

面向电池健康管理的剩余容量多核 SVM 分析方法

杨军¹, 王仲夏², 许云辰^{2*}

(1. 国电南京自动化股份有限公司, 南京 210003;

2. 皖江工学院电气与信息工程学院, 安徽马鞍山 243031)

摘要: 为解决锂离子电池剩余容量预测中非线性特征提取不足、参数寻优易陷入局部最优、预测精度偏低的问题, 提升电池健康管理的可靠性, 本文提出混沌步长粒子群 (CSPSO) 优化多核支持向量机的电池容量预测算法, 构建拉普拉斯核函数与径向基函数 (RBF) 核函数融合的多核 SVM 模型, 利用 CSPSO 算法实现模型关键参数全局寻优, 采用均方误差倒数法自适应分配核函数子模型权重。结果表明: 相较于传统 PSO 多核 SVM 预测方法, 混沌步长粒子群算法凭借混沌动态调整学习因子与步长的特性, 有效避免陷入局部最优, 提升参数寻优精度。相较于单一核 SVM 预测方法, 拉普拉斯核凭借适配高维稀疏数据的特性, 可精准捕捉电池退化全局特征, RBF 核凭借对局部非线性波动敏感的特性, 可高效拟合容量衰减局部规律, 二者融合大幅提升非线性特征提取能力。均方误差倒数法具备自适应权重分配的特点, 避免等权重融合带来的性能平均化缺陷, 提升模型整体预测精度与鲁棒性。CSPSO 优化多核支持向量机的容量预测算法可有效提取电池退化多维非线性特征, 参数寻优精度高、预测结果稳定, 为锂离子电池剩余容量精准预测与健康状态管理提供了一种可靠的新途径。

关键词: 锂离子电池; 剩余容量预测; 多核支持向量机; 混沌步长粒子群 (CSPSO) 算法; 拉普拉斯核函数; 径向基函数 (RBF) 核; 均方误差倒数法

中图分类号: TM912

文献标志码: A

文章编号: 2096-7705 (2027) 01-0001-08

Multi-kernel SVM Analysis Method for Remaining Capacity in Battery Health Management

Yang Jun¹, Wang Zhongxia², Xu Yunchen^{2*}

(1. Guodian Nanjing Automation Co., Ltd., Nanjing 210003, China; 2. School of Electrical and Information Engineering, Wanjiang University of Technology, Ma'anshan 243031, Anhui, China)

Abstract: To address the problems of insufficient nonlinear feature extraction, susceptibility to local optimum trapping in parameter optimization and low prediction accuracy in lithium-ion battery remaining capacity prediction, and improve the reliability of battery health management, this paper proposes a battery capacity prediction algorithm based on multi-kernel support vector machine (SVM) optimized by chaotic step particle swarm optimization (CSPSO). A multi-kernel SVM model integrating Laplacian kernel and radial basis function (RBF) kernel is constructed. The CSPSO algorithm is adopted for global

收稿日期: 2026-04-08

基金项目: 安徽省高等学校科学研究项目“光储一体化柔直发电系统及电能管理关键技术研究”(2024AH051874)

第一作者: 杨军 (1967—), 男, 中级工程师, 本科, 主要研究方向为电力交直流一体化电源、系统集成及工程化应用。

E-mail: 369363801@qq.com

王仲夏 (1974—), 男, 高级工程师, 硕士, 主要研究方向为智能化信息采集与处理系统的核心技术研发。

E-mail: 61166@163.com

* 通信作者: 许云辰 (1995—), 男, 高级工程师, 硕士, 主要研究方向为多模态系统建模的理论与工程实践。E-mail: 1394794528@qq.com

引用格式: 杨军, 王仲夏, 许云辰. 面向电池健康管理的剩余容量多核 SVM 分析方法[J]. 能源研究与管理, 2027, 19(1): 001-007.

optimization of key model parameters, and the reciprocal mean square error method is used to adaptively assign weights to sub-models of kernel functions. The results show that, compared with the traditional PSO-based multi-kernel SVM prediction method, CSPSO dynamically adjusts learning factors and step sizes via chaos theory, which effectively avoids local optima and improves parameter optimization accuracy. In contrast to single-kernel SVM, the Laplacian kernel adapts well to high-dimensional sparse data and accurately captures global battery degradation characteristics, while the RBF kernel is sensitive to local nonlinear fluctuations and efficiently fits local capacity fading rules. The fusion of the two kernels greatly enhances nonlinear feature extraction capability. The reciprocal mean square error method realizes adaptive weight allocation, eliminates the performance averaging defect caused by equal-weight fusion, and boosts the overall prediction accuracy and robustness of the model. The proposed CSPSO-optimized multi-kernel SVM capacity prediction algorithm can effectively extract multi-dimensional and nonlinear battery degradation features with high parameter optimization precision and stable prediction performance. It provides a novel and reliable approach for accurate remaining capacity prediction and health state management of lithium-ion batteries.

