



ELSEVIER

Contents lists available at ScienceDirect

Engineering

journal homepage: [www.elsevier.com/locate/eng](http://www.elsevier.com/locate/eng)



Research

Energy Battery—Article

## 基于液冷的电池热管理系统快充-冷却耦合规划方法

陈思琦<sup>a,b</sup>, 包能胜<sup>b</sup>, Akhil Garg<sup>a</sup>, 彭雄斌<sup>b</sup>, 高亮<sup>a,\*</sup>

<sup>a</sup> State Key Laboratory of Digital Manufacturing Equipment and Technology, School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China

<sup>b</sup> Intelligent Manufacturing Key Laboratory of Ministry of Education, Shantou University, Shantou 515063, China

### ARTICLE INFO

#### Article history:

Received 20 January 2020

Revised 17 May 2020

Accepted 2 June 2020

Available online 30 July 2020

#### 关键词

锂离子电池组

快速充电

神经网络回归

规划

荷电状态

功耗

### 摘要

高效的快速充电技术对电动汽车行驶里程的拓展十分重要。然而,锂离子电池在大电流充电倍率下会大量产热。为解决这一问题,急需一种高效的快速充电-冷却规划方法。此次研究针对锂离子电池组的快速充电过程,设计了一种配有微流道的基于液冷的热管理系统。基于81组实验数据,提出了一种基于神经网络的回归模型,由三个考虑以下输出的子模型构成:最高温度、温度标准差及功耗。训练后的子模型均呈现出较高的测试准确性(99.353%、97.332%和98.381%)。此回归模型用于预测一个设计方案全集的三个输出参数,此全集由不同充电阶段的充电电流倍率[0.5C、1C、1.5C、2C和2.5C (1C = 5 A)],以及不同的冷却液流量(0.0006 kg·s<sup>-1</sup>、0.0012 kg·s<sup>-1</sup>和0.0018 kg·s<sup>-1</sup>)组成。最终从预测得到的设计方案全集中筛选出一组最优过程方案,并经实验得到了验证。结果表明在功耗低于0.02 J的情况下电池组荷电状态(SOC)值经15 min充电后增长了0.5。同时最高温度和温度标准差可分别控制在33.35 °C和0.8 °C以内。本文所提出的方法可供电动汽车行业在实际快速充电工况下使用。此外,可以基于实验数据预测最佳快速充电-冷却计划,从而显著提高充电过程设计的效率,并控制冷却过程中的能耗。

© 2020 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company. This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

## 1. 引言

鉴于化石燃料紧缺和温室气体排放的严重问题,全球交通运输业正致力于用清洁能源汽车替代传统汽车[1]。其中,可充电电池是发展电动汽车(EV)的核心技术,锂离子电池动力电池由于具有以下优点而被广泛应用于能量供应装置:①高能量密度;②高功率密度;③长循环寿命;④低自放电率。锂离子电池也被广泛应用于不同种类的储能设备[2]。然而,锂离子电池的性能对环境温度十分敏

感。已有研究证明温度对锂离子电池的充放电效率影响较大,这也阻碍了快速充电技术的发展。极端温度会加速电池老化、缩短电池寿命,甚至导致内短路。在快速充电过程中控制最高温度尤为重要[2-4]。此外,电池组温度分布的均匀性也会影响电池单体间的一致性,会导致电池组老化速率的不一致及性能的衰退。鉴于快速充电过程会产生大量的热,将电池组最高温度控制在25~40 °C尤为重要。此外,电池组温度标准差(TSD)应控制在5 °C以内[5-6]。

电池热管理系统由冷却功能部分和加热功能部分构

\* Corresponding author.

E-mail address: [gaoliang@mail.hust.edu.cn](mailto:gaoliang@mail.hust.edu.cn) (L. Gao).

2095-8099/© 2020 THE AUTHORS. Published by Elsevier LTD on behalf of Chinese Academy of Engineering and Higher Education Press Limited Company.

This is an open access article under the CC BY-NC-ND license (<http://creativecommons.org/licenses/by-nc-nd/4.0/>).

英文原文: *Engineering* 2021, 7(8): 1165–1176

引用本文: Siqu Chen, Nengsheng Bao, Akhil Garg, Xiongbin Peng, Liang Gao. A Fast Charging-Cooling Coupled Scheduling Method for a Liquid Cooling-Based Thermal Management System for Lithium-Ion Batteries. *Engineering*, <https://doi.org/10.1016/j.eng.2020.06.016>

成, 此次研究致力于快速充电过程的冷却技术。至今已有多种涉及电池热管理的冷却技术, 如风冷技术、液冷技术、基于相变材料的冷却技术, 以及这些技术的结合。风冷技术凭借较低的成本和相对简单的结构成为电动汽车中应用最为广泛的方法。通过理论分析和实验验证, 开展了大量研究以提升此方法的冷却效果。这些研究包括气流通道结构设计[7-8]、电池单体排布设计[9-11]以及电池热管理系统的控制方法[12]。然而, 因为冷却剂(空气)较低的导热系数, 风冷技术在如高温环境或高充/放电电流倍率工况等极端应用环境下无法提供足够的冷却效果[13]。

相变材料(PCM)因可改善电池组的温度分布均匀性的特点而被应用于热管理系统[14]。然而, 因固有的导热系数较低的性能特点, 相变材料长时间段冷却效果不足, 目前无法被广泛应用于电动汽车[15]。近年来部分研究致力于相变材料在快速充电工况下的应用。为提升其导热系数, 尝试将石蜡与铝、铜、石墨、石墨烯或六方氮化硼结合。然而, 相变材料的潜热却因此结合而降低。此外, 基于相变材料的热管理系统在快速充电工况下将占用大量的体积。8C(1C=5A)充电倍率下, 体积增长量将是一般相变热管理系统的1.50~1.62倍[4,16-17]。

热管凭借汽-液相变的特点也被应用于电池热管理系统[18]。Rao等[19]通过试验探究了热管的冷却效果, 结果表明在单体产热功率低于50W的情况下, 电池模组最高温度可控制在50℃内。Wu等[20]对自然对流、强制对流和热管技术进行了比较, 并得出结论: 热管对于控制温升具有较高的效率。然而, 热管与电池间的有效换热面呈现“线接触”的特征, 这导致了电池模组冷却性能不充分, 同时存在较大的温度标准差[21]。Zhao等[22]设计了一款扁平状、内部配有微流道的热管, 其与方壳电池接触良好, 使其成为冷却结构设计的备选方案之一。

表1对不同热管理方法进行了比较。与其他冷却方法相比, 液冷技术凭借更高的比热容、导热系数而具有更高的冷却效率, 此外, 这种方法可以带来更均匀的温度分布。然而, 液冷系统相对更易出错, 由于需要额外的设备(热管、泵或换热器), 其装配和维护更复杂、昂贵[23]。

然而入口、出口间的压差也无可避免地会产生能耗[23]。此外, 模组中电池单体需被布置在绝热环境中以避免热失控。Mei等[24]建立了三种不同单元数的三维热电耦合模型, 并通过试验在不同放电倍率(0.5C、1C、1.5C和2C)下对其进行验证。结果表明一个单元的模型的计算量更低, 有利于绝热研究。此前有关液冷的研究大多集中于流道的结构设计[25-27]以及冷却介质的导热效果提升[28-30]。Chen等[31]提出了一种针对基于液冷的电池模组的优化设计方法, 并通过实验进行了验证。结果表明电池模组的热特性(最高温度、温度标准差)经结构多目标优化设计得到了显著提升。基于液冷的热管理系统经验证在较宽的电流范围内有效。Panchal等[32]针对电池模组在4C放电倍率下设计了一种液冷板。一种倾泄式液冷结构被证明可将电池模组温度标准差从7℃减少到2℃[33]。

此前的研究已证实了基于液冷的电池模组的优越性, 电池组的最高温度和温度标准差可以控制在合适的范围内。但这些研究大多集中在液冷系统的结构设计和不同工况下基于液冷的电池模组的热性能上, 对快充-冷却耦合的规划研究极少开展。为提升行驶范围和充电效率, 开展快充规划很有必要。此外, 为保证行驶安全、避免过热的同时温度的不均匀分布, 快充过程的热管理也非常重要, 而将快充过程与热管理结合的研究并不多。过程规划设计方案的选择过程实现了充电速度、冷却效率和功耗间的平衡, 对电动汽车而言有实际应用价值。

