

硕士学位论文

(专业学位论文)

基于深度学习的车用锂电池状态估计研究

**STATE ESTIMATION OF VEHICLE LITHIUM
BATTERIES BASED ON DEEP LEARNING**

杨永松

哈尔滨工业大学

2023年5月

国内图书分类号：U469.72

国际图书分类号：629

学校代码：10213

密级：公开

硕士学位论文

基于深度学习的车用锂电池状态估计研究

硕士研究生：杨永松

导师：赵立军 副教授

申请学位：硕士专业学位

学科：机械

所在单位：汽车工程学院

答辩日期：2023年5月

授予学位单位：哈尔滨工业大学

Classified Index: U469.72

U.D.C: 629

Dissertation for the Master's Degree

**STATE ESTIMATION OF VEHICLE LITHIUM-
ION BATTERIES BASED ON DEEP LEARNING**

Candidate :	Yang Yongsong
Supervisor :	Associate Prof. Zhao Lijun
Academic Degree Applied for :	Professional Degrees
Speciality :	Mechanics
Affiliation :	School of Automotive Engineering
Date of Defence :	May, 2023
Degree-Conferring-Institution :	Harbin Institute of Technology

摘要

能源危机和环境恶化两大问题推动电动汽车快速发展。对动力电池精确的状态估计可以方便电车驾驶员准确了解电池状态信息并及时调整驾驶策略，同时保证电池在安全范围内使用以延长其寿命。然而传统电池状态估计方法存在着建模复杂、无法满足全生命周期动态工况下精度要求以及受数据缺失影响的问题。针对上述问题，本文主要做了如下工作：

首先，以深度学习迁移学习模型为基础，本文提出带反馈与卡尔曼滤波器的自适应卷积门控循环单元模型（adaptive convolutional neural network-gated recurrent unit with Kalman filter and feedback mechanism, Fb-Ada-CNN-GRU-KF），用于单一老化点动态工况下的电池荷电状态（State of Charge, SOC）估计。经公开数据集验证，深度迁移学习可以从不同分布的原始数据中挖掘更多信息，误差反馈模块能修正模型系统性误差，卡尔曼滤波器可保证模型的稳定输出。为降低全生命周期 SOC 估计任务中模型的训练量，使用简化掉误差反馈模块的 Ada-CNN-GRU-KF 模型估计全生命周期内电池的 SOC。经动态老化数据集验证，模型能够在多个老化点对动态工况下的 SOC 实现准确估计。

其次，本文通过训练不同输入特征的 CNN-GRU 模型，证明了 SOC 和累计放电容量（Accumulated Discharge Capacity, ADC）作为新特征输入对电池健康状态（State of Health, SOH）估计的积极意义。相对于 SOC 而言，SOH 变化缓慢，本文提出了以双时间尺度特征为输入，以预测平均值（Average, Ave）为输出的 Ada-CNN-GRU-Ave 模型，用于估算动力锂电池 SOH。经动态老化数据集验证，模型可以在动态工况下达到较高的 SOH 估计精度。基于所提出的 SOC 估计模型和 SOH 估计模型，建立联合估计模型。通过在每个老化点设置初始 SOH 误差，开展了模拟极限误差累积情况下的 SOC 与 SOH 联合估计实验，实验结果验证了联合估计模型的精度和有效性。

最后，为解决云端平台稀疏数据信息缺失的问题，本文建立 ExtraMAE 模型用于稀疏数据还原。在松下电池数据还原实验中，本文以较高精度将 0.2Hz 和 0.1Hz 稀疏特征数据还原到 1Hz 稠密数据，且对还原数据起到数据增强效果，最终实现高精度的 SOC 估计，稀疏数据还原模型的有效性及其在云端平台应用的潜力得到证明。

关键词:动力锂电池；深度学习；状态估计；稀疏数据还原

Abstract

Energy crisis and environmental degradation are promoting the rapid development of electric vehicles. And accurate estimation of lithium-ion power batteries state can enable electric vehicle users to obtain accurate battery status information, adjust their driving strategies in a timely manner, and ensure that the battery is used within a safe range and extend its lifespan. Traditional battery state estimation methods are either complex in modeling or unable to meet the accuracy requirements under dynamic conditions throughout the entire lifecycle, or are influenced by data missing. To address these issues, this paper has done the following work:

Firstly, based on deep transfer learning models, this paper proposes an adaptive convolutional neural network-gated recurrent unit model with Kalman filter and feedback mechanism (Fb-Ada-CNN-GRU-KF) for estimating state of charge (SOC) in a single aging point under dynamic driving conditions, and the validation results show that deep transfer learning can extract more information with different distributions from raw data, the error feedback module can correct systematic errors in the model, and the Kalman filter can ensure stable outputs. To reduce the amount of training parameters required for the battery's entire lifecycle state estimation task, an Ada-CNN-GRU-KF model without the error feedback module is established, and experimental results show that this model can accurately estimate the SOC under various aging points and dynamic conditions.

Secondly, by training the CNN-GRU model with different input characteristics, this paper proves the positive significance of SOC and accumulated discharge capacity (ADC) as new feature inputs to state of health (SOH) estimation. As SOH changes slowly compared with SOC, in this paper, an Ada-CNN-GRU-Ave model with dual time-scale characteristics as input and average (Ave) predicted SOH as output is proposed to estimate the SOH of lithium-ion power batteries. Experimental results show that the model can achieve high SOH estimation accuracy under dynamic conditions, and the effectiveness of the SOH estimation model is thus verified. Based on the proposed SOC estimation model and SOH estimation model, a joint estimation model is established. By

setting an initial SOH error at each aging point to simulate the case of severe error accumulation in joint estimation, a simulation experiment is conducted and the results verify the accuracy and effectiveness of the joint estimation model.

