

基于神经网络的锂离子电池充电策略优化研究

张鑫伟¹ 魏玲^{1*}

ZHANG Xinwei WEI Ling

摘要

随着新能源汽车、便携式电子设备和储能系统的快速发展，锂离子电池作为关键能源单元，其充电效率与使用寿命已成为研究热点。传统的恒流恒压（constant current-constant voltage, CC-CV）充电策略虽然简单可靠，但在充电速度、电池安全性与寿命保护方面仍存在诸多不足。为实现对锂离子电池更加智能、高效的充电控制，文章提出了一种基于神经网络的锂离子电池充电策略优化方法。通过构建以电压、电流、温度、荷电状态等为输入特征的神经网络模型，预测电池在不同充电策略下的运行响应，并引入优化算法动态调整充电策略。实验结果表明，相较于传统恒流恒压充电策略，该方法在保障充电安全的前提下，充电时间缩短约12%，最大温升降低约15%，显著减小对电池寿命的负面影响，在提升电池智能化管理水平方面展现出广阔应用前景。

关键词

锂离子电池；充电策略；神经网络；遗传算法

doi: 10.3969/j.issn.1672-9528.2025.10.024

0 引言

近年来，随着新能源技术与节能环保理念的蓬勃发展，锂离子电池凭借其高能量密度、长循环寿命等优势，在新能源汽车、便携式电子设备及储能电站等领域得到广泛应用，其性能与安全性备受关注。

当前，基于深度学习的方法在锂离子电池健康状态评估与充电管理领域应用广泛。王浩等人^[1]提出基于TransformerEncoder和深度可分离一维卷积网络（DR1DCNN）融合的模型预测剩余使用寿命，提升了特征提取能力；张朝龙等人^[2]构建CNN、注意力机制（CBAM）与双向长短期记忆网络（BiLSTM）融合模型，实现电池健康状态动态估计；黄腾飞^[3]从电-热-机械耦合角度提出充电管理策略，提升热安全性和结构稳定性；王政^[4]基于改进GRU网络高效预测电池剩余寿命；杨庆新^[5]采用多层深度学习模型实现电池寿命长周期准确预测；杨曦^[6]提出基于自适应容积卡尔曼滤波（AUKF）的SOC估计方法；陈丁鸿^[7]利用多源数据融合策略构建寿命预测模型；黄紫依^[8]构建融合鲸鱼优化算法（WOA）、时序卷积网络（TCN）与Transformer的多模型架构用于健康状态预测。然而，针对充电过程策略优化，特别是平衡实时充电效率、安全性与寿命保护的统一高效智能化解决方案仍较为缺乏。为此，本文围绕锂离子电池充电性能优化与安全保障开展研究。

1 锂离子电池建模

本文采用以神经网络为核心的数据驱动建模方法，该方法适合处理电池系统的非线性特征和强耦合特性。

1.1 神经网络建模

神经网络模型输入为充电电流 $I(t)$ 、时间 t 、环境温度 $T(t)$ 等特征，输出为电池端电压 $V(t)$ 、SOC 或内部温度等状态。以标准前馈神经网络（BP）为例，其模型结构为：

$$\begin{cases} z_1 = W_1 \mathbf{x} + b_1 \\ a_1 = f(z_1) \\ z_2 = W_2 a_1 + b_2 \\ \mathbf{y} = f(z_2) \end{cases} \quad (1)$$

式中： \mathbf{x} 为输入特征向量； f 为激活函数； \mathbf{y} 为输出预测值。为提升模型的时序建模能力，本文还将在后续章节引入循环神经网络（如LSTM/GRU）以增强对历史充电过程的记忆能力。

1.2 损失函数与优化目标

神经网络训练时，以预测值与真实值的误差最小为目标，典型损失函数为：

$$L = \frac{1}{N} \sum_{i=1}^N (\widehat{\text{SOC}}_i - \text{SOC}_i)^2 \quad (2)$$

该损失函数将作为优化目标函数，通过反向传播与梯度下降算法对神经网络权重进行训练更新，其中 $\widehat{\text{SOC}}_i$ 是预测值， SOC_i 是真实值。

1. 辽宁工业大学电气工程学院 辽宁锦州 121001

2 神经网络模型设计与训练

2.1 神经网络结构设计

为实现对锂离子电池在充电过程中的状态精确建模与行为预测，本文设计了一种结合时序特征提取能力与非线性建模能力的神经网络结构，主要包括两类模型：前馈神经网络与循环神经网络，并结合实际充电数据开展训练与优化。