Keywords: lithium-ion battery; remaining capacity prediction; multi-kernel support vector machine (SVM); chaotic step particle swarm optimization (CSPSO) algorithm; Laplacian kernel function; radial basis function (RBF) kernel; reciprocal mean square error method

引言

当前新能源产业正以近 30 年来所未有的速度高速发展, 锂离子电池作为电动汽车^[1]、储能电站、便携式电子设备的核心储能器件。因此, 对锂离子电池的安全性与寿命进行高效管理成为新能源行业的核心问题。电池容量的精准分析是电池健康管理的核心环节^[2], 对电池容量的分析结果直接影响电池健康状态评估、剩余使用寿命的准确性^[3], 更是制定科学的电池维护、更换策略, 降低设备运行风险与运维成本的重要依据^[4]。目前锂离子电池容量预测方法主要分为基于电池机理建模的方法和基于数据驱动的方法^[5]。基于电池机理建模的方法通过建立电池内部电化学反应、容量衰减的物理 / 电化学模型实现预测, 但其建模过程复杂, 对电池内部机理参数依赖性强, 难以适配实际复杂工况下的电池退化规律^[6]。基于数据驱动的方法依托电池充放电历史数据, 通过机器学习算法挖掘数据与电池容量的内在关联, 具有建模简便、泛化能力强的优势, 成为当前容量预测的主流研究方向^[7-8]。

支持向量机 (support vector machine, SVM) 在小样本、非线性问题中表现出较强的泛化能力, 可降低神经网络预测中出现的易过拟合、局部最优等问题, 被广泛应用于电池容量预测^[9]。传统单一核函数 SVM 在处理电池退化的多维特征数据时, 存在特征提取能力不足的问题^[10]; 同时, SVM 的惩罚因子、核函数参数等对预测精度影响显著, 利用传统启发式优化算法对这些参数进行寻优, 易陷入局部最优, 难以获取全局最优参数, 从而影响预测性能^[11]。

由于电池充放电特征数据具备高维稀疏的特性, 而拉普拉斯核以指数衰减的形式计算特征空间中样本间的相似性, 因此可有效适配电池参数数据; 电池充放电特征数据呈现出局部非线性规律, 径向基函数 (radial basis function, RBF) 核由于平方指数衰减的数学构造, 对特征空间中样本的局部距离变化高度敏感, 因此可以精准拟合电池数据的局部非线性波动^[12]。

Putra 等^[13]提出一种结合粒子群优化与蚁群优化算法的鲁棒 SVM 优化框架, 通过双元启发式协同搜索有效克服传统机器学习模型的过拟合问题, 在锂离子电池健康监测中显著提升了状态预测精度与模型泛化能力, 为混合优化算法与机器学习融合在电池管理系统中的应用提供了新的思路。刘勇等^[14]提出一种面向大规模数据的核 SVM 高效求解方法, 通过构造近似高斯核的显式特征映射, 结合低秩近似思想与线性 SVM 快速优化策略, 显著降低传统核方法的时间与内存开销, 为大数据场景下核 SVM 的高效训练与混合核模型拓展提供了可行技术路径。Baker 等^[15]提出并行混合量子-经典核学习框架, 构造时间序列哈密顿核并通过多核学习对核权重做可微凸优化, 实现对混合核权重的端到端学习与高效加权。Gao 等^[16]提出了一种基于多项式核与 RBF 核融合的多核 SVM 模型, 采用粒子群优化算法对核参数、惩罚因子及权重系数进行寻优, 在 NASA 电池数据集上取得了优于单一 RBF 核 SVM 的预测效果。但该研究存在一些局限: 1) 多项式核在处理电池退化这类高度非线性问题时易出现过拟合现象, 且计算复杂度较高; 2) 传统 PSO 算法步长固定,

