充电功率由BMS提供,但其值由充电需求功率决定,故电池充电需求功率预测的准确性可帮助BMS获取最佳的充电功率。如何准确地获取最佳充电功率值以及提高充电需求功率预测精度是研究的重点,传统基于数据驱动模型的动力电池最佳充电功率的预测框架,如图1所示。针对预测动力电池组的充电需求功率,由于充电桩运营管理平台难以准确获取动力电池充电需求功率直接相关的数据,而以电动汽车实时充电报文数据为基础,利用数据驱动模型可间接得出电动汽车动力电池组的充电需求功率值。故本文以电动汽车充电数据为基础,提出基于多机器学习的组合模型与智能优化算法相结合的电池组充电需求功率预测方法。

该方法的优势为:(1)利用混沌映射与精英反向学习策略对GWO算法的初始种群进行优化,提高了算法初始种群的质量;(2)将最小二乘支持向量机(Least square support vector machine, LSSVM)神经网络与基于欧氏距离的非线性参数变化与强化学习改进的GWO算法结合,提高了GWO算法的全局搜索能力与收敛速度;(3)将LSSVM与极限学习机(Extreme learning machine, ELM)预测模型进行变权组合,从充电数据中充分挖掘出与充电需求功率相关的特征。

1 研究动机及解决方案

文献[14]利用传统BPNN神经网络作为预测模型易出现局部最优解的问题,文献[15]采用多输出结构的长短期时间记忆网络,但在面对多特征数据时训练时长增加、计算更为复杂,且两者的预测精度较差。因此,提出一种基于强化学习与变权组合模型的EV充电需求功率预测方法,该预测方法主要表现为以下4个方面:

(1)传统单一预测模型在面对多特征向量作为输入参数时会导致模型预测精度欠缺的问题,提出利用时变权重分配策略对各个单一预测模型进行变权组合。由BMS收集到的充电数据包含着影响充电需求功率的多种因素,而利用单一预测模型难以准确获取与充电需求功率密切相关的成分;通过利用两种或两种以上的预测模型进行有效组合,可更准确地获取充电数据中的有效信息。而传统组合模型并没有考虑组合权重的实时性,为了使模型权重能够变化更新,使用有序加权几何平均算子对权重进行实时分配,不仅可有效发挥各个单一预测模型本身获取有效信息的优势,还可提高预测精度。

(2)传统GWO在优化LSSVM的超参数时,算法的初始化种群往往是随机产生的,并且分布不均匀,种群中的优秀个体质量也不足,导致寻优性能降低。通过利用混沌映射策略对初始化的种群进行映射,产生个体分布更为均匀的初始化种群。为了增加算法初始种群中的优良个体,在混沌映射策略的基础上,结合精英反向学习策略对种群中的优良个体进行排序选取,构成具有良好均匀性、高质量性的初始种群。

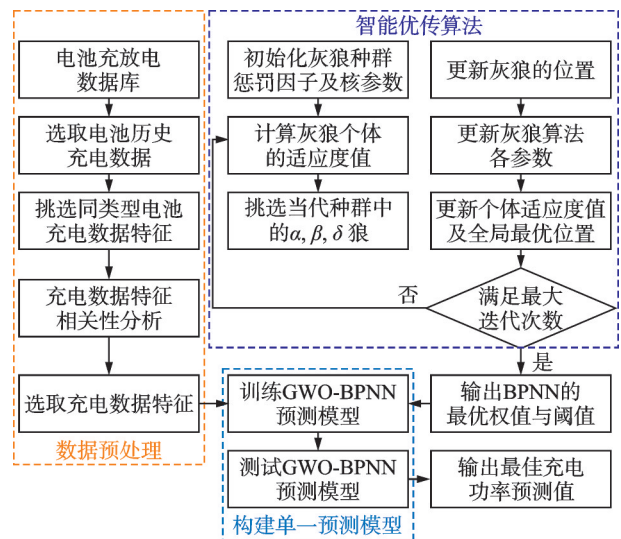


图1 传统基于数据驱动的充电功率预测框架

Fig.1 Traditional charging power prediction framework based on data driven

(3) 传统GWO中的距离控制参数呈现线性变化导致算法难以平衡全局搜索与局部开发的问题,提出一种基于欧氏距离的非线性变化参数。距离控制参数的变化影响算法前期全局搜索能力以及后期局部开发能力,而参数的线性变化难以平衡全局与局部之间的搜索开发能力。利用种群个体与历史最优位置之间的距离变化判断解的分布,通过解的分布选取距离控制参数,使得算法具有良好的全局搜索与局部开发能力。非线性变化的距离控制参数在迭代过程中以不定的速率递减,在迭代前期参数减小缓慢,使得距离控制参数能够保持在较大值内一段时间,有利于算法的全局搜索;在迭代后期距离控制参数减小较快,使得距离控制参数处于一段时间内的较小值,有利于算法的局部开发。因此,利用欧氏距离的非线性变化参数能够较好地达到协调算法全局搜索与局部开发能力的目的。

(4) 针对灰狼优化算法中采用同等权重更新灰狼个体位置可能导致算法容易陷入局部最优的问题,提出利用强化学习与离心距离变化率相结合的方法确定动态权重值。传统灰狼个体的位置是通过领头狼位置的平均值进行更新,并没有考虑领头狼位置之间的优劣性,使算法的勘探寻优效率欠缺。利用离心距离变化率判断领头狼位置之间的优劣程度,进而通过变化率的大小分配领头狼的初始权重。虽然离心距离变化率能够反映领头狼之间的优劣,但其初始权重并不是最佳组合,而利用强化学习的性质能够获取分配到领头狼之间的最佳权重组合。故基于强化学习的动态权重策略更新灰狼个体位置,能够使得算法获取全局最优解,更好地提高算法的寻优效率。

本文基于强化学习与变权组合模型的充电需求功率预测方法主要分为3个模块:改进的GWO-LSSVM预测模块、基于强化学习的GWO模块以及多机器学习的变权组合模块,其电动汽车充电需求功率的预测框图,如图2所示。本方法的主要贡献在于:

(1) 针对单一预测模型无法充分挖掘与充电需求功率相关特征,导致预测精度较低,针对这一问题,提出一种ELM与LSSVM的变权组合的预测模型。

(2) 针对传统GWO算法初始化种群中个体分布不均、优良个体欠缺的问题,提出多策略融合方法优化初始化种群。

(3) 针对GWO算法中线性变化的距离控制参数难以协调全局搜索与局部开发能力的问题,提出基于欧氏距离的非线性变化参数。

(4) 针对GWO算法中同等权重的灰狼个体位置更新可能出现局部最优的问题,提出一种基于强化学习的最佳动态权重分配策略。

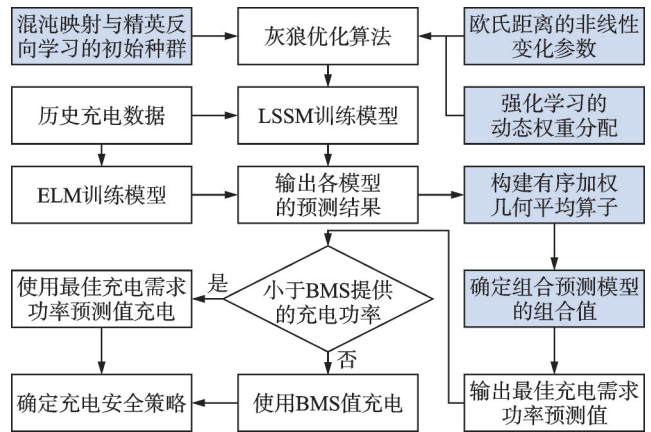


图2 电动汽车充电需求功率预测框图

Fig.2 Block diagram of electric vehicle charging demand power prediction

2 改进的GWO-LSSVM优化模型

2.1 GWO-LSSVM算法

LSSVM为SVM算法的进一步改进,其有着简单高效且运算速度较快的优点,通过将非线性样本映射至高维空间,能较好地处理动力电池组的充电需求功率预测这类高维非线性问题^[16]。考虑到LSSVM神经网络对充电需求功率的预测需要选取合适的超参数,即惩罚因子 γ ^[17]与核函数参数 σ ^[18],通过采用群体智能优化算法确定最优超参数,从而提高LSSVM的学习能力。相较于其他优化算法,采用的灰狼优化算法具有更强的搜索能力与更快的搜索速度^[19],GWO优化LSSVM算法的具体流程如图3所示^[20]。

传统GWO优化LSSVM算法的具体步骤为:

(1) 初始化灰狼种群、设置GWO的初始参数以及LSSVM算法中的惩罚因子与核参数值。

(2) 依据适应度值选取当代灰狼种群中领头狼的 α 、 β 、 δ ,根据GWO算法中的位置更新公式更新各灰狼个体的位置,并更新距离控制参数 $a(t)$ 以及振荡因子 A 、 C 。

(3) 根据灰狼个体的适应度值选择优良个体并获取更新全局最优位置。

(4) 判断是否满足最大迭代次数 T_{max} ,若满足则输出LSSVM算法中惩罚因子与核参数的最优值,并赋予至LSSVM模型中;若不满足则返回步骤2直至满足条件。

传统GWO算法中主要存在以下缺点:随机初始化种群,存在降低种群多样性与质量的风险;在面对实际优化问题时,线性距离控制参数 a 的更新可能会导致算法陷入局部最优;根据领头狼 α 、 β 、 δ 的位置找寻猎物最优位置时,缺乏 α 、 β 、 δ 位置之间的共享程度,可能会降低灰狼的搜索能力。

2.2 基于强化学习的GWO算法

文献[20]涉及传统GWO算法中的初始化种群是随机产生的,为了增强初始种群的多样性与质量,利用具有遍历性、不重复性等特点的分段混沌理论^[21],使得初始种群个体尽可能地在搜索空间中分布均匀,结合精英反向学习策略提高初始种群质量,从而提高GWO算法优化LSSVM参数的寻优性能。分段混沌映射初始种群的计算公式为

$$X(t) = \begin{cases} \frac{X(t-1)}{p} & 0 \leq X(t-1) < p \\ \frac{X(t-1)-p}{0.5-p} & p \leq X(t-1) < 0.5 \\ \frac{1-p-X(t-1)}{0.5-p} & 0.5 \leq X(t-1) < 1-p \\ \frac{1-X(t-1)}{p} & 1-p \leq X(t-1) < 1 \end{cases} \quad (1)$$

式中: p 的取值为0.4^[22], $X(t-1)$ 为第 $t-1$ 代未混沌的灰狼个体位置, $X(t)$ 为混沌后第 t 代的灰狼个体位置。由精英反向定义^[22]可知,其反向解表达式为

$$X_j^*(t) = k[a_j(t) + b_j(t)] - X_j(t) \quad (2)$$

式中: $X_j^*(t)$ 为 $X_j(t)$ 在 j 维搜索空间中第 t 代灰狼个体的反向解, $a_j(t)$ 、 $b_j(t)$ ($j=1,2,\dots,J$)分别为 j 维搜索空间中的上下界, k 为0至1之间的随机数。通过将适应度函数 $f[X_j^*(t)]$ 与 $X_j^*(t)$ 联系,比较 $f[X_j^*(t)]$ 与 $f[X_j(t)]$ 之间的值,对适应度值进行降序排列,保留前 N 个值构成初始种群。

传统GWO算法的搜索与开发能力受到振荡因子 A 的影响,而振荡因子 A 的取值依赖于距离控制参数 $a(t)$ 的变化。由于在文献[20]中的距离控制参数 $a(t)$ 为线性变化,导致GWO算法难以保证平衡其全局搜索与局部开发能力,并且线性递减的距离控制参数 $a(t)$ 并不能完全反映实际的优化搜索过程。为了增大算法前期的全局搜索能力,增强算法后期的局部开发能力,在文献[20]的基础上提出一种基于欧氏距离的非线性变化距离控制参数 $a(t)$ ^[23]。通过所提出的基于欧氏距离的非线性变化距离

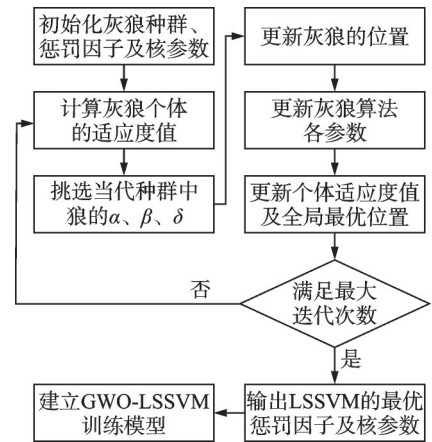


图3 GWO优化LSSVM流程图

Fig.3 GWO optimization LSSVM flow-chart

控制参数 $a(t)$, 计算并更新灰狼与猎物间的控制距离 D , 表达式为^[20]

$$D = |CX_q(t) - X(t)| \tag{3}$$

$$X(t+1) = X_q(t) - AD \tag{4}$$

$$A = 2a(t)r_1 - a(t) \tag{5}$$

$$C = 2r_2 \tag{6}$$

其中, 更新公式中距离控制参数 $a(t)$ 的表达式为

$$a(t) = \begin{cases} 1 + \left[\frac{\cos(t-1)\pi}{T_{\max} - 1} \right]^d & t \leq \frac{T_{\max}}{2} \\ 1 - \left[\frac{\cos(t-1)\pi}{T_{\max} - 1} \right]^d & \frac{T_{\max}}{2} \leq t \leq T_{\max} \end{cases} \tag{7}$$

$$\begin{cases} D_{\min} = \min_{t=1,2,\dots,T_{\max}} \left(\sqrt{\sum_{j=1}^J (X_{tj} - X_j)^2} \right) \\ D_{\text{avg}} = \frac{\sum_{t=1}^{T_{\max}} \sqrt{\sum_{j=1}^J (X_{tj} - X_j)^2}}{T_{\max}} \\ d = \frac{D_{\text{avg}} - D_{\min}}{D_{\min}} \end{cases} \tag{8}$$