此研究主要内容如下:

(1) 针对锂离子电池模组设计了一种配有微流道的热管理系统;

(2) 提出一种基于神经网络的回归模型, 用于设计一种高效的快速充电-冷却耦合过程规划方案;

(3) 回归模型被用于预测数据全集的三个结果, 此数据全集由三个不同充电阶段的电流倍率(0.5C、1C、1.5C、2C和2.5C)和冷却液流速( $0.0006 \text{ kg}\cdot\text{s}^{-1}$ 、 $0.0012 \text{ kg}\cdot\text{s}^{-1}$ 、 $0.0018 \text{ kg}\cdot\text{s}^{-1}$ )构成;

(4) 通过设定限制条件, 从预测得到的数据集中筛选出最优快速充电-冷却耦合过程规划方案;

表1 不同热管理系统的优缺点

Cooling method	Advantages	Disadvantages	Applicable type of vehicles
Air cooling	Simple structure and low cost	Large volume cost, low cooling efficiency, and easily influenced by the environment	Bus and car
Phase change material	Uniform temperature distribution	Large volume and mass cost, and high cost for replacement and maintenance	Currently being tested in the laboratory
Liquid cooling	High cooling efficiency, uniform temperature distribution, and continuous and stable cooling performance	High mass cost for equipment and high cost for maintenance	Car, logistics car, and sports car

(5) 对最优过程规划方案进行试验验证。

## 2. 基于液冷的电池模组设计

### 2.1. 针对快速充电的冷却结构设计

基于液冷的电池模组如图1所示。此次研究选择一款容量为5 A·h的锂离子电池，其工作电压为3.20~3.65 V。8节方壳电池（鉴于电池测试设备的电压限制）被布置于液冷板顶端。电池中产生的热量经液冷板由微流道传导、散热，此结构在保证所占体积较小的同时可提供足够的热传导。电池单体间的侧面由隔热棉分隔，以避免电池单体间过热情况下的相互影响，此结构设计更接近于电动汽车的实际应用。

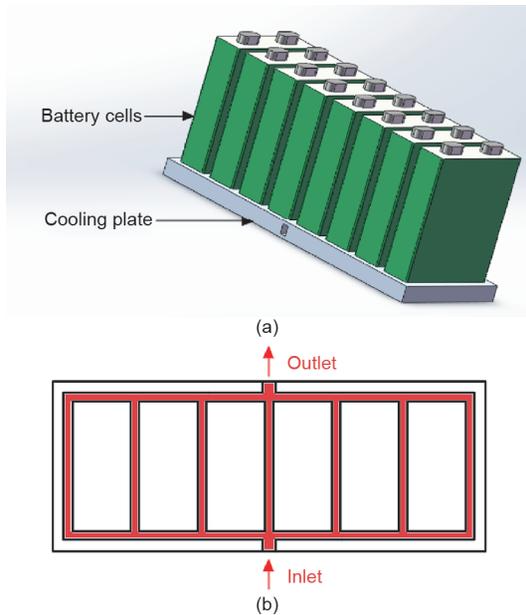


图1. 基于液冷的锂离子电池模组示意图。(a) 电池组示意图；(b) 基于微流道的液冷板示意图。

铝合金7075凭借其高导热系数、低成本的特点被选择作为铣削加工液冷板的材料。防冻液被选择作为冷却液，由乙二醇（50%）和水（50%）混合而成。防冻液因为冰点较低常被用于电动汽车和传统汽车，尤其是高纬度地区。

### 2.2. 实验装置设计

实验装置如图2所示，8节电池单体串联连接，电池模组正负极与电池测试设备（BTS-4000，新威，中国）相连。4只K型热电偶黏在各电池单体的同一侧面以获取15 min快速充电过程的实时温度。压力传感器设置在液冷板入口处，测量实时入口压力。此电池模组温度及压力数

据由数据记录仪（THM001，鹏合电子，中国）进行记录，且其数值由屏幕显示。一台电动蠕动管式泵（Kamoer Lab UIP，卡默尔，中国）用于提供液冷系统液流。实验室环境温度设为25℃。电池组荷电状态（state of charge, SOC）初始值在各组实验前放电至0.2。

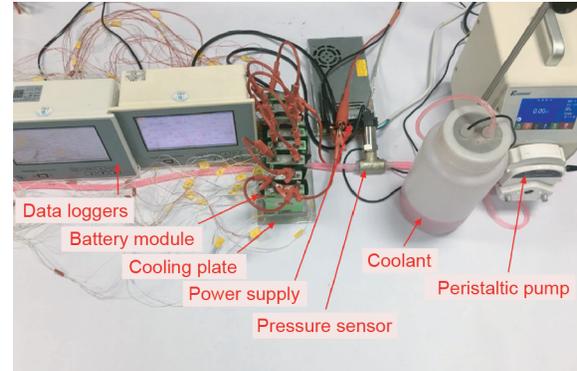


图2. 实验装置示意图。

## 3. 人工神经网络模型

### 3.1. 人工神经网络回归

人工神经网络是一种常用于数据分类或数据预测的机器学习模型。模型结构的构建基于数据和训练规则[34]。神经网络回归模型基于算法运用数据进行训练，随后可用于预测一组数据。

如图3所示，一个神经网络回归模型由许多节点/神经元构成，布置于多层（输入层、一层或多层隐藏层以及一层输出层）结构中[34-36]。各节点/神经元有一个激活函

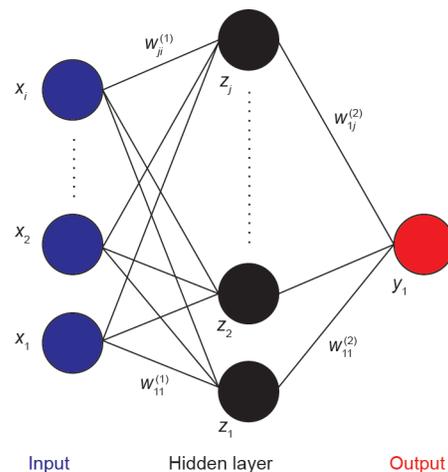


图3. 神经网络示意图。 $x$ 表示第一层的输入； $z$ 表示第一层的输出； $y$ 代表输出； $i$ 和 $j$ 表示神经网络节点索引； $x_i$ 代表输入层的第 $i$ 个输入； $z_j$ 表示第一层的第 $j$ 次输出； $w_{ji}^{(l)}$ 表示第一层中的第 $j$ 个节点和输入层中的第 $i$ 个节点之间的权重。

数，可计算多少神经元被“激活”。各层中节点/神经元的集合可传输输入参数，这些参数将被分布到下一层，具体可由式（1）、（2）和（3）进行描述：

$$z_j^n = \sum (w_{ji}^{(1)} x_i^{n-1} + w_{j0}^{(1)}) \quad (1)$$

$$a_i^n = \sum (w_{ij}^{(2)} z_j^{n-1} + w_{i0}^{(2)}) \quad (2)$$

$$y_i^n = F(a_i^n) \quad (3)$$

式中， $x$ 代表第一层的输入； $z$ 代表第一层的输出； $i, j$ 代表神经网络节点标号； $w_{ji}^{(l)}$ 代表第一层第 $j$ 个节点和第 $l+1$ 层第 $i$ 个节点间的权重； $n$ 表示层的标号； $F(a_i^n)$ 代表经激活函数激活后第 $n+1$ 层第 $i$ 个节点的输出参数值； $w$ 和 $w_0$ 代表神经元间的权重和偏向，其测量沿着连接（突触）传递的数据的重要性； $F(a)$ 代表激活函数，其使用隐藏层的聚合输出来计算输出 $y$  [35,37]。