在高维参数寻优过程中容易陷入局部最优，难以稳定获取全局最优参数组合；3) 该模型对多核预测结果的权重分配依赖于 PSO 的同步优化，增加了模型的整体复杂度与调参难度。

本研究融合拉普拉斯核函数与 RBF 核的优势，构建多核支持向量机 (multi-kernel SVM) 模型，并提出混沌步长粒子群 (chaotic step particle swarm optimization, CSPSO) 算法实现模型关键参数全局寻优，同时采用均方误差倒数法自适应分配核函数子模型权重，形成面向锂离子电池剩余容量预测的混沌步长粒子群优化多核支持向量机 (CSPSO-多核 SVM) 方法。首先，构建拉普拉斯核与 RBF 核融合的多核 SVM 模型，其中拉普拉斯核可有效适配电池充放电数据的高维稀疏特性，精准捕捉电池退化的全局特征；RBF 核对特征空间中样本的局部距离变化高度敏感，能够高效拟合容量衰减过程中的局部非线性波动，二者融合大幅提升了模型对电池退化多维非线性特征的提取能力。其次，采用 CSPSO 算法对多核 SVM 的惩罚因子、容许误差、核宽度等关键参数进行全局寻优，该算法通过混沌策略动态调整学习因子与步长，能够有效避免传统粒子群优化 (particle swarm optimization, PSO) 算法因步长固定而易陷入局部最优的缺陷，显著提升参数寻优精度。最后，采用均方误差倒数法根据各子模型预测误差大小动态赋予权重，预测误差越小、稳定性越强的子模型获得越大权重，从而强化高稳定性子模型的贡献、抑制低稳定性子模型的波动影响，避免等权重融合带来的性能平均化缺陷，且不引入额外超参数、不增加模型整体复杂度。通过对锂离子电池数据集进行算例分析，验证所提算法的有效性，以期对锂离子电池容量预测提供新的技术路径。

1 算法整体框架

所提基于混沌步长粒子群优化多核支持向量机的锂离子电池容量预测算法整体分为数据预处理和多核 SVM 预测模型两大模块。整体算法流程图如图 1 所示，展示了从数据输入到最终容量预测输出的完整流程。

算法的核心思路为：构建拉普拉斯核+RBF 核多核 SVM 模型，通过 CSPSO 算法完成模型参数寻优，利用均方误差倒数法确定不同核函数预测结果的权重，加权线性融合后得到电池容量最终预测结果。通过多核 SVM 增强对电池退化非线性特征的提取能力；通过混沌步长粒子群算法实现模型参数




图 1 整体算法流程图

Fig. 1 Flow chart of overall algorithm

的全局寻优，利用均方误差倒数法确定不同核函数预测结果的权重，可自适应放大预测稳定性更强的核函数子模型贡献，规避等权重分配导致的性能平均化缺陷，降低预测结果随机波动，且不引入额外超参数、不增加模型复杂度，最终提升电池容量预测精度。

2 基于 CSPSO 的多核 SVM 预测模型

传统单一核函数 SVM 难以充分提取电池退化的多维非线性特征，本文构建基于拉普拉斯核函数和 RBF 核的多核 SVM 模型，采用 CSPSO 算法对多核 SVM 的关键参数进行全局寻优，并通过均方误差倒数法确定 2 种核函数预测结果的权重，线性融合得到最终容量预测结果。

2.1 多核 SVM 模型构建

支持向量机通过核函数将低维输入空间映射到高能特征空间，实现非线性问题的线性化求解。对于电池容量预测的回归问题，设特征数据集为 $\{(x_i, y_i) | i=1, 2, \dots, k\}$ ，其中， x_i 为第 i 个时间点的电池参数， y_i 为第 i 个时间点的电池容量真实值。SVM 回归模型的基本形式为^[7]：

$$f(x) = \omega \cdot \varphi(x) + b \quad (1)$$

式中： $f(x)$ 为根据电池参数 x 预测的电池容量预测

值； ω 为权重向量； x 为电池参数，通常为多参数（如电压、电流、电阻等）组成的数据集； $\varphi(x)$ 为低维空间到高维特征空间的非线性映射； b 为偏置系数。SVM 回归的优化目标为最小化权重向量的范数，同时控制预测误差在容许范围内，优化问题可表示为：

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|\omega\|^2 + C \sum_{i=1}^n (\zeta_i + \zeta_i^*) \\ & \text{subject to } \begin{cases} f(x_i) \leq \zeta_i + \varepsilon \\ y_i - f(x_i) \leq \zeta_i^* + \varepsilon \end{cases} \end{aligned} \quad (2)$$