Finally, to address the problem of information missing of sparse data on cloud platforms, this paper establishes an ExtraMAE model for sparse data reconstruction. In the data reconstruction experiment based on Panasonic battery, the model is able to reconstruct 0.2Hz and 0.1Hz sparse feature data to 1Hz dense data with high accuracy and has a data augmentation effect on the reconstructed data, ultimately achieving high-precision SOC estimation. The effectiveness of the sparse data reconstruction model and its potential for application in cloud platforms are thus proved.

Keywords: lithium-ion power battery, deep learning, state estimation, sparse data reconstruction

目 录

摘 要	I
ABSTRACT	II
第 1 章 绪 论	1
1.1 研究背景及意义	1
1.2 国内外研究现状	2
1.2.1 电池荷电状态估计研究现状	2
1.2.2 电池健康状态估计研究现状	5
1.2.3 车云协同状态估计研究现状	6
1.2.4 研究现状小结	8
1.3 研究内容和技术路线	9
第 2 章 锂电池测试及数据集	11
2.1 锂电池工作原理及特性	11
2.2 电池实验平台建立	13
2.3 实验方案设计	14
2.3.1 容量测试	15
2.3.2 动态工况测试	16
2.3.3 电池加速老化实验	17
2.4 松下公开数据集	18
2.5 本章小结	20
第 3 章 基于深度迁移学习的 SOC 估计研究	21
3.1 理论基础	21
3.1.1 卷积神经网络	21
3.1.2 门控循环单元	22
3.1.3 自适应循环神经网络	23
3.1.4 卡尔曼滤波算法	25
3.2 FB-Ada-CNN-GRU-KF 模型	26
3.3 多温度下 SOC 估计验证	29
3.4 多老化点下 SOC 估计验证	35
3.5 本章小结	42
第 4 章 SOC 和 SOH 的联合估计研究	43
4.1 SOH 估计模型与验证	43

4.1.1 Ada-CNN-GRU-Ave 模型	43
4.1.2 SOH 估计效果验证与讨论	45
4.2 SOC 与 SOH 的联合估计	51
4.3 联合估计效果验证与讨论	51
4.4 本章小结.....	58
第 5 章 车云协同状态估计研究	59
5.1 理论基础.....	59
5.2 基于 ExtraMAE 的电池稀疏数据还原	60
5.3 还原数据的状态估计有效性验证	63
5.4 本章小结.....	72
结 论	73
参考文献	75
攻读硕士学位期间取得创新性成果	80
哈尔滨工业大学学位论文原创性声明和使用权限	81
致 谢	82

第 1 章 绪 论

1.1 研究背景及意义

本课题来自国家自然科学基金面上项目“锂离子电池系统故障多维演化机理和诊断方法研究”（52177210）、国家电网重庆营销服务中心委托项目“基于车桩运行大数据的充电安全预警服务”（B6QM-300009297-00010）和威海市科研创新基金“车载锂离子动力电池组自适应建模和高精度状态估计方法研究”。

随着全球科技和经济的发展，汽车越来越成为人们生活中不可或缺的一部分，而燃油车对化石燃料的不断消耗，使能源危机和环境污染两大问题日益凸显，为此人们将解决问题的目光投向了车辆动力电气化。

动力电池作为电动汽车的核心部件，还存在着单次充电行程短、安全性差、成本高等问题，制约了电动汽车发展。锂离子电池^[1]因为能量密度高、能量转换率高、自放电率小、安全性能好，成为动力电池的首选。但是其寿命易受滥用影响，过度充放电和高倍率充放电均可能导致电池损害，甚至引发安全问题。电池管理系统^[2]（Battery Management System, BMS）主要功能如图 1-1 所示，通过准确的状态估计，BMS 可以防止过充、过放、过压及过流等异常情况的发生，保证离电池的高效、安全地工作。

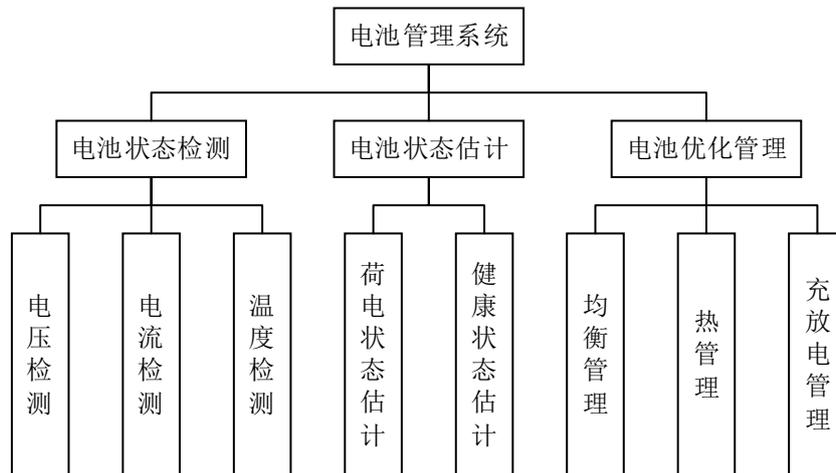


图1-1 电池管理系统主要功能

荷电状态（State of Charge, SOC）是用来衡量电池剩余电量的指标。可靠的 SOC 值有利于操作人员合理安排出行，有利于整车能量的合理分配，有利于减少过充放以延长循环寿命。由于 SOC 反映的是电化学过程的综合变化，因此只能通过基于电池特征参数（例如电压、电流和温度等）的间接估算来得

到。然而，电池本身具有强非线性特征，动力电池的使用工况亦是复杂多变，这使得精准的 SOC 估计仍面临显著挑战。

健康状态 (State of Health, SOH) 是电池寿命的衡量指标，随着动力电池不断充放电，电池的 SOH 逐渐下降，电池的性能发生劣化和衰退。当电池性能下降到一定程度时，电池泄漏、绝缘损坏、局部短路等问题发生概率增大，安全事故风险上升^[3]。而准确预测电池 SOH 值可以为 BMS 提供电池极限容量信息，提高电池 SOC 等其他状态的估计算法精度，使电池工作在安全范围内并得到有效利用，并提高电动汽车的安全性和可靠性。SOH 同样是反映电化学过程的综合变量，无法直接测量，而锂离子电池内部电化学机理十分复杂，基于电化学过程建立电池健康衰退模型难度大，亟需研发出新的精确、可靠的 SOH 估计方法。