初始权重和偏向为随机分配，训练过程持续到获得理想的输出，其可由价值函数，即式（4）进行评价。

$$E(w) = \frac{1}{2} \sum_{k=1}^K y(x_k, w_k) - o_k^2 \quad (4)$$

式中， $o$ 代表理想的输出； $E(w)$ 代表评估培训过程的成本函数； $w$ 代表重量； $k$ 表示成本函数计算的指标。Levenberg-Marquardt (LM) 被用于神经网络模型的训练过程，这是梯度下降的一种变化。在训练过程中，对神经网络模型的权重和偏向进行调整以使误差最小化，具体可由式（5）进行描述：

$$w^n = w^{n-1} - (J^T J + \mu I)^{-1} J e^{n-1} \quad (5)$$

式中， $J = \partial E / \partial w$ 代表有关于权重 $w$ 的全尺寸雅克比矩阵； $I$ 代表标号矩阵； $\mu$ 代表组合系数； $e$ 代表预测误差。

Levenberg-Marquardt 算法开始于如式（1）、（2）和（3）所示的前向计算。输出层和隐藏层的预测误差可由式（6）、（7）和（8）表示：

$$e_i^{(3)} = y_i - o \quad (6)$$

$$\delta_i^{(3)} = e_i^{(3)} \quad (7)$$

$$\delta_j^{(2)} = w_{ij} \delta_i^{(3)} \quad (8)$$

式中， $\delta$ 代表输出层的预测误差。

如式（9）和（10）所示，雅克比矩阵可由反向传播过程进行计算：

$$\frac{\partial E}{\partial w_{ji}} = \delta_j^{(2)} x_i \quad (9)$$

$$\frac{\partial E}{\partial w_{ij}} = \delta_i^{(3)} z_j \quad (10)$$

### 3.2. 神经网络模型构成

如图4所示，整个充电过程被划分为三个阶段，每个阶段持续5 min。 $I_1$ 、 $I_2$ 和 $I_3$ 代表各阶段充电电流； $Q$ 代表

充电过程冷却液流量； $I_1$ 、 $I_2$ 、 $I_3$ 和 $Q$ 被设为神经网络模型的输入参数。

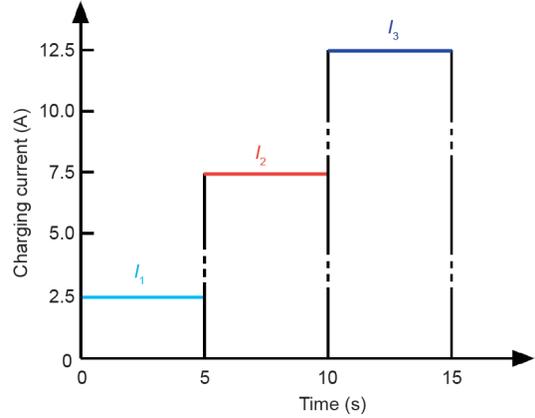


图4. 快速充电过程三阶段示意图。

本研究有以下三个目标参数：①最高温度（ $T_{max}$ ）；②温度标准差；③快速充电过程功耗（ $W$ ）。这三个目标参数被设为神经网络模型（ $NN_1$ 、 $NN_2$ 、 $NN_3$ ）的输出参数。

液冷系统功耗可由式（11）进行计算：

$$W = \int P(t) dt \quad (11)$$

式中， $P$ 代表液冷系统功耗； $t$ 代表时间。

温度标准差是基于所有温度传感器测得的温度值，可由式（12）进行计算：

$$TSD = \sqrt{\frac{1}{32} \sum_{r=1}^{32} (T_r - \bar{T})^2} \quad (12)$$

式中， $T_r$ 代表各温度传感器测得的温度值； $\bar{T}$ 代表各温度传感器测得的温度平均值； $r$ 代表电池单体编号。

所有训练数据均通过实验测得，试验中三阶段充电倍率如下：① 0.5C；② 1.5C；③ 2.5C。充电过程冷却液流量如下：① 36 mL·min<sup>-1</sup>；② 72 mL·min<sup>-1</sup>；③ 108 mL·min<sup>-1</sup>。如图5所示，81组实验数据被用于模型训练过程。

理论容量的定义基于电极中所有活性物质参与电池的化学反应的假设，具体处理为基于法拉第定律计算得到的理论最高值。此次研究中，电池理论容量为5 A·h。电

	$I_1$ (A)	$I_2$ (A)	$I_3$ (A)	$Q$ (mL·min <sup>-1</sup> )
Training data	2.5	2.5	2.5	36
	7.5	7.5	7.5	72
	12.5	12.5	12.5	108

3 × 3 × 3 × 3 = 81 sets

图5. 基于实验的训练数据构成。

池模组荷电状态值被用于评价充电效果，具体计算如式(13)所示：

$$\text{SOC} = \frac{\text{SOC}_0 + \int I(t) dt}{\text{Capacity}_{\text{theoretical}}} \times 100\% \quad (13)$$

式中， $I$ 代表充电电流。

训练数据集及相应的荷电状态值如表2所示。

### 3.3. 神经网络回归模型结构

不同于一些电池的基于行为的控制方程，神经网络回

表2 神经网络模型训练数据集

Number	Input parameters				Evaluating parameter $\Delta\text{SOC}$	Output parameters		
	$I_1$ (A)	$I_2$ (A)	$I_3$ (A)	$Q$ (mL·min <sup>-1</sup> )		$T_{\text{max}}$ (K)	TSD (K)	$W$ (J)
1	2.5	2.5	2.5	108	0.125000	26.1	0.4129	0.069725
2	7.5	2.5	2.5	108	0.208333	27.3	0.3682	0.063342
3	12.5	2.5	2.5	108	0.291667	28.3	0.5135	0.071086
4	2.5	7.5	2.5	108	0.208333	27.4	0.2596	0.084564
5	7.5	7.5	2.5	108	0.291667	27.6	0.3949	0.068818
6	12.5	7.5	2.5	108	0.375000	31.8	0.7023	0.084451
7	2.5	12.5	2.5	108	0.291667	29.1	0.5339	0.070259
8	7.5	12.5	2.5	108	0.375000	31.8	0.9332	0.077144
9	12.5	12.5	2.5	108	0.458333	32.3	0.8238	0.072041
10	2.5	2.5	7.5	108	0.208333	27.4	0.3809	0.069482
11	7.5	2.5	7.5	108	0.291667	28.5	0.4258	0.062953
12	12.5	2.5	7.5	108	0.375000	30.6	0.8403	0.072074
13	2.5	7.5	7.5	108	0.291667	28.1	0.3837	0.073613
14	7.5	7.5	7.5	108	0.375000	31.6	0.7798	0.072317
15	12.5	7.5	7.5	108	0.458333	33.2	0.9740	0.081875
16	2.5	12.5	7.5	108	0.375000	32.7	0.6894	0.075719
17	7.5	12.5	7.5	108	0.458333	32.4	0.7955	0.087269
18	12.5	12.5	7.5	108	0.541667	35.1	1.1011	0.073321
19	2.5	2.5	12.5	108	0.291667	30.9	0.5572	0.079315
20	7.5	2.5	12.5	108	0.375000	30.6	0.6335	0.072236
21	12.5	2.5	12.5	108	0.458333	32.3	0.7241	0.083608
22	2.5	7.5	12.5	108	0.375000	30.2	0.5730	0.069498
23	7.5	7.5	12.5	108	0.458333	32.0	0.7632	0.080449
24	12.5	7.5	12.5	108	0.541667	34.3	1.1734	0.083981
25	2.5	12.5	12.5	108	0.458333	29.4	0.5591	0.094235
26	7.5	12.5	12.5	108	0.541667	35.3	0.9918	0.074471
27	12.5	12.5	12.5	108	0.625000	38.0	1.4759	0.075411
28	2.5	2.5	2.5	36	0.125000	26.8	0.2462	0.015973
29	7.5	2.5	2.5	36	0.208333	27.2	0.4668	0.019013
30	12.5	2.5	2.5	36	0.291667	28.8	0.5869	0.020596
31	2.5	7.5	2.5	36	0.208333	26.8	0.6606	0.019694
32	7.5	7.5	2.5	36	0.291667	28.4	0.3939	0.021778
33	12.5	7.5	2.5	36	0.375000	29.2	0.6031	0.017685
34	2.5	12.5	2.5	36	0.291667	28.6	0.5454	0.023150
35	7.5	12.5	2.5	36	0.375000	31.1	0.7081	0.016902
36	12.5	12.5	2.5	36	0.458333	33.7	0.7630	0.019591
37	2.5	2.5	7.5	36	0.208333	27.1	0.5199	0.021292
38	7.5	2.5	7.5	36	0.291667	27.3	0.4634	0.018824
39	12.5	2.5	7.5	36	0.375000	31.8	0.5669	0.018619
40	2.5	7.5	7.5	36	0.291667	28.2	0.5400	0.019219