式中： C 为惩罚因子，表征对离群样本的惩罚程度； ε 为容许误差； ζ_i 和 ζ_i^* 为松弛变量，表征预测值与实际值的偏差； $f(x_i)$ 为第 i 个时间点的电池容量预测值。

通过引入拉格朗日乘子，求解上述优化问题，得到 SVM 回归的决策函数：

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x, x_i) + b_i \quad (3)$$

式中： α_i 和 α_i^* 为拉格朗日乘子； $K(x, x_i)$ 为核函数。

锂离子电池退化数据具有高维稀疏、局部非线性波动显著的双重特性，单一核函数难以同时适配全局特征与局部规律。为验证最优核函数组合，本文选取锂离子电池领域常用的拉普拉斯核、RBF 核、线性核、多项式核、Sigmoid 核构建 5 组双核组合模型，基于平均绝对百分比误差（mean absolute percentage error, MAPE）开展预测性能对比，结果如表 1 所示。

表 1 不同核函数组合预测性能对比

Table 1 Comparison of prediction performance of different kernel function combinations

核函数组合	MAPE / %
拉普拉斯核+RBF 核	1.10
线性核+RBF 核	2.37
拉普拉斯核+线性核	3.84
多项式核+RBF 核	2.15
拉普拉斯核+多项式核	4.22

由表 1 可知，拉普拉斯核+RBF 核组合的 MAPE 最低，预测精度显著优于其他组合。其中，拉普拉斯核以指数衰减形式计算样本相似度，对高维稀疏电池退化数据的全局特征捕捉能力更强；RBF 核以平方指数衰减构造，对局部距离变化高度敏感，可精准拟合容量衰减的局部非线性波动^[1]。线性核仅能处理线性可分问题，对电池非线性退化特征适配

性差；多项式核易出现过拟合，计算复杂度高。综合适配性、预测精度与计算效率，本文最终构建拉普拉斯核+RBF 核的多核 SVM 模型。2 种核函数的表达式分别见式(4)和式(5)。

拉普拉斯核函数^[18]：

$$K_1(x, x_i) = \exp\left(-\frac{\|x - x_i\|}{\sigma_1}\right) \quad (4)$$

RBF 核函数^[19]：

$$K_2(x, x_i) = \exp\left(-\frac{\|x - x_i\|^2}{2\sigma_2^2}\right) \quad (5)$$

式中： σ_1 为拉普拉斯核函数的核宽度； σ_2 为 RBF 核函数的核宽度。 σ_1 、 σ_2 决定高维特征空间的映射范围。

基于 2 种核函数分别构建 SVM 子模型，得到 2 个子模型的预测结果 $f_1(x)$ 和 $f_2(x)$ ，通过权重系数线性融合得到多核 SVM 的最终预测结果：

$$f(x) = q_1 \cdot f_1(x) + q_2 \cdot f_2(x) \quad (6)$$

式中： q_1 和 q_2 为拉普拉斯核与 RBF 核子模型的权重系数，满足 $q_1 + q_2 = 1$ 。

2.2 基于 CSPSO 算法的多核 SVM 参数优化

多核 SVM 的预测精度受多个关键参数影响：拉普拉斯核 SVM 的惩罚因子 C_1 、容许误差 ε_1 、核宽度 σ_1 ；RBF 核 SVM 的惩罚因子 C_2 、容许误差 ε_2 、核宽度 σ_2 。传统 PSO 算法由于步长固定，在参数寻优时易陷入局部最优^[20]，本文采用 CSPSO 算法先对拉普拉斯核 SVM 的关键参数进行寻优，再对 RBF 核 SVM 的关键参数进行寻优，2 次寻优均以模型的均方根误差（root mean squared error, RMSE）为适应度函数，寻找使预测精度最高的参数组合。

2.2.1 混沌步长粒子群算法原理

混沌步长粒子群算法在传统 PSO 基础上，引入混沌策略动态调整学习因子 c_1 和 c_2 （步长相关参数），解决传统 PSO 步长固定导致的局部最优问题。算法核心公式主要有粒子速度更新公式、混沌更新策略、粒子位置更新公式 3 种。

1) 粒子速度更新公式。

$$v_i(t+1) = w \cdot v_i(t) + c_1 r_1 [p_{i, \text{best}}(t) - x_i(t)] + c_2 r_2 [g_{\text{best}}(t) - x_i(t)] \quad (7)$$