另外，BMS 在计算能力和数据存储方面受到限制^[4]，算法被固定地编写到硬件中也导致 BMS 在实际应用中缺乏灵活性，不能及时更新换代。基于云边协同的 BMS 将能够解决当前 BMS 的计算能力、数据存储问和灵活性等问题。然而，车辆和电池都是动态系统^[5]，在实际驾驶过程中将会产生大量方差较大的稠密数据，云端和车辆之间数据传输过程中不可避免的延迟和数据缺失给电池状态的云边协同估计带来巨大挑战。

在现有传感器精度与数据传输水平下，充分挖掘电池特征数据和动态工况的规律，并借助新理论、新方法设计出高精度、快响应和适用广泛的 SOC 和 SOH 估计算法，是摆在 BMS 研发者面前的急切问题，且具有显著应用价值。

1.2 国内外研究现状

针对上述 BMS 中现存的问题，世界各地研发人员提出了多种解决方案并进行了验证，形成了专业且详尽的理论，对 BMS 的发展极具价值。接下来本节将分别针对电池荷电状态估计、健康状态估计与车云协同任务中的稀疏数据还原三个研究方向的现状做归纳总结。

1.2.1 电池荷电状态估计研究现状

SOC 估计现阶段应用较多的方法主要有安时积分法、开路电压法、卡尔曼滤波法以及人工智能法等，以下将对其进行简要介绍。

(1) 安时积分法

安时积分法实现简单且使用方便^[6]，如式(1-1)所示，将充放电时间内电流的积分值除以电池的额定容量，即可得到电池的 SOC 值。在充电过程中，电

流为负值，而在放电过程中，电流为正值。

$$SOC(t_{n+1}) = SOC(t_n) - \int_{t_n}^{t_{n+1}} \eta idt / Q_N \quad (1-1)$$

式中 $SOC(t_{n+1})$ ——电池在 t_{n+1} 时刻的 SOC；

η ——库伦效率又称为充放电效率；

i ——电流值的大小，充电时电流为负，放电时为正；

Q_N ——电池的额定容量。

然而，安时积分法对电流传感器精度要求高，实际使用中电流测量精度极易受温度和实际工况影响，不准确的电流测量值将导致安时积分法产生较大的累积误差。

(2) 开路电压法

开路电压法是根据开路电压 (Open Circuit Voltage, OCV) 和 SOC 之间的关系来估计 SOC，又被称作查表法^[7]，该方法通过在实验室中进行密集的实验来描述电池的行为，并将这种关系制成表格^[8]。由于 SOC 与 OCV 之间呈单调关系，所以可以根据可直接测得的 OCV 的值来估算 SOC。

首先，LIB 在固定的时间间隔内完全静置，以达到退极化相位。之后，利用电流脉冲将锂离子电池组完全放电。然后，在固定的时间内保持电池静置，测量 LIB 对应的 OCV。最后，映射出 OCV 与 SOC 之间的关系^[9]。在充电阶段，采用类似的过程来监测 OCV。一旦建立了查表，测量 LIB 的瞬时 OCV 就可以得到 SOC 的水平。

该方法过程简单，特定工况下精度较高。然而，LIB 在充电时的电压值要高于放电时的电压值，其结果是由欧姆电阻、极化电阻、电化学极化和浓度极化产生的迟滞^[10]带来了 OCV-SOC 曲线的不一致；为了准确地测量锂电池的 OCV，必须给锂电池足够的休息时间，使其达到平衡条件，在电池运行时测量 OCV 会导致精度差^[11]；而且 OCV 的测量还受到环境温度、电池老化^[12]等其他因素的影响。另外，OCV-SOC 曲线随电池放电过程整体呈现出两边陡，中间缓的趋势。在 SOC 大于 10% 小于 90% 时，OCV 处于平台区^[13]随 SOC 变化缓慢，较小的 OCV 变化对应很大的 SOC 区间，此时开路电压法的精确度差。

(3) 卡尔曼滤波法

卡尔曼滤波算法是一种用于估计动态系统状态的算法，具有较强的非线性适应能力。因为电池系统是一个高度非线性的复杂动态系统，近年来 KF 被广泛应用于电池系统 SOC 估计^[14]。该算法包含一组时间更新方程和一组状态更新方程，使用上一时刻的估算值和当前时刻的观测值来更新状态变量。在 SOC

估计任务中，KF 根据等效电路模型（Equivalent Circuit Model, ECM）和输入特征（电流、电压、温度等）进行递推运算，得出 SOC 的估计值^[15]，再由卡尔曼增益来修正估计值，从而实现较为准确的 SOC 估计。

然而 KF 法也有着比较明显的劣势。由于涉及到太多递推计算，它对电池 ECM 的精度要求较高^[16]。另外，一般在应用 KF 法估计 SOC 时，会假定系统噪声为高斯噪声，但是真实的系统噪声是未知的，故该假设引入一定误差。

（4）人工智能法

随着计算能力的提高，人工智能算法再次焕发生机获得较大发展。通过学习已知输入输出数据间的映射关系，人工智能算法可以实现从未知非线性输入到输出的映射^[17]。SOC 估计领域应用较多的有机器学习和深度学习等。

支持向量机（Support Vector Machine, SVM）属于机器学习算法中应用较为广泛的方法^[6]，其本质是一种分类算法，用于解决模式识别问题。后又被改进推广到函数拟合领域^[18]，称为支持向量回归（Support Vector Regression, SVR），使用核函数将非线性回归问题转化为高维度中的线性问题。李智鹏^[19]根据锂离子电池特性，将改进的遗传算法与最小二乘支持向回归结合，获得了比标准最小二乘支持向量机模型更快的收敛速度和更高的估算精度。但是该模型对实际放电工况的模拟比较简单，不能预测复杂工况下的电池荷电状态。