前馈神经网络适用于短期无记忆建模任务，可用于基准模型对比。输入特征包括：当前时刻充电电流 $I(t)$ 、充电起始至当前的累计时间 t 、环境温度 $T(t)$ 、历史 SOC 估值。

网络结构为 3 层神经元，典型结构如表 1 所示。

表 1 网络结构

层级	神经元数	激活函数
输入层	3	—
隐藏层 1	64	ReLU
隐藏层 2	32	ReLU
输出层	1 (V 或 SOC)	Linear

2.2 输入与输出特征选择

输入与输出变量定义如表 2 所示。

表 2 输入与输出变量定义

输入特征	含义	单位
$I(t)$	当前充电电流	A
t	当前时刻或累计充电时间	s
$T(t)$	当前环境温度	°C
$V(t-1)$	上一时刻端电压	V

输出目标包括两种：电池当前电压 $V(t)$ 和电池状态（如 SOC 或温度）。

输入特征包括当前 SOC (State of Charge)、当前电压、电流、电池温度、历史若干时刻的 SOC、电压、电流（供 LSTM 建模）、当前充电时间片 (timestep) 或周期索引、环境温度（若可获取）、电池类型参数（可选）。

输出变量为在给定状态下建议的最优充电电流（或电压），或者为分类变量，如推荐充电阶段（恒流、恒压、涓流等）、输入特征经过归一化处理（如 Z-score 或 Min-Max），以减少不同量纲带来的训练不平衡问题。

2.3 数据集构建与预处理

为保证模型的可训练性和泛化能力，本文采用公开的 NASA 电池数据集 (battery prognostics data set) 与部分仿真生成数据集结合的方法。

数据集构建过程如下：

采集电池在不同充电策略下的工作数据，包括 SOC、电压、电流、温度等；剔除异常值、缺失值和重复项，修正采样误差；将时间序列数据按照滑动窗口划分为训练样本；所有特征统一缩放到 $[0,1]$ 或 $[-1,1]$ 区间；按照 7:2:1 划分训练集、验证集和测试集。

为增强模型的泛化能力，还对数据进行了平滑处理与样本扩增（如添加噪声模拟不同电池差异性）。

2.4 网络训练与验证方法

模型训练采用监督学习方式，目标为最小化预测充电参数与目标策略之间的差异。

(1) 训练流程：对于回归任务采用 MSE 损失函数，对于策略分类采用交叉熵损失；使用 Adam 优化器，自适应调整学习率（初始为 $1e-3$ ，逐步衰减）；Batch Size 设为 64，每轮训练 200 个 Epoch；在验证集损失不再下降时提前停止训练，防止过拟合；

(2) 模型评估指标：选择均方根误差 (RMSE)、平均绝对误差 (MAE) 和策略选择准确率（若为分类任务），实际仿真测试下的充电效率提升率与温控效果。

训练完成后，在验证集和测试集上进行性能对比，评估模型在不同电池类型和不同初始 SOC 下的策略适应性与稳定性。如图 1 和图 2 为模型在训练集和验证集上的精度和 Loss 变化曲线。




图 1 模型精度变化曲线

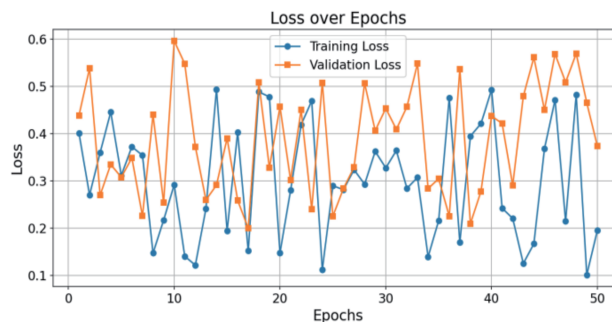


图 2 模型损失变化曲线

从图 1 可以看出，随着训练轮次 (epoch) 的增加，模型在训练集上的准确率逐步提升，且整体趋势稳定向上。同时，

测试集（验证集）上的准确率也随之提高，说明模型不仅在训练数据上表现好。当训练集和验证集准确率的增长趋于平稳时，这可能表示模型已经接近收敛。

从图2可以看出，随着训练轮次增加，训练集和验证集的损失值持续下降，模型的收敛效果明显。训练集损失的下降表明模型对训练数据的拟合程度逐渐提高。

2.5 锂离子电池充电优化策略

针对锂离子电池在电动汽车充电过程中存在的充电时间长、容量衰减快以及温升风险高等问题，本文以提升电动汽车锂电池充电效率与使用寿命为目标，基于神经网络预测模型，提出了一种结合遗传算法的充电策略优化方法。