式中： w 为惯性权重； $v_i(t)$ 为第 i 个粒子在第 t 次迭代的速度向量； $x_i(t)$ 为第 i 个粒子在第 t 次迭代的位置向量（对应 SVM 的参数组合）； $p_{i, \text{best}}(t)$ 为第 i 个粒子在第 t 次迭代的个体最优位置； $g_{\text{best}}(t)$ 为第 t 次迭代的种群全局最优位置； r_1 、 r_2 为 $[0, 1]$ 范围内的随机数。

2) 学习因子 c_1 、 c_2 的混沌更新策略（每次循环

执行)。

$$\alpha(t+1)=\begin{cases} 2\cdot|\alpha(t)|+\lambda\cdot r & \alpha(t)\leq 0.5 \\ 2\cdot|1-\alpha(t)|+\lambda\cdot r & \alpha(t)>0.5 \end{cases} \quad (8)$$

式中： $\alpha(t)$ 为当前第 t 次迭代的学习因子（ c_1 或 c_2 ）； $\alpha(t+1)$ 为下一次迭代的学习因子； λ 为防止学习因子陷入循环的扰动因子，本文取0.005； r 为[0, 1]范围内的随机数。混沌策略动态调整步长，增强算法的全局搜索能力。

3) 粒子位置更新公式。

$$x_k(t+1)=x_k(t)+v_k(t+1) \quad (9)$$

粒子位置得到更新，可展开全局搜索，搜索出使得SVM性能最优的参数组合。

2.2.2 CSPSO 优化 SVM 参数的实现步骤

将SVM的关键参数作为粒子的位置向量，设定参数的搜索范围，以模型RMSE为适应度函数，CSPSO优化多核SVM参数的具体步骤如下。

1) 初始化参数。设置粒子群规模 N 、最大迭代次数 T ，惯性权重 $w=0.7$ ；确定多核SVM各参数的搜索范围： $C_1, C_2 \in [1, 500]$ ， $\varepsilon_1, \varepsilon_2 \in [0, 5]$ ， $\sigma_1, \sigma_2 \in [1, 1000]$ ，随机生成 N 个粒子位置向量（初始参数组合），初始化粒子速度向量为0，学习因子 $c_1=c_2=0.5$ 。

2) 计算适应度值。将每个粒子位置向量对应的参数组合代入SVM模型，利用训练数据集训练模型，计算模型的RMSE作为该粒子的适应度值；记录每个粒子的个体最优位置（适应度值最小的位置）和种群全局最优位置。

3) 混沌步长更新。更新学习因子 c_1 和 c_2 ；更新粒子速度向量 $v_k(t)$ ；更新粒子位置向量 $x_k(t)$ ，确保位置向量在参数搜索范围内。

4) 更新最优位置。重新计算每个粒子的适应度值，若当前适应度值优于个体最优，则更新个体最优位置；若个体最优适应度值优于全局最优，则更新全局最优位置。

5) 判断终止条件。若当前迭代次数达到最大迭代次数，则停止寻优，输出全局最优位置作为多核SVM的最优参数组合；否则返回步骤3)，继续迭代寻优。

2.3 基于均方误差倒数法的权重确定

权重系数的分配直接影响多核SVM的预测精度，是提升预测稳定性与精度的关键环节。为科学选取最优权重方法，本文将均方误差倒数法与贝叶斯权重优化法、熵权法、层次分析法（AHP）、等权重法开展对照实验，用MAPE反映预测的精度，预

测精度对比结果如图2所示。




图2 不同权重分配方法预测精度对比

Fig. 2 Comparison of prediction accuracy of different weight allocation methods

由图2可知，均方误差倒数法预测精度均优于其他方法，因此本文采用均方误差倒数法作为权重分配的方法。不同权重分配方法复杂度与运行效率对比结果如表2所示。

表2 不同权重分配方法复杂度与运行效率对比

Table 2 Comparison of complexity and operation efficiency of different weight allocation methods

权重分配方法	算法复杂度	单次响应时间 / ms	部署适用性
均方误差倒数法	底	18.6	极高
等权重法	低	12.3	高
熵权法	中等	75.4	中
层次分析法	中等	142.8	低
贝叶斯权重优化法	高	216.5	低