反向传播神经网络（Back Propagation Neural Network, BPNN）属于深度学习发展早期的产物。以图 1-2 所示的 BP 神经网络为例，模型以电池外特征参数电流（I）、电压（U）和温度（T）作为神经网络的输入，以参考 SOC 值作为输出进行训练，训练好的模型即可用于 SOC 的实时估计^[20]。He W 等人^[21]使用前馈神经网络根据 U、I、T 估算电池 SOC，但受 BP 模型本身结构影响，训练出的模型不能较好适应非线性任务，得到的 SOC 值波动较大。

相比于 BP 神经网络，循环神经网络（Recurrent Neural Network, RNN）隐藏层的输入由该时刻的输入数据和前一个时刻隐藏层的数据信息组成，RNN 还具备记忆能力，能够使用有限长度的参数来处理任意长度的时间序列^[22]，更适用于时间序列的估计和预测任务。LSTM 是 RNN 的改进形式，2018 年 Ephrem Chemali^[23]等人利用 LSTM 进行 SOC 估计，虽然全生命周期内的 SOC 估计精度没有验证，但在不同温度、不同工况时，SOC 估计结果的平均绝对误差为 1.19%，展示出深度学习类算法的优越性。2019 年 Xiangbao Song 等人^[24]利用 CNN-LSTM 估计 SOC，其平均绝对误差低于 1%，相比于 LSTM 模型和 CNN 模型，CNN-LSTM 的优越性也在实验中得到验证。

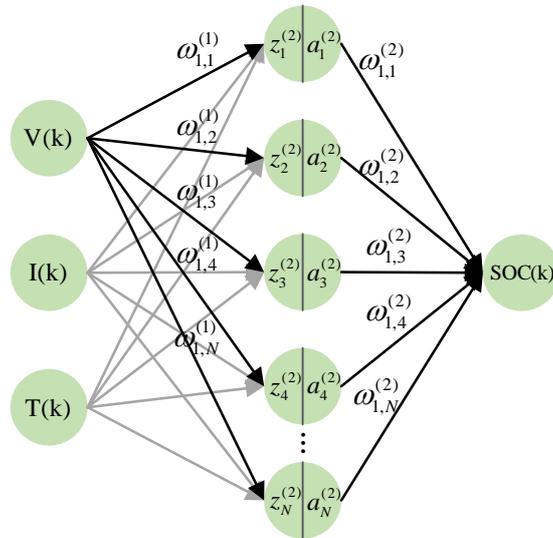


图1-2 BP 神经网络

1.2.2 电池健康状态估计研究现状

SOH 同样是电池的重要指标之一，对 SOH 的准确估计有利于驾驶员掌握电池容量信息，保障北汽的使用安全。目前常见的 SOH 估计算法有如下 4 种：

(1) 直接测量法

直接测量法是公认的 SOH 评定方法，最能真实反应电池的健康状态。该方法就是在标准工况下，对电池进行一次完全的充放电循环，得到电池的实际放电容量^[25]。如式(1-2)所示，实际容量与新电池的额定容量的比值就是当前状态下的 SOH。

$$SOH = (C_{current} / C_{initial}) \times 100\% \quad (1-2)$$

式中 $C_{current}$ —— 电池当前可用最大容量；

$C_{initial}$ —— 电池初始容量。

但是因为此方法需要对电池以一定的倍率进行离线放电，消耗时间长，需专用设备，不适用于在电动汽车上应用，因此不具实用性。

(2) 电化学阻抗法

电化学阻抗法是一种对系统施加小幅值的正弦波（电压或者电流信号）作为干扰信号的电化学测量方法^[26]。该方法将多个不同频率、不同幅值的正弦信号施加于锂离子电池系统，测量采集系统的输出，并对相关的数据进行分析，最后估算电池 SOH^[27]。该方法需要对同类电池进行大量的数据采集、分析、处理，从而获得此类电池的相应特性。这种方法内容繁琐，工作量大，且设备比较昂贵，只适用于实验室研究，不适用于嵌入汽车系统，因此实用性也不强。

（3）卡尔曼滤波法

KF 算法在 SOH 估计中与 SOC 估计任务中应用方法相似，均基于 ECM 利用电池外特性实现电池的状态估计^[28]。然而，由于电池的温度、充放电倍率、SOC 等会影响电池内参数变化，依靠外特征实现 ECM 准确的参数辨识具有较大困难；另外，简单的 ECM 往往难以准确描述电池特性，复杂的 ECM 会不能保证实际应用时的计算速度。所以，基于 ECM 的 KF 方法存在较大的局限性。

（4）人工智能法

SVR 方法前一小节已有介绍，它是一种基于非线性映射的算法，并且适用于非线性系统。湖南大学的刘栋^[29]根据电池充放电循环中的电流、电压曲线，提取出 3 个健康因子，采用支持向量回归建立了提取的健康因子与 SOH 的关系，对电池健康状态进行估算。

神经网络法由于不需要明确电池内部机理，且具有较强的非线性拟合能力，同样成为了 SOH 研究领域的热点方法^[30]。由于电池老化是一个长时间尺度的过程，利用 BMS 采集到的稠密特征数据直接将神经网络应用于 SOH 估计会造成很大的计算力消耗，所以目前应用神经网络估计 SOH 前多进行特征提取。Eddahech^[31]等人直接从充电的恒流或恒压曲线中提取特征，使用机器学习算法对电池 SOH 进行估计，这属于直接提取特征的方法。由于不同循环下充电曲线形状上差异不显著，因此 SOH 估计精度不高。