式中: D_{\min} 为最小欧氏距离, D_{avg} 为平均欧氏距离, X_{tj} 为种群个体的最优位置, X_j 为种群当前最优位置, $X_q(t)$ 为猎物个体的位置, $X(t)$ 为灰狼个体的位置, t 为迭代次数, r_1, r_2 为 0 至 1 之间的随机变量。从式 (7) 以及余弦三角函数的性质可知, 种群迭代前期, d 值较大, 使得式 (5) 中 A 值下降缓慢, 有利于扩大全局搜索范围; 种群迭代后期, d 值较小, 使式 (5) 中 A 保持在小的取值范围内, 提高局部搜索能力。

文献 [20] 中利用 GWO 算法找寻 LSSVM 中最优的惩罚因子以及核参数时, 由于传统 GWO 算法采用同等权重作为灰狼个体的位置更新系数, 但该方式忽略了领头狼 α, β, δ 间的位置优劣关系, 不利于 GWO 算法快速找寻全局最优解。因此, 通过考虑领头狼 α, β, δ 之间的位置优劣关系, 增强灰狼个体的位置更新过程, 提出不同等权重的灰狼个体位置更新方法。当灰狼个体发现猎物时, 在传统 GWO 算法中灰狼个体位置根据领头狼 α, β, δ 的位置进行更新的过程中, 借用粒子群算法的思想^[24-25], 通过将分配至领头狼 α, β, δ 上的不同等权重与灰狼个体间的位置建立联系, 进而达到修正灰狼个体位置的目的。灰狼个体位置的计算表达式为^[20]

$$D_\alpha = |C_\alpha X_\alpha(t) - X(t)| \tag{9}$$

$$D_\beta = |C_\beta X_\beta(t) - X(t)| \tag{10}$$

$$D_\delta = |C_\delta X_\delta(t) - X(t)| \tag{11}$$

$$X_1(t) = X(t) - A_\alpha D_\alpha \tag{12}$$

$$X_2(t) = X(t) - A_\beta D_\beta \tag{13}$$

$$X_3(t) = X(t) - A_\delta D_\delta \tag{14}$$

基于粒子群算法思想的不同等位置权重系数的灰狼个体位置更新表达式为

$$X(t+1) = X(t) + V(t+1) \tag{15}$$

$$V(t+1) = C_\alpha r_3 \omega_\alpha [X_1(t) - X(t)] + C_\beta r_4 \omega_\beta [X_2(t) - X(t)] + C_\delta r_5 \omega_\delta [X_3(t) - X(t)] \tag{16}$$

$$\left\{ \begin{array}{l} D_{\Omega_{\text{avg}}} = \frac{\sum_{t=1}^{T_{\text{max}}} \sqrt{\sum_{j=1}^J (X_{tj} - X_{\Omega})^2}}{T_{\text{max}}} \\ D_{\Omega_{\text{max}}} = \max_{t=1, 2, \dots, T_{\text{max}}} \left(\sqrt{\sum_{j=1}^J (X_{tj} - X_{\Omega})^2} \right) \end{array} \right. \quad \Omega = \alpha, \beta, \delta \quad (17)$$

$$\left\{ \begin{array}{l} \varphi_{\alpha} = \frac{D_{\alpha_{\text{max}}} - D_{\alpha_{\text{avg}}}}{D_{\alpha_{\text{max}}}} \\ \varphi_{\beta} = \frac{D_{\beta_{\text{max}}} - D_{\beta_{\text{avg}}}}{D_{\beta_{\text{max}}}} \\ \varphi_{\delta} = \frac{D_{\delta_{\text{max}}} - D_{\delta_{\text{avg}}}}{D_{\delta_{\text{max}}}} \end{array} \right. \quad (18)$$

$$\left\{ \begin{array}{l} w_{\alpha} = \frac{\varphi_{\alpha}}{\varphi_{\alpha} + \varphi_{\beta} + \varphi_{\delta}} \\ w_{\beta} = \frac{\varphi_{\beta}}{\varphi_{\alpha} + \varphi_{\beta} + \varphi_{\delta}} \\ w_{\delta} = \frac{\varphi_{\delta}}{\varphi_{\alpha} + \varphi_{\beta} + \varphi_{\delta}} \end{array} \right. \quad (19)$$

式中： φ_{α} 、 φ_{β} 、 φ_{δ} 分别为领头狼 α 、 β 、 δ 的离心距离变化率， $D_{\Omega_{\text{max}}}$ 为最大离心距离， $D_{\Omega_{\text{avg}}}$ 为平均离心距离， X_{Ω} 为领头狼的当前最优位置， w_{α} 、 w_{β} 、 w_{δ} 分别为分配至领头狼 α 、 β 、 δ 上的不同等权重系数， r_3 、 r_4 、 r_5 为0至1之间的随机变量。虽然不同的权重能够反映领头狼之间的位置优劣关系，但并没有分析领头狼之间的位置共享程度，分配至领头狼的权重值并不是最优的。故利用强化学习算法对权重值进行优化，通过设置奖惩策略获得最佳的权重组合，提高GWO算法的寻优能力，提高算法的收敛速度。

强化学习主要部分包括环境、智能体、状态、行动以及奖励，是智能体通过观察环境获得状态，采取行动以获得奖励，基于环境执行下一个状态，进而使得策略具有最大回报^[26]。Q学习算法是强化学习中使价值函数最优的学习策略，利用智能体反复探索累积值函数以使Q最大化，可表示为^[26]

$$g(s, a) = \operatorname{argmax} Q(s, a) \quad (20)$$

式中： $g(s, a)$ 为给定状态 s 与动作 a 的最优策略，在已知状态 s 后，用于选择未来动作的表达式为^[27]

$$Q^{\text{new}}(s_t, a_t) = Q(s_t, a_t) + \alpha [R(s_t, a_t) + \lambda \max Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)] \quad (21)$$