Number	Input parameters				Evaluating parameter $\Delta$ SOC	Output parameters		
	$I_1$ (A)	$I_2$ (A)	$I_3$ (A)	$Q$ (mL·min <sup>-1</sup> )		$T_{\max}$ (K)	TSD (K)	$W$ (J)
41	7.5	7.5	7.5	36	0.375000	30.3	0.7927	0.020504
42	12.5	7.5	7.5	36	0.458333	32.1	0.6227	0.020407
43	2.5	12.5	7.5	36	0.375000	30.3	0.4976	0.020957
44	7.5	12.5	7.5	36	0.458333	32.8	0.6300	0.020682
45	12.5	12.5	7.5	36	0.541667	33.8	0.8014	0.018479
46	2.5	2.5	12.5	36	0.291667	28.7	0.5205	0.020585
47	7.5	2.5	12.5	36	0.375000	31.1	0.5642	0.016524
48	12.5	2.5	12.5	36	0.458333	33.5	0.7250	0.021827
49	2.5	7.5	12.5	36	0.375000	33.7	1.1370	0.017167
50	7.5	7.5	12.5	36	0.458333	32.2	0.5482	0.018571
51	12.5	7.5	12.5	36	0.541667	34.2	0.8794	0.018630
52	2.5	12.5	12.5	36	0.458333	34.1	1.3452	0.018808
53	7.5	12.5	12.5	36	0.541667	33.6	0.9299	0.022351
54	12.5	12.5	12.5	36	0.625000	35.4	0.9096	0.023992
55	2.5	2.5	2.5	72	0.125000	26.2	0.3001	0.041008
56	7.5	2.5	2.5	72	0.208333	26.7	0.3742	0.046310
57	12.5	2.5	2.5	72	0.291667	29.0	0.5135	0.046926
58	2.5	7.5	2.5	72	0.208333	26.7	0.4392	0.049216
59	7.5	7.5	2.5	72	0.291667	28.4	0.4938	0.051646
60	12.5	7.5	2.5	72	0.375000	30.1	0.4827	0.039182
61	2.5	12.5	2.5	72	0.291667	28.4	0.4117	0.039064
62	7.5	12.5	2.5	72	0.375000	30.4	0.4655	0.043211
63	12.5	12.5	2.5	72	0.458333	32.7	0.7315	0.044064
64	2.5	2.5	7.5	72	0.208333	27.5	0.6321	0.041278
65	7.5	2.5	7.5	72	0.291667	27.6	0.4295	0.044345
66	12.5	2.5	7.5	72	0.375000	30.0	0.5010	0.048924
67	2.5	7.5	7.5	72	0.291667	27.9	0.4536	0.047855
68	7.5	7.5	7.5	72	0.375000	29.7	0.3648	0.037930
69	12.5	7.5	7.5	72	0.458333	32.7	0.7269	0.037552
70	2.5	12.5	7.5	72	0.375000	30.4	0.7312	0.044539
71	7.5	12.5	7.5	72	0.458333	31.9	0.7326	0.045144
72	12.5	12.5	7.5	72	0.541667	34.1	0.7250	0.042120
73	2.5	2.5	12.5	72	0.291667	29.0	0.5479	0.054475
74	7.5	2.5	12.5	72	0.375000	31.1	0.6193	0.047423
75	12.5	2.5	12.5	72	0.458333	34.4	1.1914	0.040241
76	2.5	7.5	12.5	72	0.375000	31.3	0.5785	0.052909
77	7.5	7.5	12.5	72	0.458333	33.3	0.8902	0.049464
78	12.5	7.5	12.5	72	0.541667	35.9	1.0829	0.049399
79	2.5	12.5	12.5	72	0.458333	33.3	0.7716	0.055804
80	7.5	12.5	12.5	72	0.541667	35.6	1.0460	0.044712
81	12.5	12.5	12.5	72	0.625000	36.9	1.0378	0.052693

归模型是一种“黑箱”模型，无法提供模型隐藏层如何工作的视角。此外，非线性神经网络回归模型存在两个问题：①欠拟合或过度拟合；②训练过程可能停滞于局部最优。

为获得更好的回归效果，提出了一些解决方法：①输入参数预处理，这样可以从中提取一些有代表性的特征；②提升训练数据集的整体比例以覆盖预期运行范围；③遇到未知的用法配置文件时，为提升训练质量进行详尽

的交叉验证[34]。

三个神经网络回归子模型的构成如表3所示。每个模型由三层构成，这些模型的训练过程设计有着相同的激活函数（前馈Levenberg-Marquardt反向传播法）。如图6所示，传统的神经网络模型可分为三个子模型，每一个有着不同的目标参数（输出参数）。每个输入层由四个输入参数（ $I_1$ 、 $I_2$ 、 $I_3$ 和 $Q$ ）构成，而后是隐藏层。输出参数的评估对每一个输入层进行响应，输入层节点数量显示了模型输入参数的数量。为获得连续性的结果，隐藏层将被注入另一个聚合层，然后结合前面层的结果，并将其注入输出层。为避免过度拟合和欠拟合，隐藏层设置两个节点/神经元以获得理想的回归效果。81组实验数据中，73组（90%）用于训练，4组（5%）用于验证，4组（5%）用于测试。神经网络回归训练过程设置了1000个训练阶段数。

表3 三个神经网络回归子模型的构成

Model	Input parameters	Output parameter
NN <sub>1</sub>	$I_1, I_2, I_3, Q$	$T_{\max}$
NN <sub>2</sub>	$I_1, I_2, I_3, Q$	TSD
NN <sub>3</sub>	$I_1, I_2, I_3, Q$	$W$

### 3.4. 神经网络模型回归性能评估

如3.3节所描述，Levenberg-Marquardt反向传播方法被采用，通过引入纯误差反向传播和最快速下降方法提升模型训练速度，此算法保证了所训练模型的准确性。

神经网络回归模型在所设计模型结构、输入参数、节点数的设定下展开训练。模型训练和预测/评估准确性通

过平均绝对误差（MSE）进行评估，具体由式（14）进行描述：

$$e_{\text{avg}} = \frac{1}{M} \sum_{m=1}^M \left| \text{Output}_m - \text{Output}_{r,m} \right| \quad (14)$$

式中， $e_{\text{avg}}$ 代表平均绝对误差； $M$ 代表数据点数量； $\text{Output}_m$ 代表第 $m$ 个预测的输出参数； $\text{Output}_{r,m}$ 代表第 $m$ 个参数输出参数。神经网络预测的最小误差被证实每个输出参数预测层节点数设置为2时最小。

神经网络回归子模型的训练过程如图7所示。通过以上神经网络结构设计，预测性能可得到提升，在训练过程中三个回归子模型在初始化后都达到了理想的误差收敛速度。

如图8所示，训练过程可实现较高的拟合准确性。对于训练过程，NN<sub>1</sub>、NN<sub>2</sub>和NN<sub>3</sub>的拟合准确率分别为95.123%、82.866%和98.142%；测试过程NN<sub>1</sub>、NN<sub>2</sub>和NN<sub>3</sub>的拟合准确率分别为99.353%、97.332%和98.381%；NN<sub>1</sub>、NN<sub>2</sub>和NN<sub>3</sub>的整体拟合准确率分别为95.478%、83.496%和98.049%。三个神经网络回归子模型呈现出较高的准确性，尤其是在测试过程中，输出参数的预测值与参考值较为接近。预测得到的功耗与测量值之间存在较小差别，但相差在容许范围内。结果表明输入参数与输出参数间的关系已较好地建立起来，三个子模型具有较好的回归性能，因而所做预测/评估较为可靠。

三个神经网络回归模型的误差直方图如图9所示。对于本研究所提出的三个神经网络回归子模型，20个柱呈高斯分布，证明此次训练数据具有代表性。

## 4. 最优充电-冷却过程规划选择与实验验证

### 4.1. 基于回归模型的快速充电-冷却过程规划评估

神经网络回归模型被用于评估给定输入参数组合的结果。预测所得结果与实验结果参考值对比证明训练所得模型的准确性和稳定性。

基于快速充电技术电流倍率特点，五个充电倍率被选择应用于快速充电三个阶段：① 0.5C；② 1C；③ 1.5C；④ 2C；⑤ 2.5C。三个冷却液流量被选择应用于充电过程：① 36 mL·min<sup>-1</sup>；② 72 mL·min<sup>-1</sup>；③ 108 mL·min<sup>-1</sup>。图10展示了快充过程设计的各种组合。