2.5.1 优化目标函数定义

为系统性描述优化需求，本文设计了以下多目标优化函数：

$$J = w_1 \cdot T_{\text{charge}} + w_2 \cdot D_{\text{SOH}} + w_3 \cdot R_{\text{temp}} \quad (3)$$

式中： T_{charge} 表示电池从当前 S_{OC} 充至目标 S_{OC} 所需的充电时间； D_{SOH} 表示充电过程中 S_{OH} 的衰减程度，由神经网络预测得到； R_{temp} 表示温升风险，用最大温度变化幅度衡量； w_1 、 w_2 、 w_3 表示权重系数，用于根据不同应用场景调整优化侧重点。上述指标中， D_{SOH} 和 R_{temp} 分别由训练好的神经网络预测模型估算，为优化提供精细的状态反馈。

2.5.2 基于遗传算法的优化算法设计

为求解上述多目标优化问题，本文采用遗传算法（genetic algorithm, GA）进行充电策略参数的全局搜索。具体步骤如下：

（1）编码设计

将充电参数（如恒流阶段电流 I_{cc} 、恒压阶段截止电流 I_{cutoff} 、阶段切换SOC等）编码为染色体基因。

（2）初始种群生成

随机生成一组具有不同充电参数的个体，构成初始种群。

（3）适应度函数定义

利用神经网络模型预测每个个体对应的 T_{charge} 、 D_{SOH} 、 R_{temp} ，计算优化目标函数 J 作为个体适应度。

（4）选择、交叉与变异

选择采用轮盘赌或锦标赛选择高适应度个体进入下一代；交叉采用单点交叉或多点交叉生成新个体；变异引入小概率基因突变，保证种群多样性。

（5）终止条件

达到最大迭代代数或目标函数收敛时，输出最优充电策略参数。

算法流程如图3所示。

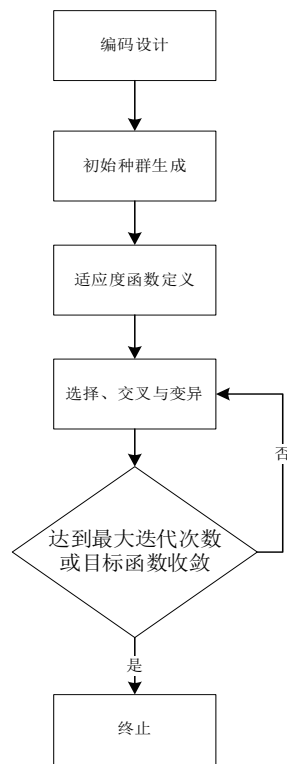


图3 算法流程图

2.5.3 仿真实验

如图4所示为遗传算法适应度值随迭代次数变化曲线图。

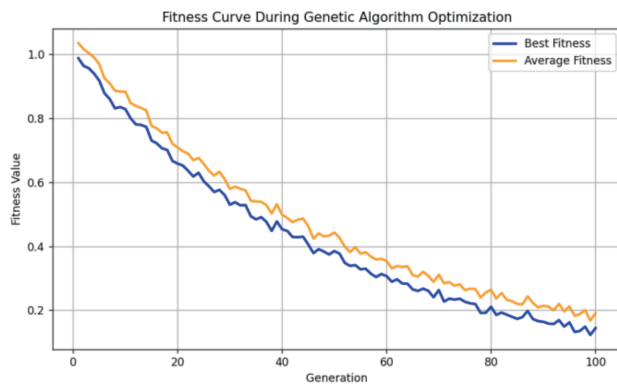


图4 适应度变化曲线

图5为充电时间、SOH衰减、温升的优化收敛曲线；图6为优化前后充电策略对比柱状图。




图5 充电时间、SOH衰减、温升的优化收敛曲线

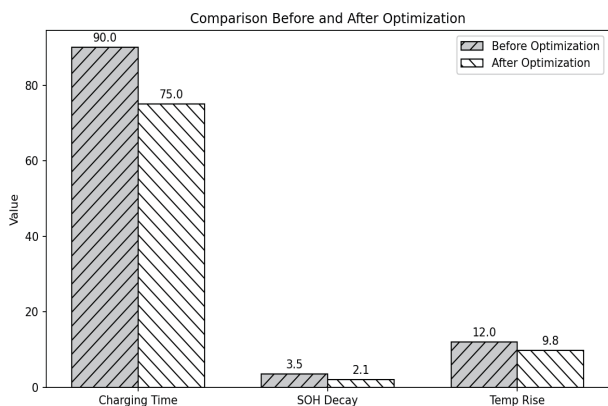


图 6 优化前后充电策略对比柱状图

可以看出，充电时间从约 90 min 逐步优化到 75 min，SOH 衰减从 3.5% 下降到 2.1%，温升从 12 °C 降至约 9.8 °C，表明优化过程不仅有效降低了充电时间，还兼顾了电池健康（SOH）与热安全表现（温升），实现了多目标协调优化。曲线在迭代后期趋于平稳，表明解的稳定性较好。

为了验证所提充电优化策略的有效性，本文将传统恒流恒压 CC-CV 策略和遗传算法优化策略进行对比分析，如表 3 所示，验证了基于神经网络预测与遗传算法优化相结合的方法能够显著缩短充电时间、降低健康衰减、减小温升风险，有助于提升锂离子电池的使用寿命与安全性能。

表 3 实验结果表

策略类型	充电时间 /min	SOH 衰减 /%	温升幅度 /°C
传统 CC-CV 策略	90	3.5	12.0