式中： $Q(s_t, a_t)$ 为 t 次迭代时的累积Q值， $R(s_t, a_t)$ 表示奖励值， α 为学习率， λ 为折扣因子， $Q^{\text{new}}(s_t, a_t)$ 表示更新的Q值， $\max Q(s_{t+1}, a_{t+1})$ 为最优未来值，其结构框图如图4所示^[28-29]。

通过上述介绍，提出基于Q-Learning算法的最佳权重组合方法，具体步骤如下：

(1) 初始化Q代理参数，包括状态 S 与动作 a ，其中状态矩阵 $S = [w_{\alpha}, w_{\beta}, w_{\delta}]$ ，动作矩阵 $a = [\Delta w_{\alpha}, \Delta w_{\beta}, \Delta w_{\delta}]$ ， Δw_{α} 、 Δw_{β} 、 Δw_{δ} 分别为智能体对领头狼 α 、 β 、 δ 的权值调整。

(2) 分别建立误差计算式 E_t 和奖励 R 表达式，即

$$E_t = \sqrt{\frac{1}{N} \sum_{t=1}^N [Y_T(t) - Y_P(t)]^2} \quad (22)$$




图4 强化学习结构框图^[28-29]

Fig.4 Reinforcement learning structure block diagram^[28-29]

$$R = \begin{cases} +1 + E_t - E_{t+1} & E_{t+1} \leq E_t \\ -1 + E_t - E_{t+1} & E_{t+1} > E_t \end{cases} \quad (23)$$

$$r_t = R(S_t, a_t) \quad (24)$$

式中: $Y_T(t)$ 为真实值, $Y_P(t)$ 为预测值。

(3) 由 ϵ -贪心策略选 a 值, 选择式为^[30-31]

$$a = \begin{cases} \text{最大动作值 } Q_{\max} & \text{动作概率为 } 1 - \epsilon \\ \text{任意动作值 } Q & \text{动作概率为 } \epsilon \end{cases} \quad (25)$$

式中勘探概率 ϵ 为 0 至 1 之间的随机数。

(4) 根据误差计算公式与奖励表达式, 计算误差值与奖励值并更新 Q 表, 其表达式为

$$Q_{t+1}(S_t, a_t) = Q(S_t, a_t) + \alpha [R(S_t, a_t) + \lambda \max Q(S_{t+1}, a_{t+1}) - Q(S_t, a_t)] \quad (26)$$

(5) 重复步骤 3 与步骤 4, 直到满足停止条件, 最终状态 S 为最佳权值。

3 基于 ELM 与改进 LSSVM 的变权组合预测模型

虽然 LSSVM 算法能够较好处理非线性问题, 但无法从充电数据中充分挖掘与充电需求功率相关的充电特征。ELM 常被用于处理这类复杂非线性系问题^[32]。与传统的反向传播神经网络(Back propagation neural network, BPNN)模型相比, ELM 具有计算复杂度低、泛化能力好等优点^[33-34], 但 ELM 训练前, 对输入层与隐含层之间的连接权重与偏差都是随机分配参数, 这在一定程度上会使得 ELM 的预测精度并不能满足要求。通过对 ELM 与 LSSVM 神经网络模型的表述可知, 两者都可预测充电需求功率, 但各个模型有各自的优点及不足。为了更好发挥各个模型的优点, 获得更为准确的预测值, 可将各个预测模型的优点进行变权组合。本文利用有序加权几何平均算子对预测模型进行权重分配, 提出一种时变权重分配策略的组合方式, 其步骤如下:

(1) 定义单一 ELM 预测模型在 t 时刻的预测精度 a_{1t} 以及单一改进 LSSVM 预测模型在 t 时刻的预测精度 a_{2t} 分别为^[35]

$$a_{1t} = \begin{cases} 1 - \left| \frac{y_t - y_{1t}}{y_t} \right| & \left| \frac{y_t - y_{1t}}{y_t} \right| < 1 \\ 0 & \left| \frac{y_t - y_{1t}}{y_t} \right| \geq 1 \end{cases} \quad (27)$$

$$a_{2t} = \begin{cases} 1 - \left| \frac{y_t - y_{2t}}{y_t} \right| & \left| \frac{y_t - y_{2t}}{y_t} \right| < 1 \\ 0 & \left| \frac{y_t - y_{2t}}{y_t} \right| \geq 1 \end{cases} \quad (28)$$

式中: y_t 为充电需求功率真实值, y_{1t} 为 ELM 预测值, y_{2t} 为 LSSVM 预测值。

(2) 依据有序加权几何平均算子的定义^[36] 获得由组合模型预测值与预测精度构成的诱导变量

$$f_w(\langle a_{1t}, y_{1t} \rangle, \langle a_{2t}, y_{2t} \rangle) = \prod_{i=1}^2 y_{\max(it)}^{w_i} \quad (29)$$

式中: $\max(it)$ 表示集合 $\{a_{1t}, a_{2t}\}$ 中最大预测精度的下标, $y_{\max(it)}$ 为诱导变量 $\max(it)$ 对应的预测值,

$w_i = (w_1, w_2)^T$ 为 f_w 相关的权重, 且满足 $\sum_{i=1}^2 w_i = 1, w_i \in [0, 1]$ 。

(3) 计算在 t 时刻的组合预测的预测误差为

$$e_{\max(it)} = \ln y_t - \ln y_{\max(it)} \quad (30)$$

(4) 计算 T 时间段内的预测误差平方和为^[36]

$$S = \sum_{i=1}^2 \sum_{j=1}^2 \tau w_i \tau w_j \sum_{t=1}^T e_{\max(it)} e_{\max(jt)} \quad (31)$$

(6) 通过求解 T 时间段内的预测误差平方和的最小值, 获得两个预测模型的权重系数

$$\begin{aligned} \min(S) &= \sum_{i=1}^2 \sum_{j=1}^2 \tau w_i \tau w_j \sum_{t=1}^T e_{\max(it)} e_{\max(jt)} \\ \text{s.t.} &\begin{cases} \sum_{i=1}^2 \tau w_i = 1 \\ \tau w_i \geq 0 \quad i = 1, 2 \end{cases} \end{aligned} \quad (32)$$