数据全集中含有375组快速充电-冷却过程规划设计方案，各方案的最高温度、温度标准差和功耗通过所提出的三个神经网络回归子模型（NN<sub>1</sub>、NN<sub>2</sub>、NN<sub>3</sub>）进行预测。这些快速充电-冷却过程规划方案的具体信息和荷电状态值如Appendix A中的表S1所示。

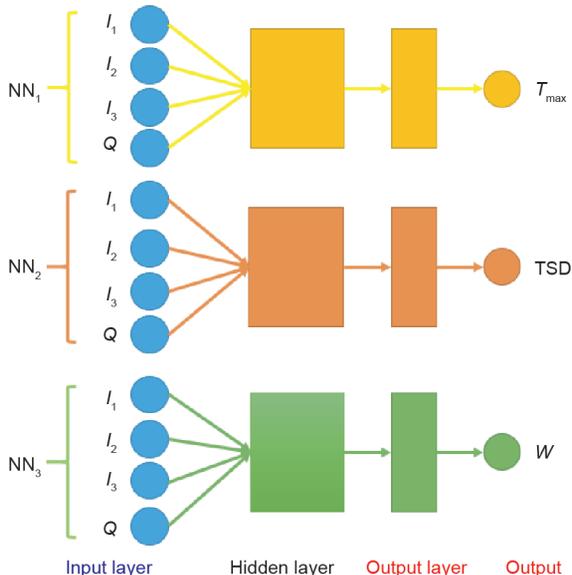


图6. 本研究所提出的神经网络模型示意图。

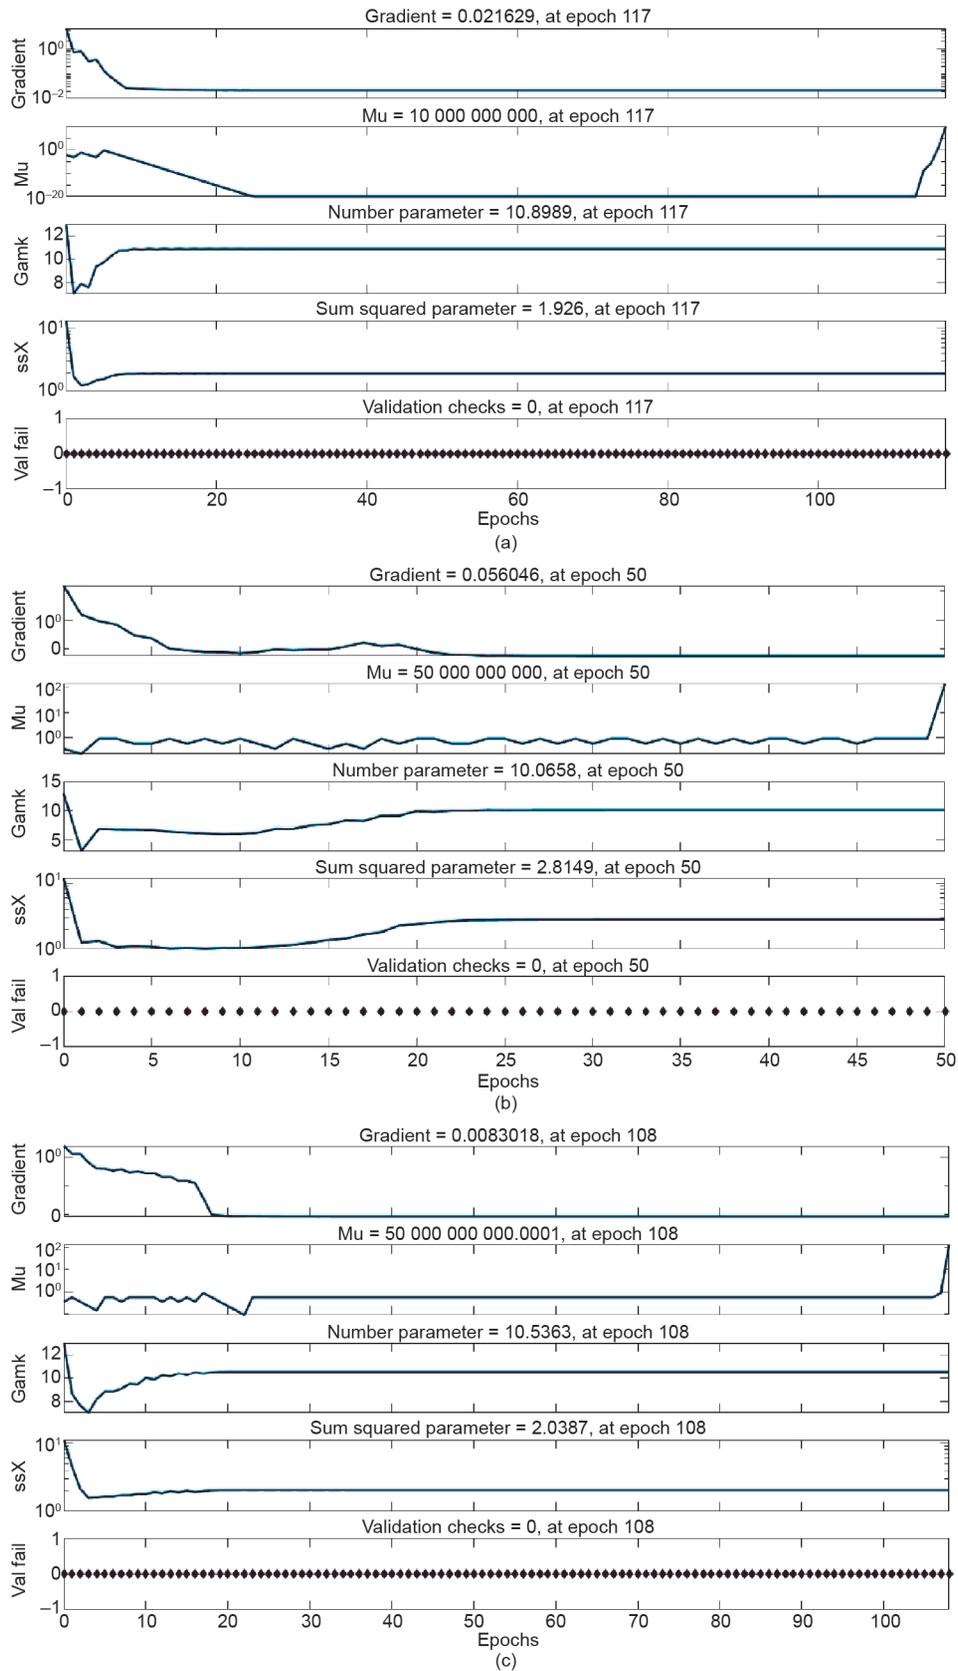


图7. 三个神经网络回归子模型的训练过程示意图。(a)  $NN_1$  的训练过程；(b)  $NN_2$  的训练过程；(c)  $NN_3$  的训练过程。Mu: 衰减系数；Gamk: 显示频率；ssX: 膨胀因子；Val fail: 验证失败时长。