由图2和表2可知，1) 预测精度。本文均方误差倒数法在电池剩余容量预测上精度最高（MAPE=1.10%），仅在内阻特征预测上略低于贝叶斯权重法，整体综合精度最优。2) 运行效率。均方误差倒数法为线性复杂度，计算量小、响应速度快，显著优于熵权法、层次分析法与贝叶斯权重优化法，更适合在线预测场景。3) 适用性。等权重法虽速度快但未考虑子模型差异，易造成性能平均化；熵权法、层次分析法、贝叶斯权重优化法复杂度高、耗时长，难以满足电池管理系统实时性要求。

综合精度、效率与工程实用性，本文采用均方误差倒数法进行权重分配。该方法根据子模型预测误差自适应赋权，误差越小权重越高，可强化高稳定子模型贡献、抑制低稳定子模型波动，避免等权重融合缺陷，且不引入额外超参数、不增加模型整体复杂度。

设拉普拉斯核SVM子模型预测结果的均方误差为 r_1 ，RBF核SVM子模型预测结果的均方误差为 r_2 ，则2个子模型的权重系数计算为：

$$q_1 = \frac{1/r_1}{1/r_1 + 1/r_2} \quad (10)$$

$$q_2 = \frac{1/r_2}{1/r_1 + 1/r_2} \quad (11)$$

均方误差 r 的计算式为:

$$r = \frac{1}{k} \sum_{i=1}^k (\hat{y}_i - y_i)^2 \quad (12)$$

式中: $\hat{y}_i$ 为第 i 个预测值; k 为训练样本数。

3 实验验证与结果分析

3.1 实验数据集与评价指标

本文采用美国马里兰大学 CALCE 工程中心的锂离子电池退化数据集进行实验验证^[21], 选取该实验中对电池 A 的棱柱形锂离子电池为研究对象, 电池标称容量 1.1 Ah, 充放电制度为 0.55 A 恒流充电至 4.2 V, 随后恒压充电至电流降至 0.05 A 以下, 再以 0.55 A 恒流放电至 2.7 V。实验提取每节电池的放电容量、充电时间、平均放电电压、平均放电温度、内阻 5 个充放电特征参数作为原始特征, 计算电池的实际容量。

为验证所提算法的性能, 选取 RMSE、平均绝对误差 (mean absolute error, MAE)、MAPE 作为预测精度评价指标, 各指标的计算公式为:

$$P_{\text{RMSE}} = \sqrt{\frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2} \quad (13)$$

$$P_{\text{MAE}} = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i) \quad (14)$$

$$P_{\text{MAPE}} = \frac{1}{N} \sum_{i=1}^N \left| \frac{\hat{y}_i - y_i}{y_i} \right| \times 100\% \quad (15)$$

式中: P_{RMSE} 为均方根误差; P_{MAE} 为平均绝对误差; P_{MAPE} 为平均绝对百分比误差; N 为测试样本数。各指标值越小, 表明预测精度越高。

3.2 实验设置

实验环境为 Matlab2021b, 运行平台为 Intel Core i7-12700H CPU, 32GB 内存, 采用 MATLAB 自带的 Statistics and Machine Learning Toolbox 实现 SVM 模型自行编写混沌步长粒子群算法代码。实验步骤如下。

1) 对电池的充放电特征参数进行归一化处理, 消除量纲影响;

2) 以电池数据的前 80% 循环数据为训练集, 后 20% 为测试集;

3) 采用 CSPSO 算法对多核 SVM 的参数进行寻优, 设置粒子群规模 $N=50$ 个, 最大迭代次数

$T=500$ 次;

4) 训练 CSPSO-多核 SVM 模型, 采用均方误差倒数法确定权重, 得到容量预测结果;

5) 进行对比分析, 分别训练单一拉普拉斯核 SVM、单一 RBF 核 SVM、BP 神经网络、传统 PSO-多核 SVM 模型, 在相同数据集上进行预测, 对比各模型的评价指标。

3.3 实验结果与分析

3.3.1 CSPSO 参数寻优结果

CSPSO 算法以模型 RMSE 为适应度函数的迭代初期适应度值快速下降, 表明混沌步长策略有效增强了算法的全局搜索能力; 在迭代至 280 次左右时, 适应度值趋于稳定, 最终收敛到全局最优解参数组合, 对应的多核 SVM 最优参数组合为: $C_1=322.4$ 、 $\varepsilon_1=0.80$ 、 $\sigma_1=588.6$ 、 $C_2=410.2$ 、 $\varepsilon_2=0.63$ 、 $\sigma_2=590.5$ 。