4 算法分析

本文算法是针对电动汽车动力电池组的充电需求功率的研究, 由于动力电池组的充电需求功率可通过电动汽车的需求充电电流以及需求充电电压表示, 因此利用电动汽车的充电数据作为研究对象。考虑到动力电池组的充电需求功率受到充电温度、充电电压、充电电流、SOC、SOH 以及单体不一致等因素的影响, 难以通过建立动力电池组的等效电路模型、电化学模型, 以及单一预测模型难以完全充分挖掘出多种充电特征与充电需求功率之间的关系, 结合 ELM 与 LSSVM 算法两者的优点进行组合, 利用组合的数据驱动模型来预测动力电池组的充电需求功率。面对 LSSVM 算法中参数选取的问题, 利用改进的 GWO 算法对参数进行寻优。基于强化学习与变权组合模型的原理框图如图 5 所示。

本文主要创新点表现在将 LSSVM 算法与改进的 GWO 算法相结合。首先, 提出利用混沌映射与精英反向学习策略选取前 N 个适应度值较好的灰狼个体构建 GWO 算法的初始种群, 获取较优的初始种群, 解决传统 GWO 算法中初始种群质量欠缺且分布不均匀的问题; 其次, 提出一种欧氏距离与余弦函数相结合的距离控制参数 $a(t)$, 平衡算法的全局与局部搜索能力; 最后, 提出基于强化学习与粒子群思想的不同等权重系数 $w_\alpha, w_\beta, w_\delta$, 解决了传统 GWO 算法易陷入局部最优的问题, 提高 GWO 算法的寻优速度。为解决单一预测模型预测效果欠缺的问题, 提出利用有序加权算子构建 ELM 与 LSSVM 的变权组合预测模型, 避免多特征因素影响预测模型的精度。本文提出的变权组合预测模型同样适用于其他相似场景下的预测, 同时强化学习与 GWO 算法相结合的方法也适用于其他神经网络的参数寻优。

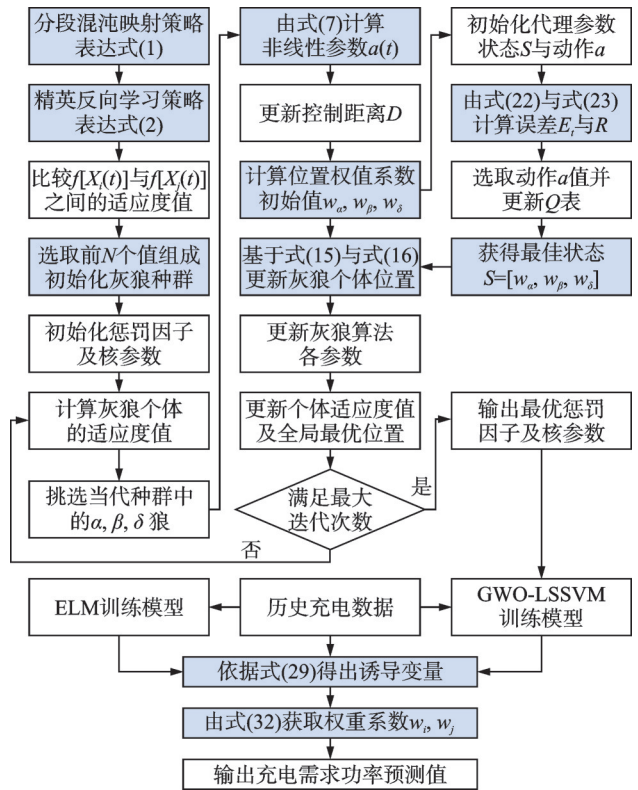


图 5 基于强化学习与变权组合模型原理框图

Fig.5 Block diagram of reinforcement learning and variable weight combinatorial model

5 仿真与结果分析

5.1 数据集介绍及预处理

为了验证所提基于强化学习与变权组合模型的电动汽车充电需求功率预测方法的可靠性,采用杭州某电动汽车充电运营商数据库中的电动汽车实际充电报文数据进行分析,其充电报文数据来自杭州某充电运营服务商公司,到目前为止,公司累计充电次数为300多万次,累计充电量为6000多千瓦时,累计为13多万的电动汽车用户提供充电服务,累计充电桩为1400多台。该公司自2016年起开始运营电动汽车充电桩,在浙江、广东、江苏、上海等地设有充电站;其采用的充电桩型号主要有永联YLCE-120750和英飞IDS210K750D-X5等。充电桩采用充电国标GB/T 27930—2015与车辆BMS系统进行通信,实现与电动汽车BMS系统之间的报文交互,并且通过CAN总线采集到充电报文后,会将报文信息打包,通过以太网传输至公司的充电安全监控平台,形成了电动汽车充电数据库。

BMS报文中不仅包含动力电池组的容量、型号以及循环次数等信息,还包含SOC、充电时间、充电时长、充电电压、充电电流、最高单体电压、电池最高和最低温度等信息。这些信息会在每次充电启动时上传给充电桩,随后由充电桩上传至云端充电安全监控平台。本文研究数据就来源于该云端充电安全监控平台,考虑到电动汽车充电用户的充电随机性,难以找到从SOC为0充到100%的数据,故从公司数据库中挑选了充电频率较高且起止SOC相差较大的电动汽车充电数据作为基本数据源,但数据中仍然会出现SOC值不连续的情况。

因此,利用K-means插值法对缺失值进行补全。由于充电数据由BMS依据SOC进行控制,可以根据同类型车辆用户的SOC历史数据进行K-means插值,其横坐标为SOC,纵坐标为插入值。簇类中心 u 的表达式为^[37]

$$u = \arg \min_u \sum_{i=k} \|x_i - u\|^2 \tag{33}$$

式中 x_i 为充电样本。簇类中心的纵坐标表示缺失的充电数据。随后,将补全后的充电数据进行归一化处理,其中充电数据包括充电电流、充电电压、最高单体电压、最高温度、最低温度、SOH以及SOC值等作为预测模型的输入数据。预测模型需要输出的特征如表1所示。

表1 PSO-ELM、PSO-LSSVM、GWO-LSSVM与本文算法的输出特征

Table 1 Output characteristics of PSO-ELM, PSO-LSSVM, GWO-LSSVM and the proposed algorithm

预测模型	输入特征	输出特征
PSO-ELM	充电电流、充电电压、电池组温度、SOC、SOH	充电需求功率
PSO-LSSVM	充电电流、充电电压、电池组温度、SOC、SOH	充电需求功率
GWO-LSSVM	充电电流、充电电压、电池组温度、SOC、SOH	充电需求功率
本文算法	充电电流、充电电压、电池组温度、SOC、SOH	充电需求功率