在间接提取特征的方法中，电量增量分析法（Incremental Capacity Analysis, ICA）和差分电压分析法（Differential Voltage Analysis, DVA）获得较大关注，它们从电池恒流充电过程中的电压、电流、时间数据中分别提取出 IC 曲线和 DV 曲线，其中 IC 曲线和 DV 曲线的变化特征反映了电池的衰退程度^[32]。另外，基于 ICA 和 DVA 的方法以端电压为标尺，实际应用时无需完整充电过程，在电流一致的情况下提取的健康特征便较为稳定^[33]，然而该方法不能应用于动态放电过程。2020 年山东大学的 Qiang Liu^[34]等人利用 IC 曲线和 LSTM 网络实现了横流恒压充电条件下的 SOH 估计，虽其最大估计误差不超过 4%，但同样不能应用于动态放电过程。如何在动态放电过程中实现较小算力消耗的 SOH 估计成为摆在 BMS 研发人员面前的难题。

1.2.3 车云协同状态估计研究现状

对于 BMS 有限的内存空间，降低记录频率会明显增加总记录时间^[28]。因此，汽车企业通常会将电动汽车的行驶数据保存在云端进行监控和管理。云数据的质量通常难以保证，这对基于模型的状态估计方法提出了巨大的挑战。虽

然电动汽车的数据采样频率很高，但由于网络带宽和数据存储容量的原因，目前云数据的记录周期可能长达 10-30 秒。因此，利用云数据很难揭示电动汽车的动态驾驶状况。^[35]

Chaojie Xu^[36]对不同类型的电池模组故障进行了实验，建立了电池系统仿真模型。模拟正常和故障电池模块的充放电情况，获得海量循环数据，用于云端算法训练。但是因为传输数据量庞大，带宽不能满足要求，该方法没有办法实现云端和边端的实时协同工作，云端计算只能离线进行。

Yong Zhou^[37]首先提出了 BMS 与云相结合的边缘云协同计算架构，有效利用 BMS 数据质量和云计算能力的优势。其次，通过相关向量机与粒子群优化和水平参数传递的结合，模型学习所需的样本数量减少到 30%。该方法通过特征提取的方式，降低了数据传输量。

目前云端数据的记录周期一般长达 10-30 秒，因此很难通过云端数据来揭示电动汽车的动态驾驶状况。^[35]但充电数据是稳定的，避免了稀疏的动态放电工况数据的使用，使得根据充电云端数据估计电池寿命成为可能。面对电池老化过程中电池单体间的变异问题，Yifan Lu^[38]提出一种基于充电云数据的锂离子电池电池间差异评估方法，利用原始信号对电压、温度、内阻、容量、电量等 5 个指标的变化情况进行了分析和评估，并通过充电电压曲线估计电池容量和电量，但是 SOC 的估计不能通过充电过程获得。

在对边端数据进行采集时，由于 BMS 的数据保存能力不足及传感器故障等原因，数据缺失的情况大量存在于数据采集、存储及应用环节^[39]。根据数据缺失机制的不同，数据缺失可分为完全随机缺失，随机缺失和非随机缺失^[40]。完全随机缺失是指造成数据缺失的原因与已经记录到的数据无关，只与随机过程有关。由于传感器故障造成的数据缺失即属于完全随机缺失。随机缺失是指数据缺失与已记录变量相关而与缺失数据本身不相关。非随机缺失是指数据缺失的原因和缺失值自身相关。受限于 BMS 存储能力而降低采样频率导致的数据缺失（稀疏数据），即为非随机缺失。

对于缺失数据，直接删除或忽略缺失值的方法容易造成：1) 可用数据量的大量减少^[41]；2) 数据集潜在特征的改变^[42]；3) 时间序列中缺失值前后时间关联被破坏^[43]。平均值插补方法将缺失数据两端的平均值作为缺失数据的代替，然而缺失项被均值替代后，样本整体方差降低，同质数据增多。回归插补利用已知观测样本点建立线性回归模型，进而对缺失样本点进行预测填补，但当缺失数据非线性相关较强时，模型容易产生有偏估计^[44]。常见的基于机器学习的缺失值插补算法，最邻近插补，通过数据项的相似度大小来估计缺失

值^[45]，在缺失比例不高时该方法有较高插补精度，但其在缺失比例较大时难以得到准确预测结果。

自编码（Auto Encoder, AE）模型及其衍生模型的发展，使得数据的压缩与重构还原成为可能，为电池领域云边协同技术的发展和进一步提高电池状态估计效果提供了新的思路。Liang Ma^[46]使用 AE 模型中的编码器学习无标签数据在掩藏层的输入表示，再根据编码器输出，使用解码器对输入数据的特征进行了重构，但是该模型无法对数据本身进行还原。Mingqiang Zhang^[47]受 AE 启发，提出了深度压缩感知网络，实现了数据的压缩和还原，但是对于本身即稀疏的数据，该网络无法实现对其稠密化。另外，上述 AE 类方法也无法实现对云边数据传输过程中随机缺失数据的补全。

1.2.4 研究现状小结

针对动力锂电池状态估计问题，已经涌现出多种解决方法，这些方法各有优缺点，对现存主流方法的优点和主要存在的问题总结如下：

当前动力锂电池的 SOC 估计方法都有着各自的优势和局限性，安时积分法精度高，但是容易受到硬件精度影响，经多次循环后易产生精度漂移；开路电压法简单、精度高，但容易受到老化和温度的影响；而卡尔曼滤波算法可以通过电池荷电状态的改变，从而对电池状态补偿来估算电池 SOC，但由于测量过程中存在噪声导致算法的精确度一直受到影响。并且，上述研究方法中，大部分算法对运行工况有一定要求，在室温下和平稳工况下的估算精度较高；而实际工作中的锂电池，受到不同的充放电电流等因素的影响，电池的状态量会发生较大变化，上述方法在实际动态工况下会存在较大 SOC 估计误差。