遗传算法优化策略	75	2.1	9.8

3 实验与结果分析

为进一步验证所提出 CNN-LSTM 模型在锂离子电池充电策略优化中的优越性，本文将其与 3 种常见神经网络模型进行了对比，如表 4 所示。

表 4 各模型在测试集上的性能对比

模型类型	MSE	MAE	R ²	训练时间 /s
BP 神经网络	0.009 8	0.074 2	0.913	102.4
单独 LSTM	0.004 3	0.054 7	0.958	135.2
GRU	0.003 9	0.051 2	0.964	126.7
CNN-LSTM(本文)	0.002 5	0.037 6	0.982	158.7

从表 4 可以看出，本文提出的 CNN-LSTM 模型在 4 个指标中均优于其他 3 种模型：R² 值显著提升，说明模型对目标输出变量的拟合度更高；MAE 与 MSE 指标均优于传统模型。

4 总结

本文提出了 CNN-LSTM 融合算法，在优化锂离子电池充电策略方面表现出以下几点优势：

(1) 时序特征提取能力强：结合卷积神经网络和长短时记忆网络的结构使模型既能提取局部充电特征，又能捕捉时间序列中的长期依赖关系，从而有效提升了策略预测的准确性和稳定性。

(2) 预测精度显著提高：相比传统 BP 神经网络及单一结构的 LSTM 或 GRU 模型，CNN-LSTM 模型的 MSE 和 MAE 均显著降低，R² 值提升至 0.982，表明模型拟合度高，能更准确地为电池充电提供策略参考。

参考文献：

- [1] 王浩, 李亚, 王海瑞, 等. 基于 TransformerEncoder-DR1DCNN 的锂离子电池 RUL 预测 [J]. 陕西理工大学学报 (自然科学版), 2025, 41(2):54-63.
- [2] 张朝龙, 张侯峰, 陈阳, 等. 基于 CNN-CBAM-BiLSTM 融合模型的锂离子电池健康状态估计方法 [J/OL]. 电源学报, 1-15[2025-05-02]. <https://knshtbprolnckihbprolnet-p.libvpu.zuel.edu.cn/kcms/detail/12.1420.TM.20250410.1125.012.html>.
- [3] 黄腾飞. 基于电-热-机械耦合特性的三元锂离子电池状态估计与充电管理 [D]. 长春: 吉林大学, 2024.
- [4] 王政. 基于改进门控循环单元的锂离子电池剩余寿命预测 [D]. 无锡: 江南大学, 2024.
- [5] 杨庆新. 基于深度学习的锂离子电池剩余使用寿命预测方法研究 [D]. 烟台: 烟台大学, 2024.
- [6] 杨曦. 基于自适应容积卡尔曼滤波算法的锂离子电池 SOC 估计 [D]. 合肥: 安徽理工大学, 2024.
- [7] 陈丁鸿. 多类型数据驱动的锂离子电池寿命预测方法研究 [D]. 北京: 北京交通大学, 2024.
- [8] 黄紫依. 基于 WOA-TCN-Transformer 的锂离子电池健康状态预测 [D]. 武汉: 华中科技大学, 2024.

【作者简介】

张鑫伟 (2001—)，男，山东济宁人，硕士，研究方向：控制工程。

(收稿日期：2025-05-28 修回日期：2025-10-15)