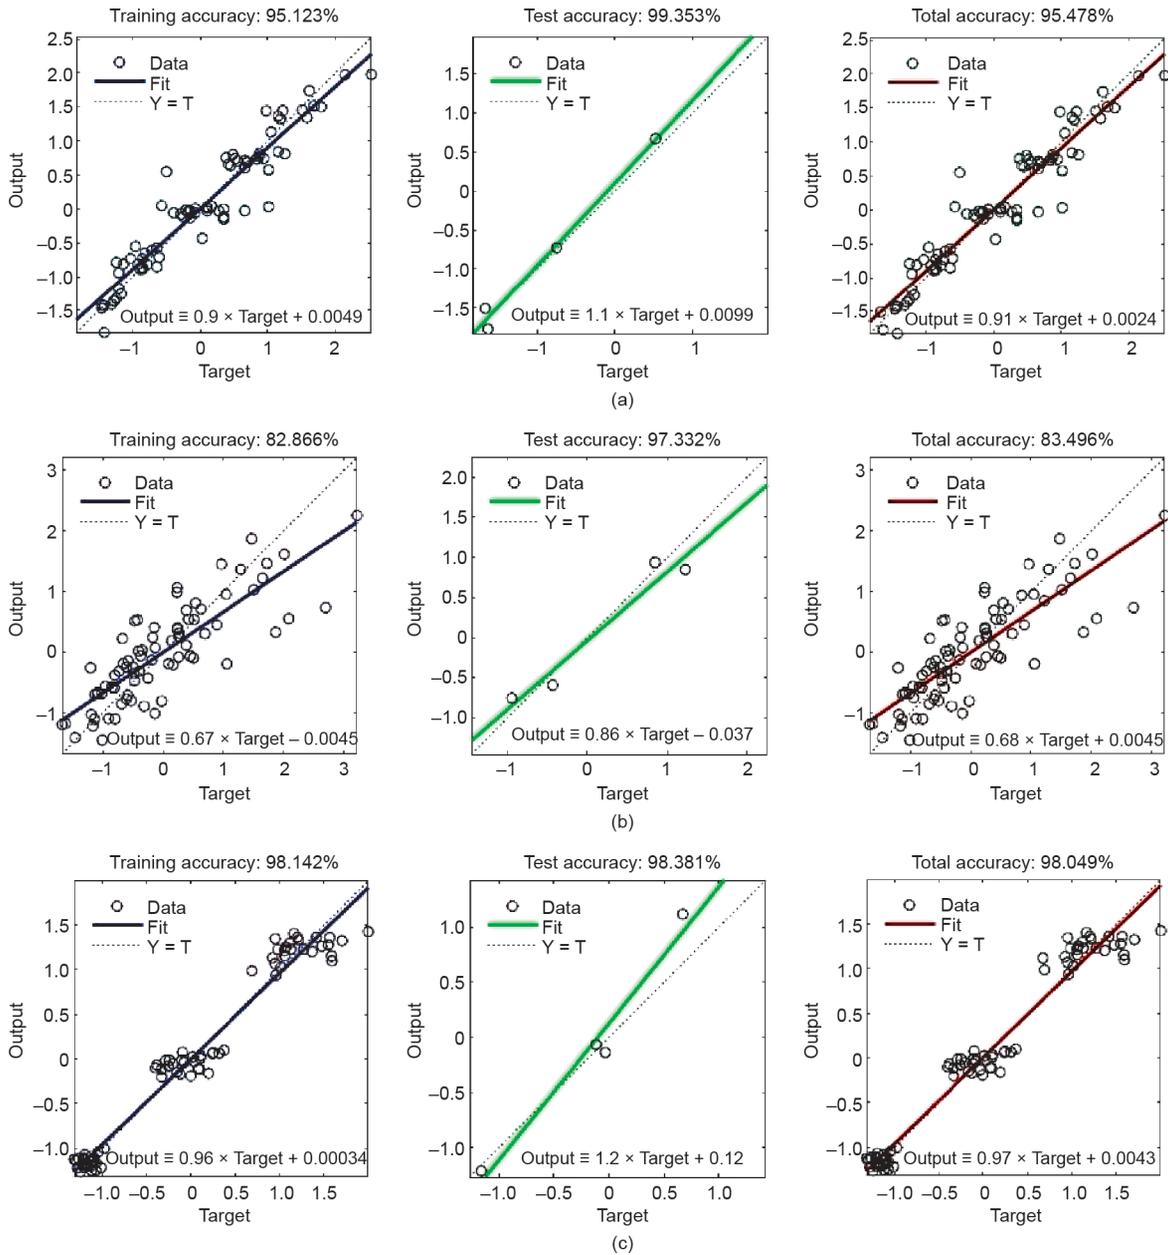


图8. 三个神经网络回归模型回归性能。(a)  $NN_1$ 的回归性能；(b)  $NN_2$ 的回归性能；(c)  $NN_3$ 的回归性能。 $Y=T$ ：理想状态下拟合率为100%的趋势线； $Y$ ：输出； $T$ ：目标。

#### 4.2. 最优充电-冷却过程规划方案筛选

为获得最高效的快速充电过程规划方案，电池模组的热特性（最高温度和温度标准差）应得到控制，电池模组的荷电状态值应在短时间内充至较高值，同时冷却系统的功耗应得到控制。

在本研究中，最优快速充电-冷却过程规划方案选择的具体要求如下：

- (1) 电池模组的荷电状态值在快充过程（15 min）后可增长0.5；
- (2) 电池模组最高温度可控制在306.5 K（33.35 °C）

以内；

- (3) 电池模组温度标准差可控制在0.8 °C以内；
- (4) 快速充电过程冷却系统功耗控制在0.02 J以内。

以上限制条件对筛选一个详尽、可靠的充电-冷却过程规划方案十分重要。冷却效果、温度分布均匀性、充电速度和功耗同等重要。具体筛选标准如式（15）所示：

$$\begin{cases} \Delta SOC \geq 0.5 \\ T_{\max} \leq 33.35 \text{ } ^\circ\text{C} \\ TSD \leq 0.8 \text{ } ^\circ\text{C} \\ W \leq 0.02 \text{ J} \end{cases} \quad (15)$$