本文GWO算法初始参数的选择参考了文献[25]的参数设置,GWO算法中的相关参数设置如下:种群规模 $N=50$,最大迭代次数 $T_{max}=30$,空间的上界 u_a 的取值范围为 $[1000,100]$,空间的下界 l_b 的取值范围为 $[0.1,0.01]$;LSSVM中惩罚因子 γ 的初始值为10,核参数 σ 的初始值为100。

5.2 预测结果分析

在预处理后的数据中,选择同类型车辆充电总数据的60%作为训练集,40%作为验证集。为了更好地验证所提算法的性能,选取不同算法进行比较,并采用均方根误差(RMSE)、决定系数(R_2)以及平均绝对百分比误差(MAPE)作为评价指标,对比结果分别如图6~13所示。图6和图7分别为利用相同的

粒子群优化算法 (Particle swarm optimization, PSO) 对 ELM、LSSVM 进行寻优而后用于预测充电需求功率的结果。图 8 为使用 GWO 算法优化 LSSVM 后的充电需求功率预测结果, 图 9 为本文所提算法的充电需求功率预测结果。图 10~12 分别为采用 PSO 算法对 ELM、LSSVM 优化的预测误差对比, 以及采用 GWO 算法优化 LSSVM 的预测误差对比。图 13 为不同方法下的充电需求功率预测误差对比。

由图 6~8 的预测结果与图 9 的预测结果进行对比分析可看出, 所提出模型算法的预测表现最好, 并且预测误差相对较小; 由图 11 的预测误差以及图 12 的预测误差对比可知, PSO-LSSVM 的预测性能优于 PSO-ELM 的预测性能; 由图 12 的预测误差以及图 13 的预测误差进行对比分析, 可得出所提模型的预测性能比 GWO-LSSVM 的预测性能更好, 预测误差更小。本文通过对 GWO 进行改进, 并对

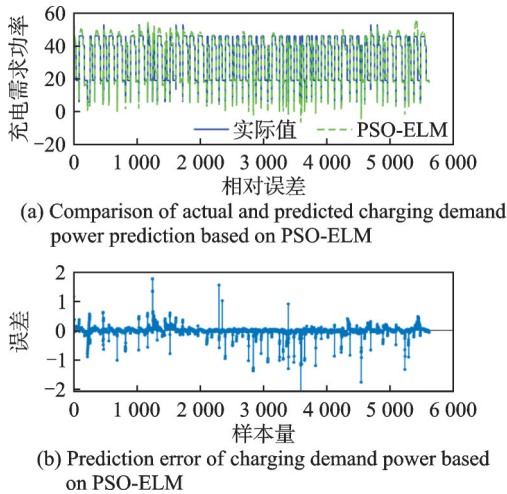


图 6 基于 PSO-ELM 的充电需求功率预测

Fig.6 Prediction of charging demand power based on PSO-ELM

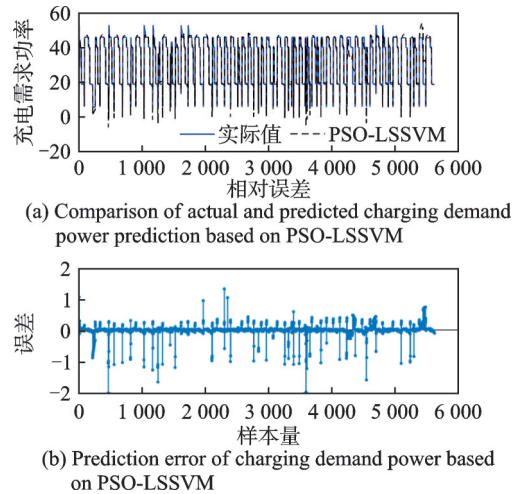


图 7 基于 PSO-LSSVM 的充电需求功率预测

Fig.7 Prediction of charging demand power based on PSO-LSSVM

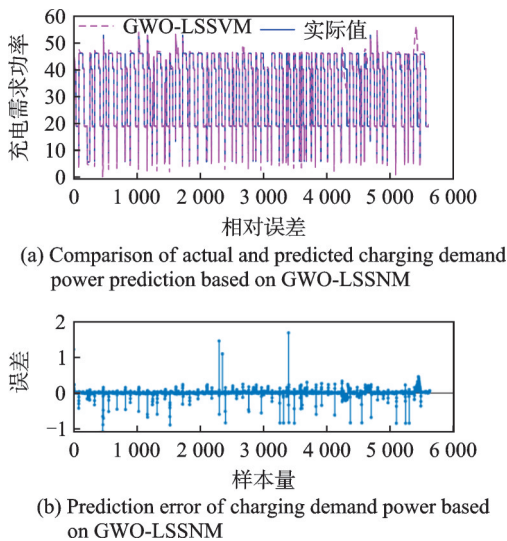


图 8 基于 GWO-LSSVM 的充电需求功率预测

Fig.8 Prediction of charging demand power based on GWO-LSSVM

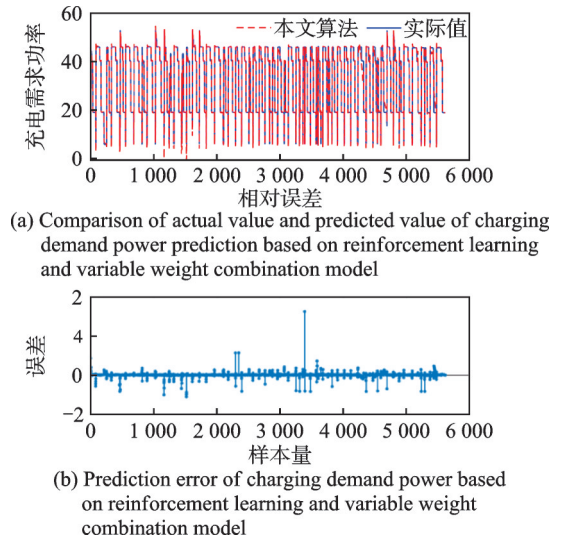


图 9 基于强化学习与变权组合模型的充电需求功率预测

Fig.9 Prediction of charging demand power based on reinforcement learning and variable weight combination model




图10 PSO-ELM与本文算法的充电需求功率预测误差对比

Fig.10 Comparison of charging demand power prediction error between PSO-ELM and the proposed algorithm




图11 PSO-LSSVM与本文算法的充电需求功率预测误差对比

Fig.11 Comparison of charging demand power prediction error between PSO-LSSVM and the proposed algorithm