3.3.2 不同模型的预测性能对比

将所提 CSPSO-多核 SVM 算法与单一拉普拉斯核 SVM、单一 RBF 核 SVM、BP 神经网络、传统 PSO-多核 SVM 算法在 4 节电池上的预测结果进行对比, 各模型的平均评价指标如表 3 所示。

表 3 不同模型的预测性能对比

Table 3 Comparison of prediction performance of different models %

模型	RMSE	MAE	MAPE
单一拉普拉斯核 SVM	8.52	3.98	4.51
单一 RBF 核 SVM	5.32	3.34	2.75
BP 神经网络	7.37	4.14	3.96
传统 PSO-多核 SVM	5.20	3.71	1.68
CSPSO-多核 SVM (均方误差倒数法权重分配)	2.23	1.77	1.10

电池容量预测值与实际值对比曲线如图 3 所示。由图可知, CSPSO-多核 SVM 模型的预测曲线相较于其他算法的预测曲线, 与电池真实容量曲线的重合度更高。相较于单核 SVM 和神经网络预测模型, 多核 SVM 具备更强的预测能力。相较于传统 PSO-多核 SVM 预测算法, CSPSO-多核 SVM 模型的容量预测平均绝对百分比误差降低了 34.5%, 体现了混沌步长参数寻优与均方误差倒数法权重分配的协同作用。CSPSO 算法通过混沌策略动态调整学习因子, 能够避免在对 SVM 模型参数的寻优过程中因步长固定而陷入局部最优, 因此通过预测构建的 SVM 模型的预测精度更高。同时, 均方误差倒数法




图 3 预测结果对比图

Fig. 3 Comparison of prediction results

根据各核 SVM 模型的预测均方误差,对 2 种 SVM 的预测结果分配权重实现了多核预测结果的高效融合,有效降低了预测结果的随机波动。

4 结论

1) 拉普拉斯核函数+RBF 核的多核 SVM 模型使 MAPE 降至 1.10%, 优于 2 种单一核函数 (最高 4.51%)。拉普拉斯核函数与 RBF 核的多核 SVM 融合模型,可充分发挥拉普拉斯核函数对高维稀疏电池退化特征的强捕捉能力,以及 RBF 核优异的局部非线性规律挖掘能力,从特征提取层面解决了单一核函数 SVM 适配性不足的问题,实现了对电池退化多维非线性特征的全面提取,为提升预测精度奠定了模型基础。

2) CSPSO 算法使 RMSE 较传统 PSO 降低 57.1%, 收敛更稳定。CSPSO 算法的引入,提高了拉普拉斯核与 RBF 核的关键参数的优化精度,进一步提升多核 SVM 的预测能力。

3) 均方误差倒数法权重分配使预测波动显著降

低, MAPE 优于等权重法 (1.68%→1.10%)。通过均方误差倒数法对预测结果进行权重分配,既提升了多核预测结果的融合效率,又有效抑制了预测结果的随机波动。

本文实验的数据来源为标准化充放电的电池数据集,并没有考虑在电池预测的实际场景中出现对应的特殊情况,如温度突变、充放电倍率变化、循环工况波动等。后续将根据电池充放电场景的实际应用场景适配相应的预测模型,适配电池健康管理的实时采样预测场景。未来将从如下几个方面进一步开展电池健康度预测方法的研究。

1) 致力于构建面向复杂工况的自适应预测模型。针对电池实际使用中动态变化的运行条件,拟将温度波动、充放电倍率及循环老化轨迹等时变特征作为关键输入变量,通过融合时空维度的信息,构建基于多核支持向量机的容量预测模型,以增强算法在复杂动态工况下的鲁棒性与泛化精度。

2) 着力于实现算法的轻量化与嵌入式部署。为促进实验室成果向工程实践转化,后续研究将结合

电池管理系统的硬件资源约束,对多核 SVM 算法进行结构优化与计算加速,在保证预测精度的前提下降低模型复杂度,从而提升计算效率,最终实现电池容量的实时在线估计与健康状态跟踪。

3) 未来将进一步构建多目标协同优化的复合适应度函数,以 RMSE、MAE、MAPE 等多项预测精度指标为优化目标,采用动态加权融合策略赋予各指标自适应权重,建立兼顾全局误差、绝对偏差与相对偏差的综合优化目标;并依据实时预测误差与模型收敛状态动态调整各指标权重系数,实现参数寻优过程中多维度精度指标的协同最优,从适应度函数设计层面进一步提升 CSPSO 算法的寻优合理性与模型泛化性能。