在分析了现有锂离子电池 SOC 估计的模型之后，确定电池 SOC 的估计模型需要向更高的精确性、更好的鲁棒性发展，而神经网络最大的优势就是通过输入和输出自动逼近且任意逼近一个非线性系统，十分适用于估计电池的 SOC，故本文将采用神经网络的方法进行 SOC 估计。在使用数据训练神经网络模型时，训练集内部的各数据区间往往分布存在差异，而已有的基于神经网络进行 SOC 估计的方法并没有有效地考虑训练集中各个工况之间的差异，将训练集中的数据不加区分地送入模型进行训练，导致训练出的模型泛化性能差，精度低；而且因为网络结构复杂、参数众多，预测结果往往会出现较大波动甚至是异常值，这些问题都亟需解决。

对于电池 SOH 估计，直接测量法虽然结果精准，但是因为需要特定工况完全放电，不适用实车应用；电化学阻抗法过程繁琐，同样只适用于实验室中

操作；卡尔曼滤波法需建立等效电路模型，而模型受温度、放电倍率等影响较大，需在模型复杂度与计算效率间做权衡；人工智能法，尤其是神经网络，具有较强非线性拟合能力，且不需对电池内部机理进行建模，随着计算能力的加强，正成为提高 SOH 估计精度的一个理想方案，本文将根据神经网络进行车用锂电池的 SOH 估计。

而电池 SOH 属于长时间尺度变量，直接将整个寿命周期内的电池充放电数据作为输入耗费计算量大且计算时间长。如何更加合理和高效地利用传感器搜集到的数据建立特征和 SOH 的映射关系，是该类方法的研究重点和难点。同时，在进行网络训练时，如何更好的考虑训练集中多工况之间的差异，提高模型泛化性，也是 SOH 估计时亟需解决的问题。

面对 BMS 有限的内存空间以及车云协同估计时的数据传输带宽限制问题，将车端的稀疏特征数据传输到云端是现阶段的解决办法之一，但是这将产生数据的失真，导致云端的状态估计模型训练困难。而使用简单的充电数据上传云端训练的方法，不能够在复杂放电工况下的 SOC 估计中得到应用，使用过于场景单一。

1.3 研究内容和技术路线

综合当下电池状态估计领域各种方法的优缺点，本课题将以深度迁移学习技术为主要方法，对车用锂离子动力电池的 SOC 和 SOH 进行高精度和高鲁棒性地在线估算，同时解决传感器采集过程中的数据缺失和稀疏问题。具体研究内容包括锂电池 SOC 估计研究、锂电池 SOH 估计研究、车云协同估计研究。

(1) 锂电池 SOC 估计研究

在具有迁移学习功能的 Ada-RNN 的基础上，提出 FB-Ada-CNN-GRU-KF 模型，并首次将其应用于锂电池 SOC 估计中。在松下锂离子电池不同温度下的动态行驶工况下，验证所提方法估算 SOC 的准确性和鲁棒性，并与其他现有方法进行比较；同时，验证所提模型中 CNN 层、误差反馈模块和 KF 算法对提高 SOC 估算性能的有效性。为实现全生命周期 SOC 估计，建立去除误差反馈模块的轻量化 Ada-CNN-GRU-KF 模型，为 SOC 与 SOH 的联合估计作铺垫，并验证该模型在全生命周期 SOC 估计任务中的有效性。

(2) SOC 和 SOH 的联合估计研究

建立双时间尺度的 Ada-CNN-GRU-Ave 模型用于锂电池 SOH 估计。使用动态工况数据代替恒流放电或充电数据进行训练和测试，利用 CNN-GRU 模型验证特征 SOC 和 ADC 对 SOH 估计任务的精度影响，随后对比验证 Ada-CNN-

GRU-Ave 模型相对于传统数据驱动方法的估计表现。基于 Ada-CNN-GRU-KF 模型和 Ada-CNN-GRU-Ave 模型，建立 SOC 和 SOH 的联合估计模型，实现更接近真实情况全生命周期的 SOC 和 SOH 联合估计。通过在每个老化点设置初始 SOH 误差，开展模拟极限误差累积情况下的 SOC 与 SOC 联合估计实验，验证联合估计模型的精度和鲁棒性。

(3) 车云协同状态估计研究

建立带外推器的掩码自编码模型 (Extrapolation Masked Autoencoders, ExtraMAE)。利用规则掩码的方式训练模型，用于电池稀疏特征数据的还原，以在云端平台得到保真度更高的数据，并通过松下电池公开数据集验证生成数据精度。进一步，通过与稀疏数据、稠密参考数据作对比，验证由 ExtraMAE 模型所生成的还原数据在电池 SOC 估计任务中的优越性，证明模型在云端平台应用的潜力。