规划方案50被选为最优快速充电-冷却过程规划方

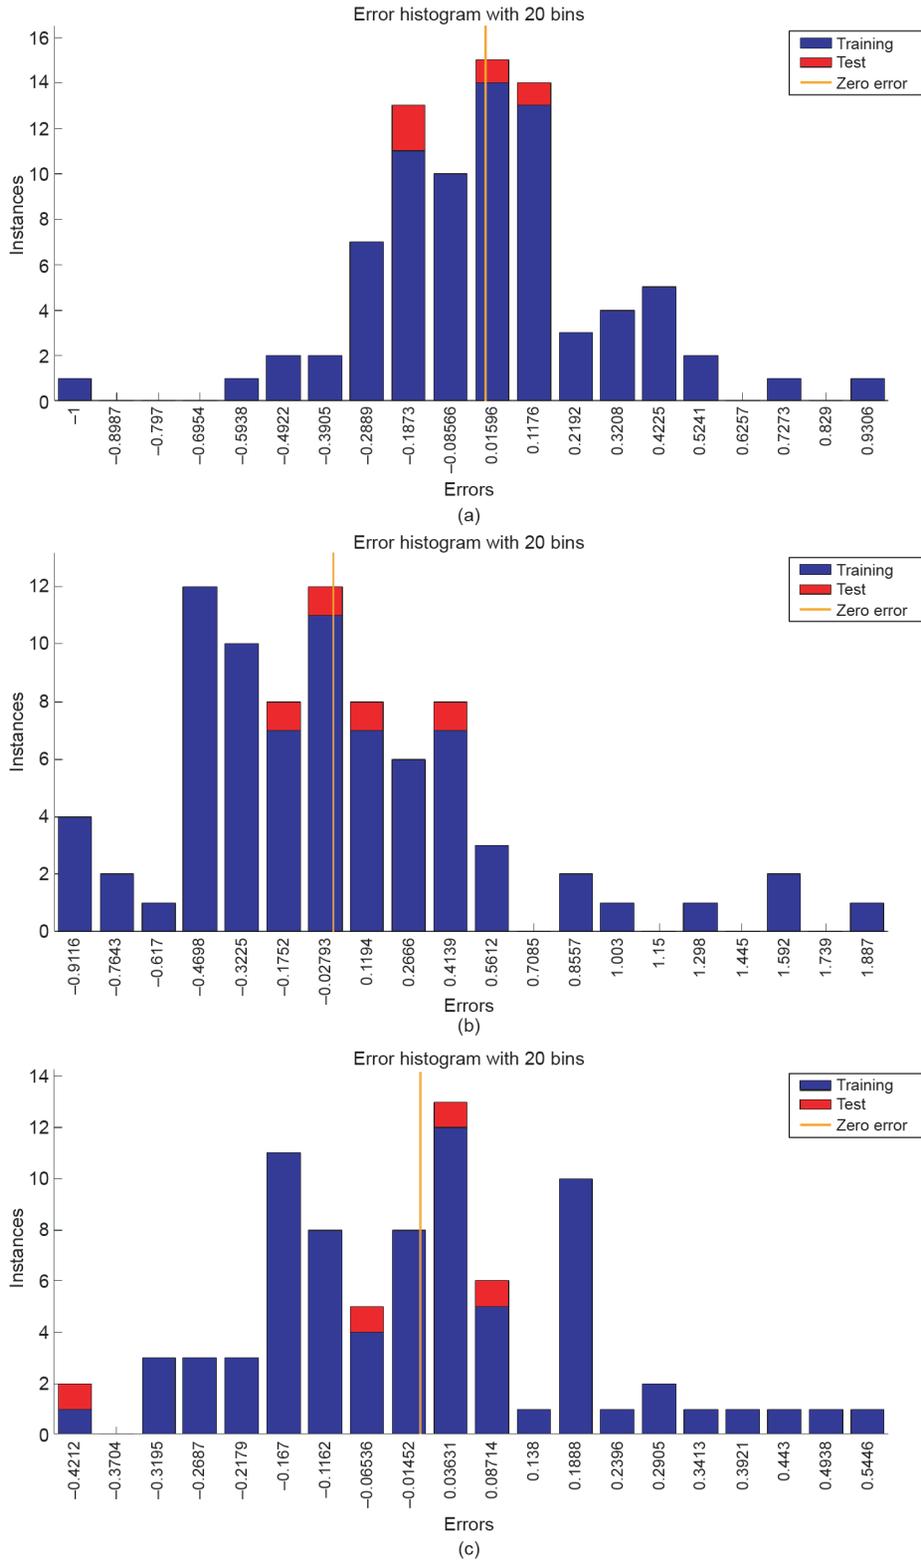


图9. 神经网络回归模型误差直方图。(a) NN<sub>1</sub>的误差直方图；(b) NN<sub>2</sub>的误差直方图；(c) NN<sub>3</sub>的误差直方图。误差=目标 - 输出。

案，对其采用上述实验设备进行了验证。

力曲线。

### 4.3. 实验验证

最优快速充电-冷却过程规划方案的预测值和实验数据比较如表4所示。

图11~12分别展示了规划方案50的温升曲线和入口压

如结果所示，预测值与实验值相差在可容许范围内。

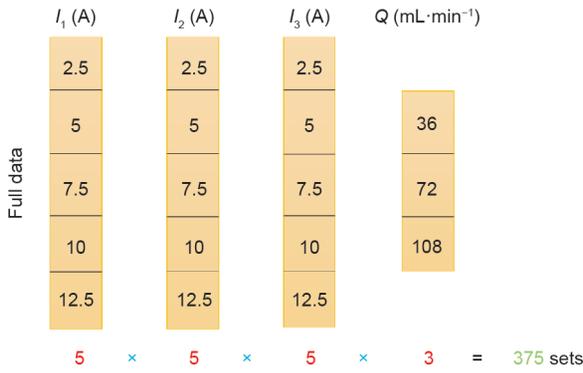


图10. 快充过程设计的各种组合。

最高温度、温度标准差和冷却系统功耗的偏差分别为 0.468 °C、0.045327 °C 和 0.001694 J。这证明了所提出的三个神经网络回归子模型的预测准确性。此模型可在较低成本下用于快速充电-冷却耦合规划。

### 5. 结论与未来的工作

本文针对快速充电-冷却耦合过程规划，提出了一种基于神经网络的回归模型，可显著节省快速充电和冷却过程设计的时间和成本。所提出的模型可实现理想的回归效果，而所设计模型结构使预测更准确。本文结论如下。

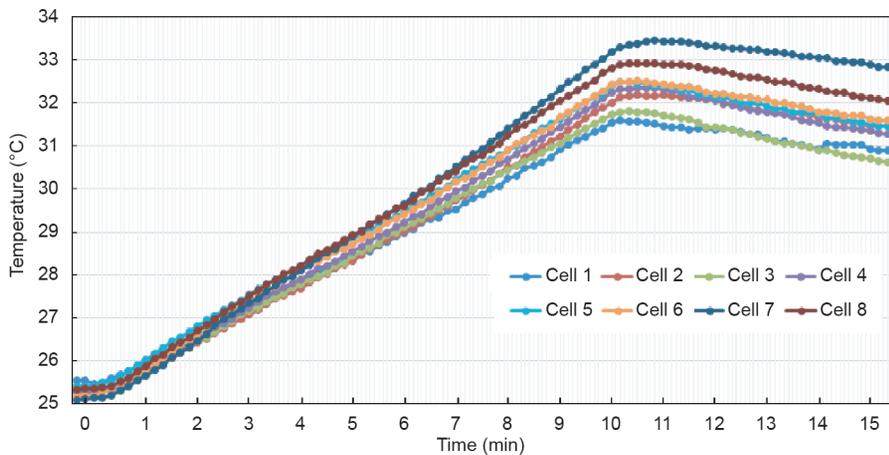


图11. 规划方案50的升温曲线。

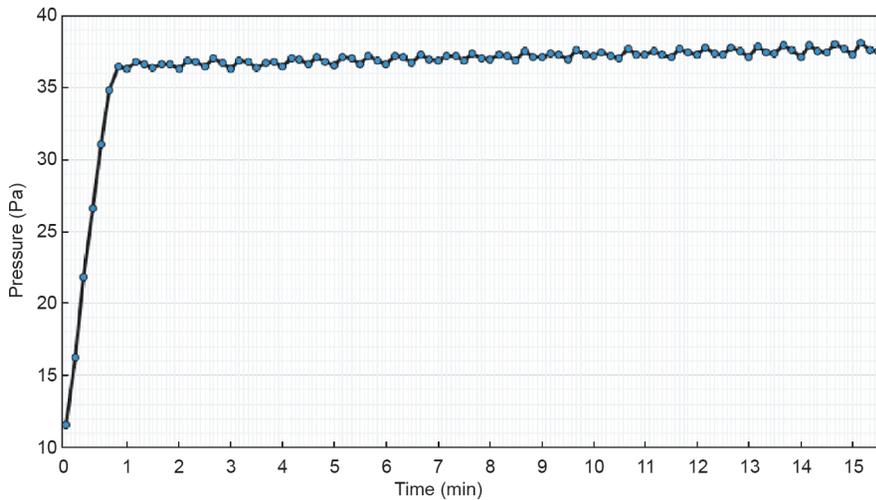


图12. 规划方案50的入口压力曲线。

表4 筛选所得最优快速充电-冷却过程规划方案的预测值和实验数据比较

Parameter	$I_1$ (A)	$I_2$ (A)	$I_3$ (A)	$Q$ (mL·min <sup>-1</sup> )	$\Delta$ SOC	$T_{max}$ (K)	TSD (K)	$W$ (J)
Predicted data	12.5	12.5	5.0	36	0.5	33.268	0.725872	0.019196
Experimental validation	12.5	12.5	5.0	36	0.5	32.800	0.680500	0.017502

(1) 此模型基于81组实验数据进行训练,由三个考虑以下目标参数的子模型构成:最高温度、温度标准差和冷却系统功耗的偏差。回归结果在测试环节呈现较高的准确率:99.353%、97.332%和98.381%。

(2) 回归模型被用于预测由三个充电阶段更宽范围充电倍率(0.5C、1C、1.5C、2C和2.5C)和冷却液流量( $0.0006 \text{ kg}\cdot\text{s}^{-1}$ 、 $0.0012 \text{ kg}\cdot\text{s}^{-1}$ 和 $0.0018 \text{ kg}\cdot\text{s}^{-1}$ )所构成的数据集的目标参数值。此外,通过对所预测数据集的目标参数值进行限制,可筛选出最优快速充电-冷却过程规划方案。

(3) 最优过程规划方案经实验验证,结果表明电池模组的荷电状态值在15 min充电过程后增长了0.5;此过程冷却系统功耗可控制在0.02 J;最高温度和温度标准差分别控制在33.35 °C和0.8 °C以内。

此方法可用于电动汽车的实际快速充电工况,实验数据可用于回归训练,用于预测最优快速充电-冷却过程规划方案,显著提升充电过程设计效率并控制冷却过程功耗。

未来的工作可致力于开发、训练覆盖更多工况的神经网络模型,环境温度变化及电池老化也可以被考虑到研究当中。

## 致谢

本研究得到了华中科技大学学术前沿青年团队项目(2017QYTD04)、华中科技大学研究生创新创业基金项目(2019YGSCXC037)的支持。感谢华中科技大学数字制造装备与技术国家重点实验室基金(DMEKF2018019)的资助。本研究也得到了广东省科技项目(2016B020240001)和广东省自然科学基金(2018A030310150)的资助。

## Compliance with ethics guidelines

Siqi Chen, Nengsheng Bao, Akhil Garg, Xiongbin Peng, and Liang Gao declare that they have no conflict of interest or financial conflicts to disclose.