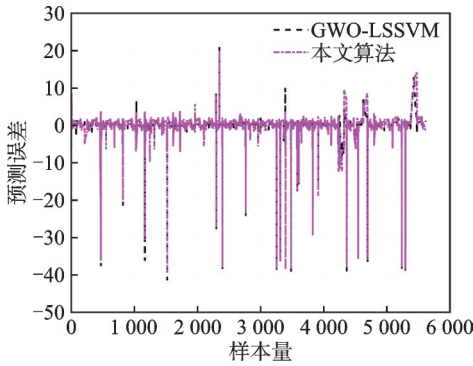


图12 GWO-LSSVM与本文算法的充电需求功率预测误差对比
Fig.12 Comparison of charging demand power prediction error between GWO-LSSVM and the proposed algorithm

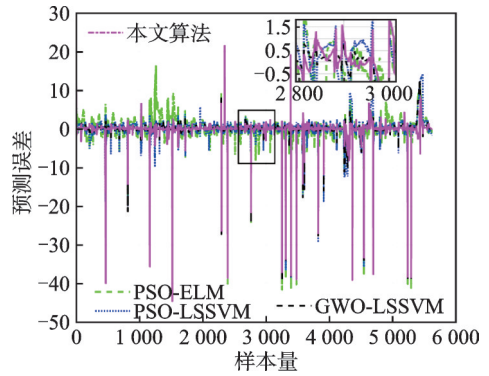


图13 不同方法下的充电需求功率预测误差对比
Fig.13 Comparison of charging demand power prediction error under different methods

LSSVM算法中的参数进行寻优,其最优的惩罚因子 γ 为845.257 1,最优核参数 σ 为6.509 6。相较于直接利用GWO对LSSVM算法寻优,在寻优上有很大的提升,寻优进化曲线如图14所示。各个算法预测性能的评价指标如表2所示。由表2可知,本文所提模型算法中均方根误差相较于PSO-ELM算法、




图14 寻优进化对比

Fig.14 Comparison of evolutionary search for excellence

表2 PSO-ELM、PSO-LSSVM、GWO-LSSVM与本文算法评价对比

Table 2 Evaluation comparison of PSO-ELM, PSO-LSSVM, GWO-LSSVM with the proposed algorithm

算法	RMSE	R_2	MAPE/%
PSO-ELM	3.202 9	0.947 26	7.386 5
PSO-LSSVM	3.080 2	0.950 13	6.477 6
GWO-LSSVM	2.513 7	0.966 69	3.019 0
本文算法	2.238 6	0.973 19	2.635 6

PSO-LSSVM算法以及GWO-LSSVM算法都要小,所提模型算法中决定系数相较于PSO-ELM、PSO-LSSVM、GWO-LSSVM算法均大。

6 结束语

本文提出了基于强化学习和变权重组合模型的EV充电需求功率预测方法,通过仿真和对比,验证了算法的有效性。为了提高算法的预测精度,采用时变权重组合方法将ELM和LSSVM相结合。由于LSSVM算法涉及参数的选择,本文将强化学习与GWO算法相结合来寻找LSSVM算法的最优参数。通过与PSO-ELM、PSO-LSSVM及GWO-LSSVM算法对比,提出的预测算法具有更高的预测精度,在RMSE、 R_2 以及MAPE这3个指标上都优于其他3种方法。但本文没有考虑电池组中电芯的不一致性,电芯内的化学变化易受环境因素影响,内阻变化不一致且难以获取等影响,可能对充电需求功率的预测结果产生一定的影响,在后续的研究中将会考虑这一因素。

参考文献:

- [1] 潘思源. 基于数据驱动的锂离子电池状态估计及SOP研究[D]. 青岛:青岛科技大学, 2023.
PAN Siyuan. Lithium-ion battery state estimation and SOP research based on data driven[D]. Qingdao :Qingdao University of Science and Technology, 2023.
- [2] 彭思敏,徐璃. 锂离子电池功率状态预测方法综述[J]. 机械工程学报, 2022, 58(20): 361-378.
PENG Simin , XU Li. Overview of state of power prediction methods for lithium-ion batteries[J]. Journal of Mechanical Engineering, 2022, 58(20): 361-378.
- [3] 刘子豪,张雪松,林达. 基于扩展卡尔曼滤波的储能电池能量和功率状态联合估计方法[J]. 储能科学与技术, 2023, 12(3): 913-922.
LIU Zihao, ZHANG Xuesong, LIN Da. Joint energy and power state estimation method for energy storage battery based on extended Kalman filter[J]. Energy Storage Science and Technology, 2023, 12(3): 913-922.
- [4] 李文倩. 基于多新息 Kalman 方法的锂电池状态估计[D]. 青岛:青岛大学, 2021.
LIU Wenqian. State estimation of lithium battery based on multi-neo-interest Kalman method[D]. Qingdao :Qingdao University of Science and Technology, 2021.
- [5] 黄敬源. 基于锂电池电化学模型功率状态估计的模型预测方法研究[D]. 成都:西南交通大学, 2022.
HUANG Jingyuan. Study on model prediction method based on power state estimation of lithium battery electrochemical models [D]. Chengdu: Southwest Jiaotong University, 2022.
- [6] 王煜. 车载动力电池功率状态的在线估计[D]. 天津:天津工业大学, 2022.
WANG Yu. Online estimation of power states of on-board power batteries[D]. Tianjin: Tianjin Polytechnic University, 2022.
- [7] 李博豪. 多约束条件下基于数据模型融合的锂离子电池状态多功能估计与分析[D]. 银川:宁夏大学, 2024.
LI Bohao. Analysis of multifunctional estimation of lithium-ion battery state based on data model fusion under multiple constraints[D]. Yinchuan: Ningxia University, 2024.
- [8] RAHIMIFARD S, AHMED R. Interacting multiple model strategy for electric vehicle batteries state of charge/health/power estimation[J]. IEEE Access, 2021, 9: 109875-109888.
- [9] TANG X, WANG Y, YAO K, et al. Model migration based battery power capability evaluation considering uncertainties of temperature and aging[J]. Journal of Power Sources, 2019, 440: 227141.
- [10] HUSSEIN A A. Adaptive artificial neural network-based models for instantaneous power estimation enhancement in electric vehicles' li-ion batteries[J]. IEEE Transactions on Industry Applications, 2019, 55(1): 840-849.
- [11] 李强,张凯旋,袁文文. 基于多时间尺度双扩展卡尔曼滤波的电池峰值功率估计方法[J]. 电工技术学报, 2024, 39(7): 2225-2235.
LI Qiang, ZHANG Kaixuan, YUAN Wenwen. Battery peak power estimation based on dual extended Kalman filtering at