论文总体技术路线如图 1-3 所示。

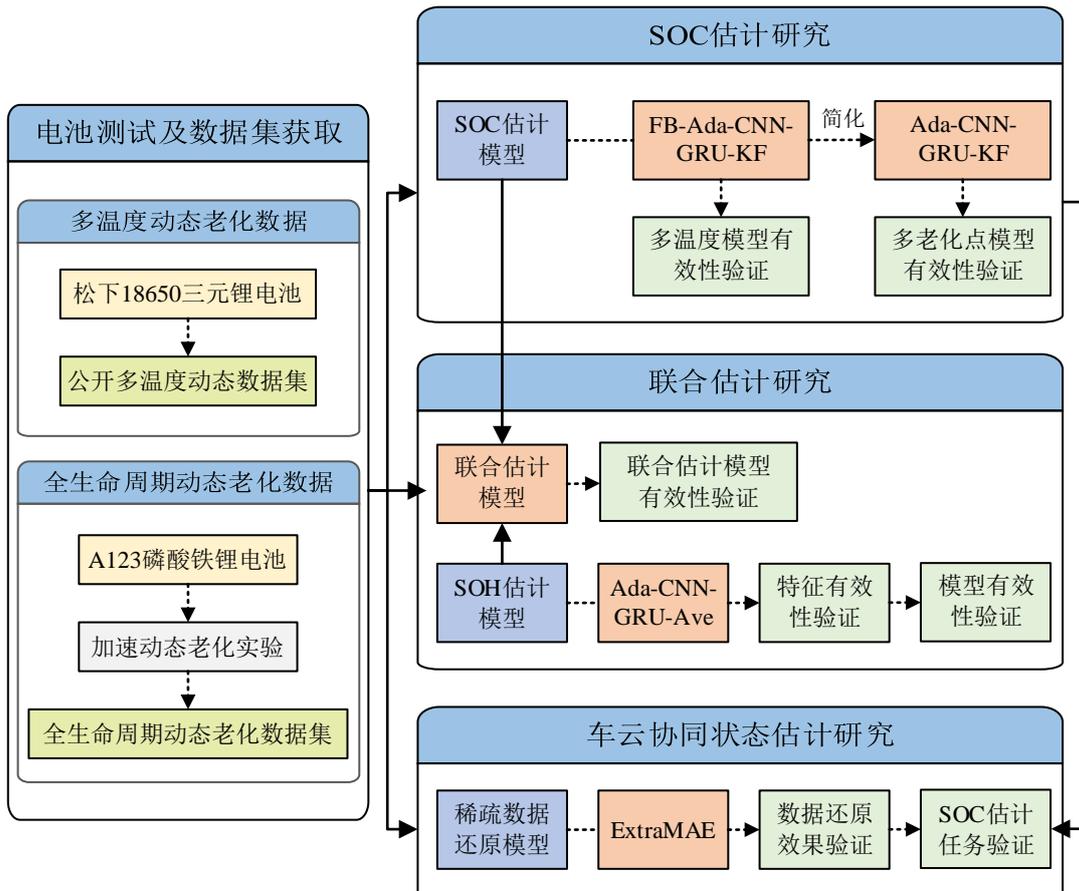


图1-3 技术路线

第 2 章 锂电池测试及数据集

目前，网上的公开的锂离子电池数据集往往存在记录数据不全面的问题。为满足全生命周期动态工况下 SOC 估计模型和 SOH 估计模型的验证，对锂电池展开独立的、完整的动态老化实验是有必要的。本章将首先介绍锂电池工作原理及特性，然后基于模型验证的需要搭建电池测试平台，并开展电池测试实验。最后，因多温度下 SOC 估计模型及稀疏数据还原模型的验证需要，从网上获取松下电池公开数据集并作简要介绍。

2.1 锂电池工作原理及特性

锂电池通常由正极、负极、电解质和隔膜组成。其中，正极材料是由锂金属氧化物或磷酸铁锂等化合物组成，而负极材料则通常采用石墨或碳材料。电解质则是一种导电液体或聚合物，可以促进锂离子在正极和负极之间移动。其结构如图 2-1 所示。

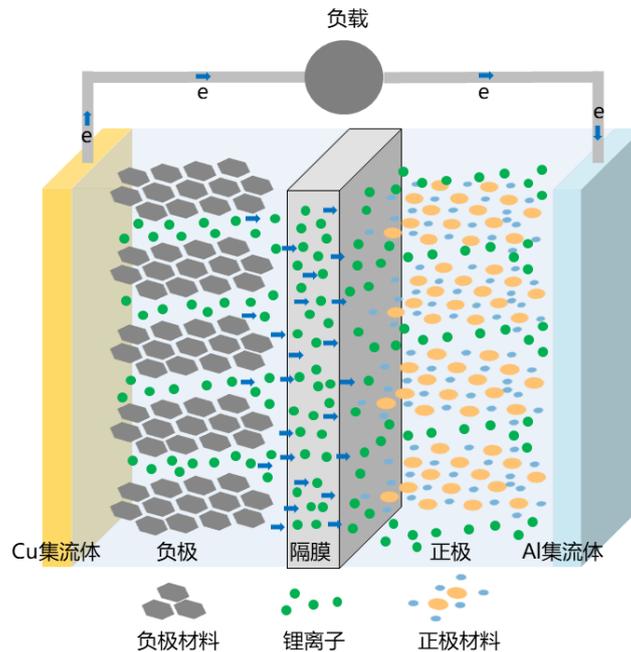


图2-1 锂离子电池结构

在锂离子电池充电过程中，外部电源会将电流传输到电池中，这会使得电池中的锂离子在正极处被氧化，并且在负极处被还原。这些离子会穿过电解质并在两个电极之间移动。同时，电子也通过电路从负极流向正极，完成了闭环电路。在放电过程中，这个过程反转，离子会回到负极，而电子则从

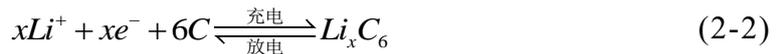
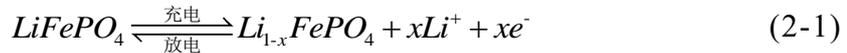
电路流回到负极。通过这种方式，锂离子电池能够将化学能转换为电能，并且可以反复充放电，实现长期使用。

根据动力电池正极材料的不同，可以将动力电池分为钴酸锂电池、锰酸锂电池、磷酸铁锂电池、三元锂电池等。每种电池的基本信息如表 2-1 所示。磷酸铁锂电池因为其安全性好、成本低、高效率输出、使用寿命长、过放电特性良好等优点而在近年得到广泛使用，本文将以磷酸铁锂电池为实验对象，开展电池动态工况老化实验，进行电池状态估计相关方法验证。

表2-1 不同材料体系锂离子动力电池基本情况表

名称	正极材料化学式	电池性能特点
钴酸锂电池	LiC_0 (LCO)	电压高，比能量高，起火隐患较大
锰酸锂电池	LiMn_2O_4 (LMP)	电压高，比能量高，容量衰退快，热稳定性差
三元锂电池	$\text{LiNi}_{1-x-y}\text{Co}_x\text{Mn}_y\text{O}_2$ (NCM)	电压略低于 LCO，安全性优于 LCO，寿命略短
磷酸铁锂电池	LiFePO_4 (LFP)	功率密度高，能量密度低，热稳定性好