## Appendix A. Supplementary data

Supplementary data to this article can be found online at <https://doi.org/10.1016/j.ultsonch.2019.104640>.

## References

- [1] Fathabadi H. A novel design including cooling media for lithium-ion batteries pack used in hybrid and electric vehicles. *J Power Sources* 2014; 245:495–500.
- [2] Jaguemont J, Boulon L, Dubé Y. A comprehensive review of lithium-ion batteries used in hybrid and electric vehicles at cold temperatures. *Appl Energy* 2016; 164:99–114.
- [3] Sun J, Li J, Zhou T. Toxicity, a serious concern of thermal runaway from commercial Li-ion battery. *Nano Energy* 2016; 27:313–9.
- [4] Wang Q, Jiang B, Li B, Yan Y. A critical review of thermal management models and solutions of lithium-ion batteries for the development of pure electric vehicles. *Renew Sustain Energy Rev* 2016; 64:106–28.
- [5] Pesaran AA. Battery thermal models for hybrid vehicle simulations. *J Power Sources* 2002; 110(2):377–82.
- [6] Dan D, Yao C, Zhang Y, Zhang H, Zeng Z, Xu X. Dynamic thermal behavior of micro heat pipe array-air cooling battery thermal management system based on thermal network model. *Appl Therm Eng* 2019; 162:114183.
- [7] Park H. A design of air flow configuration for cooling lithium ion battery in hybrid electric vehicles. *J Power Sources* 2013; 239:30–6.
- [8] Liu Z, Wang Y, Zhang J, Liu Z. Shortcut computation for the thermal management of a large air-cooled battery pack. *Appl Therm Eng* 2014; 66(1–2): 445–52.
- [9] He F, Li X, Ma L. Combined experimental and numerical study of thermal management of battery module consisting of multiple Li-ion cells. *Int J Heat Mass Transfer* 2014; 72:622–9.
- [10] Chen K, Song M, Wei W, Wang S. Structure optimization of parallel air-cooled battery thermal management system with U-type flow for cooling efficiency improvement. *Energy* 2018; 145:603–13.
- [11] Yang N, Zhang X, Li Z, Hua D. Assessment of the forced air-cooling performance for cylindrical lithium-ion battery packs: a comparative analysis between aligned and staggered cell arrangements. *Appl Therm Eng* 2015; 80: 55–65.
- [12] Mahamud R, Park C. Reciprocating air flow for Li-ion battery thermal management to improve temperature uniformity. *J Power Sources* 2011; 196 (13):5685–96.
- [13] Fathabadi H. High thermal performance lithium-ion battery pack including hybrid active – passive thermal management system for using in hybrid/electric vehicles. *Energy* 2014; 70:529–38.
- [14] Sabbah R, Kizilel R, Selman JR. Active (air-cooled) vs. passive (phase change material) thermal management of high power lithium-ion packs: limitation of temperature rise and uniformity of temperature distribution. *J Power Sources* 2008; 182(2):630–8.
- [15] Wu W, Yang X, Zhang G. Experimental investigation on the thermal performance of heat pipe-assisted phase change material based battery thermal management system. *Energy Convers Manage* 2017; 138:486–92.
- [16] Zheng Y, Shi Y, Huang Y. Optimisation with adiabatic interlayers for liquid-dominated cooling system on fast charging battery packs. *Appl Therm Eng* 2019; 147:636–46.
- [17] Li J, Huang J, Cao M. Properties enhancement of phase-change materials via silica and Al honeycomb panels for the thermal management of LiFeO<sub>4</sub> batteries. *Appl Therm Eng* 2018; 131:660–8.
- [18] Park Y, Jun S, Kim S, Lee DH. Design optimization of a loop heat pipe to cool a lithium ion battery onboard a military aircraft. *J Mech Sci Technol* 2010; 24 (2):609–18.
- [19] Rao Z, Wang S, Wu M, Lin Z, Li F. Experimental investigation on thermal management of electric vehicle battery with heat pipe. *Energy Convers Manage* 2013; 65:92–7.
- [20] Wu MS, Liu KH, Wang YY, Wan CC. Heat dissipation design for lithium-ion batteries. *J Power Sources* 2002; 109(1):160–6
- [21] Ye Y, Bernard LHS, Shi Y, Tay AAO. Numerical analyses on optimizing a heat pipe thermal management system for lithium-ion batteries during fast charging. *Appl Therm Eng* 2015; 86:281–91.
- [22] Zhao Y, Zhang K, Diao Y, inventors; Guangwei Hetong Energy Technology Beijing Co. Ltd., assignee. Heat pipe with micro-pore tubes array and making method thereof and heat exchanging system. US patent US 20110203777 A1. 2011 Aug 25.
- [23] Khateeb SA, Farid MM, Selman JR, Al-Hallaj S. Design and simulation of a lithium-ion battery with a phase change material thermal management system for an electric scooter. *J Power Sources* 2004; 128(2):292–307.
- [24] Mei W, Duan Q, Zhao C, Lu W, Sun J, Wang Q. Three-dimensional layered electrochemical-thermal model for a lithium-ion pouch cell. Part II. The effect

- of units number on the performance under adiabatic condition during the discharge. *Int J Heat Mass Transf* 2020; 148:119082.
- [25] Jarrett A, Kim IY. Design optimization of electric vehicle battery cooling-plates for thermal performance. *J Power Sources* 2011; 196(23): 10359–68.
- [26] Qian Z, Li Y, Rao Z. Thermal performance of lithium-ion battery thermal management system by using mini-channel cooling. *Energy Convers Manage* 2016; 126:622–31.
- [27] Basu S, Hariharan KS, Kolake SM. Coupled electrochemical thermal modelling of a novel Li-ion battery pack thermal management system. *Appl Energy* 2016; 181:1–13.
- [28] Huo Y, Rao Z. The numerical investigation of nanofluid based cylinder battery thermal management using lattice Boltzmann method. *Int J Heat Mass Transf* 2015; 91:374–84.
- [29] Yang XH, Tan SC, Liu J. Thermal management of Li-ion battery with liquid metal. *Energy Convers Manage* 2016; 117:577–85.
- [30] Wu F, Rao Z. The lattice Boltzmann investigation of natural convection for nanofluid based battery thermal management. *Appl Therm Eng* 2017; 115: 659–69.
- [31] Chen S, Peng X, Bao N. A comprehensive analysis and optimization process for an integrated liquid cooling plate for a prismatic lithium-ion battery module. *Appl Therm Eng* 2019; 156:324–39.
- [32] Panchal S, Dincer I, Agelinchaab M. Thermal modeling and validation of temperature distributions in a prismatic lithium-ion battery at different discharge rates and varying boundary conditions. *Appl Therm Eng* 2016; 96:190–9.
- [33] Zhang T, Gao Q, Wang G. Investigation on the promotion of temperature uniformity for the designed battery pack with liquid flow in cooling process. *Appl Therm Eng* 2017; 116:655–62.
- [34] Tong S, Lacap JH, Park JW. Battery state of charge estimation using a load-classifying neural network. *J Energy Storage* 2016; 7:236–43.
- [35] Kalogirou SA. Artificial neural networks in renewable energy systems applications: a review. *Renew Sustain Energy Rev* 2001; 5(4): 373–401.
- [36] Shen WX, Chan CC, Lo EWC, Chau KT. A new battery available capacity indicator for electric vehicles using neural network. *Energy Convers Manage* 2002; 43(6):817–26.
- [37] Cheng B, Bai Z, Cao B. State of charge estimation based on evolutionary neural network. *Energy Convers Manage* 2008; 49(10):2788–94.