参考文献

- [1] 赵璐,吴鹏江,齐绍通,等.基于多物理场耦合的磷酸铁锂电池组热失控及其蔓延特性仿真分析[J].能源研究与管理,2026,18(1):7-15.
- [2] 康振华,凌鑫晨,万里平,等.基于活化能的功率型动力电池寿命影响因素分析[J].能源研究与管理,2024,16(3):79-84.
- [3] 高国章,刘长昊,袁裕鹏,等.基于 PKO-XGBoost-TCN 的锂电池 SOH 估计[J].电源技术,2025,49(12):2553-2562.
- [4] 杜江龙,王旭峰,陈润凯.磷酸铁锂电池正极压实密度的多维度作用及对循环老化的影响[J].能源研究与管理,2026,18(1):89-97.
- [5] 夏宇.基于健康特征变换的锂离子电池健康状态评估及预测方法[D].重庆:重庆大学,2023.
- [6] 邓昊,杨林,邓忠伟,等.基于电化学机理模型的锂离子电池参数辨识及 SOC 估计[J].上海理工大学学报,2018,40(6):557-565.
- [7] 何法,韩志,李彦超,等.基于遗传算法优化 BP 神经网络的锂电池容量预测研究[J].汽车技术,2026(1):45-50.
- [8] 王瑞,陈泽坤,逯静.基于 VMD 和 IBA-LSSVM 的短期风电功率预测[J].河海大学学报(自然科学版),2021,49(6):575-582.
- [9] 李雨佳,欧阳权,刘灏仪,等.基于支持向量机与改进高斯过程混合模型的车用动力电池容量预测方法[J].电气工程学报,2024,19(1):87-96.
- [10] 蔡仕云,吴肖龙,李豫,等.基于融合聚类 and RBF-SVM 的固体氧化物燃料电池系统故障识别[J].武汉大学学报(理学版),2025,71(6):841-850.
- [11] 鞠红梅,周菲,孟凡.基于模糊隶属度与粒子群算法协同优化的双子支持向量机鲁棒性分类方法[J/OL].系统科学与数学,(2025-09-17).<https://link.cnki.net/urlid/11.2019.01.20250916.1042.002>.
- [12] Pan Jing,Tong Shu,Li Yang,et al.State of health estimation for lithium-ion batteries based on improved Gaussian process regression[C].2021 IEEE 12th Energy Conversion Congress & Exposition,2021:1-6.
- [13] Putra M R A,Nizam M,Mujiato A,et al.Robust SVM optimization using PSO and ACO for accurate lithium-ion battery health monitoring[J].Mechanical Engineering for Society & Industry,2025,5(1):1-12.
- [14] 刘勇,江沙里,廖士中.基于近似高斯核显式描述的大规模 SVM 求解[J].计算机研究与发展,2014,51(10):2171-2177.
- [15] Baker J S,Park G,Yu K,et al.Parallel hybrid quantum-classical machine learning for kernelized time-series classification[J].Quantum Machine Intelligence,2024,6(1):1-18.
- [16] Gao Dong,Huang Miaohua.Prediction of remaining useful life of lithium-ion battery based on multi-kernel support vector machine with particle swarm optimization[J].Journal of Dalian University of Technology,2017,17(5):1288-1297.
- [17] 李丽,车金香,赵云,等.基于 Subbagging 的支持向量回归集成及应用[J].数学的实践与认识,2019,49(15):167-172.
- [18] 刘鑫,李彬周,王军生,等.一种改进型拉普拉斯核的 GRNN 模型在重轨性能预测中的应用[J].铁道科学与工程学报,2025,22(8):3471-3480.
- [19] 胡林静,李在伟.基于灰狼优化算法和组合核函数 GPR 模型的锂电池剩余使用寿命预测[J].综合智慧能源,2025,47(12):25-33.
- [20] 潘冯超,刘勤明,叶春明,等.基于改进萤火虫算法的分布式能源供应链配置研究[J].能源研究与信息,2022,38(1):46-52.
- [21] Williard N,He Wei,Osterman M,et al.Comparative analysis of features for determining state of health in lithium-ion batteries[J].International Journal of Prognostics and Health Management,2013,4(1):14-20.