- multiple time scales[J]. Transactions of China Electrotechnical Society, 2024, 39(7): 2225-2235.
- [12] SUN X, XU N, CHEN Q, et al. State of power capability prediction of lithium-ion battery from the perspective of electrochemical mechanisms considering temperature effect[J]. IEEE Transactions on Transportation Electrification, 2023, 9(2): 2453-2463.
- [13] 顾启蒙, 华旻, 潘宇巍, 等. 锂离子电池功率状态估计方法综述[J]. 电源技术, 2019, 43(9): 1563-1567.
GU Qimeng, HUA Yang, PAN Yuwei, et al. Review of state of power estimation methods for lithium-ion battery[J]. Power Technology, 2019, 43(9): 1563-1567.
- [14] 张文博. 电动汽车动力锂离子电池峰值功率研究[D]. 长沙: 湖南大学, 2019.
ZHANG Wenbo. Study of peak power of electric vehicle powered lithium-ion batteries[D]. Changsha: Hunan University, 2019.
- [15] LONG T, WANG S, CAO W, et al. A novel M-1 structured bidirectional long short term memory-rauch tung striebel smoothing algorithm for the joint estimation state of charge and multi-constrained sustained peak power of lithium-ion batteries [J]. Journal of Energy Storage, 2023, 67: 107576.
- [16] MENG J, LUO G, GAO F, et al. Lithium polymer battery state-of-charge estimation based on adaptive unscented Kalman filter and support vector machine[J]. Transactions on Power Electronics, 2016, 31(3): 2226-2238.
- [17] CAI Y, HAO S, WEN X, et al. Short-term power prediction by using least square support vector machine with variational mode decomposition in a photovoltaic system[J]. IEEE Access, 2023, 11: 143486-143500.
- [18] WANG D, XU X, YAO Y, et al. Virtual DVL reconstruction method for an integrated navigation system based on DS-LSSVM algorithm[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-13.
- [19] GE L, XIAN Y, WANG Z, et al. Short-term load forecasting of regional distribution network based on generalized regression neural network optimized by grey wolf optimization algorithm[J]. CSEE Journal of Power and Energy Systems, 2021, 7(5): 1093-1101.
- [20] 马君, 万俊杰. 基于健康特征筛选与GWO-LSSVM的锂电池健康状态预测[J]. 电气技术, 2024, 25(2): 37-44.
MA Jun, WAN Junjie. Prediction of state of health for lithium battery based on health feature screening and GWO-LSSVM[J]. Electrical Engineering, 2024, 25(2): 37-44.
- [21] ZHOU Y, WANG S, XIE Y, et al. Remaining useful life prediction and state of health diagnosis for lithium-ion batteries based on improved grey wolf optimization algorithm deep extreme learning machine algorithm[J]. Energy, 2023, 285: 128761.
- [22] 王鹏晖. 基于多样性增强的麻雀搜索算法研究与应用[D]. 赣州: 江西理工大学, 2023.
WANG Penghui. Research and application of sparrow search algorithm based on diversity enhancement[D]. Ganzhou: Jiangxi University of Technology, 2023.
- [23] 步同杰. 基于改进灰狼算法的啤酒灌装PID液位控制[J]. 包装工程, 2023, 44(21): 245-252.
BU Tongjie. PID liquid level control for beer filling based on improved grey wolf algorithm[J]. Packaging Engineering, 2023, 44(21): 245-252.
- [24] EL-HASNONY I M, BARAKAT S I. Improved feature selection model for big data analytics[J]. IEEE Access, 2020, 8: 66989-67004.
- [25] LI H, LV T, SHUI Y, et al. An improved grey wolf optimizer with weighting functions and its application to unmanned aerial vehicles path planning[J]. Computers and Electrical Engineering, 2023, 111: 108893.
- [26] NIE L, NING Z. A reinforcement learning-based network traffic prediction mechanism in intelligent internet of things[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 2169-2180.
- [27] DABBAGHJAMANESH M, MOEINI A. Reinforcement learning-based load forecasting of electric vehicle charging station using Q-learning technique[J]. IEEE Transactions on Industrial Informatics, 2021, 17(6): 4229-4237.
- [28] HU Z, YU X. Reinforcement learning-based comprehensive learning grey wolf optimizer for feature selection[J]. Applied Soft Computing, 2023, 149: 110959.
- [29] YANG R, LIU H, NIKITAS N, et al. Short-term wind speed forecasting using deep reinforcement learning with improved multiple error correction approach[J]. Energy, 2022, 239: 122128.

- [30] PENG Fei, LIU Hui, ZHENG Li. A sarsa reinforcement learning hybrid ensemble method for robotic battery power forecasting [J]. *Journal of Central South University*, 2023, 30(11): 3867-3880.
- [31] YIN S, LIU H. Wind power prediction based on outlier correction ensemble reinforcement learning, and residual correction[J]. *Energy*, 2022, 250: 12.
- [32] MA W, CAI P, SUN F, et al. State of health estimation for lithium-ion batteries based on extreme learning machine with improved blinex loss[J]. *International Journal of Electrochemical Science*, 2022, 17(11): 221170.
- [33] GOU B, XU Y. An ensemble learning based data-driven method for online state-of-health estimation of lithiumion batteries[J]. *Transactions on Transportation Electrification*, 2021, 7(2): 442-436.
- [34] 刘耿峰. 基于补丁学习和多模型融合的动力电池健康状态估计算法研究[D]. 桂林: 桂林电子科技大学, 2022.
LIU Gengfeng. Research on power battery health state estimation algorithm based on patch learning and multi-model fusion[D]. Guilin: Guilin University of Electronic Science and Technology, 2022.
- [35] CHENG Y, SONG D, WANG Z, et al. An ensemble prognostic method for lithiumion battery capacity estimation based on time-varying weight allocation[J]. *Applied Energy*, 2020, 266: 114817.
- [36] CAO M, ZHANG T, LIU Y, et al. An ensemble learning prognostic method for capacity estimation of lithiumion batteries based on the VIOWGA operator[J]. *Energy*, 2022, 257: 124725.
- [37] 乔涵哲. 动力电池充电系统故障诊断和健康监测研究[D]. 杭州: 杭州电子科技大学, 2021.
QIAO Hanzhe. Research on power battery charging system fault diagnosis and health monitoring[D]. Hangzhou: Hangzhou University of Electronic Science and Technology, 2021.

作者简介:



宋宗仁(1995-),男,硕士研究生,研究方向:数据挖掘、智能电网、机器学习,E-mail: 202130210089@stu.shmtu.edu.cn。



葛泉波(1980-),通信作者,男,博士,教授,研究方向:信息融合、智能电网、自主无人系统、机器视觉等,E-mail: geqb@nuist.edu.cn。



李春喜(1982-),男,博士,高级工程师,研究方向:智能电网、机器学习、能量管理系统等。

(编辑:夏道家)