磷酸铁锂电池的正极材料是磷酸铁锂 (LiFePO_4)，由铝箔与电池的负极连接。它是一种晶体结构稳定、化学惰性强的材料。在充电过程中，这种材料可以从无序状态转变为具有规则结构的晶体状态，而在放电过程中则反转，这使得磷酸铁锂电池能够实现高效率的储能；电池的负极材料主要是碳，由铜箔与电池负极连接，能够有效地嵌入/脱出锂离子，并且具有良好的导电性能；隔膜则用于分隔正负极，在电池内形成离子传输通道，同时防止电极之间的短路。充放电过程中磷酸铁锂电池内部正、负极所化学反应分别如式 (2-1)与式(2-2)所示：



通常情况下，磷酸铁锂电池的充电截止电压大约为 3.6V，放电截止电压则约为 2.0V。然而，由于不同生产厂家使用的正负极材料和电解质材料质量以及工艺的差异，电池的性能也会有所不同。本文选用 A123 生产的 18650 磷酸铁锂电池开展实验研究，其基本参数如表 2-2 所示。

表2-2 测试用 A123 产 18650 电池基本参数表

参数名称	参数值
标称电压 (V)	3.2
额定容量 (Ah)	1.1
上截止电压 (V)	3.65
下截止电压 (V)	2.0
最大持续放电电流 (C)	30
单体电池质量 (g)	(39.0±2.0)
外形尺寸 (mm)	$\varnothing = (18.0\pm 0.2)$; $H = (65\pm 0.2)$

充放电倍率、所处环境温度、循环次数等因素会影响电池状态^[48]，进而影响电池状态的估计精度：

1) 充放电倍率。较高的充放电倍率下，电池内部的化学反应速率加快，电荷/离子在电解质内的传输速率也会随之增加，这可能会导致部分电荷/离子无法完全转化为电能，从而降低电池的可用容量。过高的充放电倍率，还会对电池内部材料和结构造成损伤，从而降低电池的寿命。

2) 温度。温度升高会加快电池内部化学反应速率，从而提高电池的放电能力和充电效率；温度变化也会影响电池内部材料的性质和反应动力学，导致电池在不同温度下的实际容量产生差异。一般而言，温度越低，电池容量越小；温度越高，电池容量越大。温度对电池的寿命也有很大影响，过高或过低的温度都可能导致电池内部材料老化，降低电池寿命。

3) 循环次数。随着循环次数的增加，电池内部材料的老化和腐蚀等问题会导致电解质浓度和电荷传输速率下降，从而增加电池的内阻，影响其输出功率和充电效率。另外，电池内部活性物质的消耗和沉积等问题也会随着循环次数增加而逐渐加剧，从而降低电池的可用容量。

2.2 电池实验平台建立

为采集多工况、多老化点下的动力电池单体放电数据，本文采用如图 2-2 所示的电池单体测试平台开展电池实验。

其中，Digatron 充放电测试仪一共八个独立通道，每个通道的最大量程为 5V100A，可同时最多对 8 个电池进行不同倍率、不同方式的充放电工况模拟；主机用来建立电池与充放电测试仪之间的通讯，控制充放电测试仪对电池加载特定工况的激励，并记录与储存测试仪采集到的电池测试数据；贝尔温度箱用来控制动力电池的环境温度。各设备的主要技术参数分别如表 2-3 和表 2-4 所示。

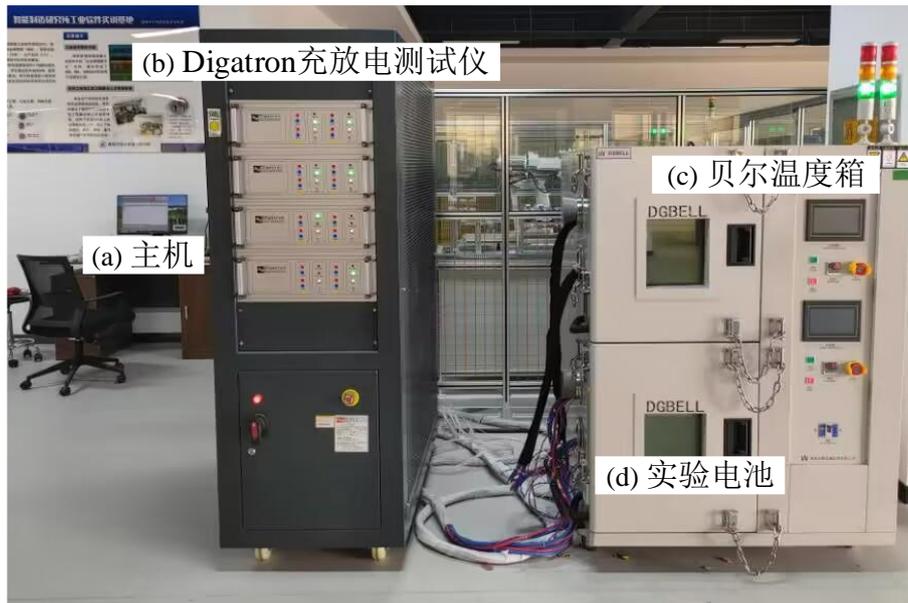


图2-2 充放电测试平台

表2-3 Digatron 充放电测试仪技术参数

通道数	最大充放电电流	电压范围	可选模式	响应速度	精度
8	100A	0-5V	恒流恒压充电 恒流充电 模拟工步等	100 毫秒	满量程±0.05%

表2-4 贝尔温度箱技术参数

独立温箱数	尺寸 (mm)	温度范围	速率	功能
2	内箱: 800×700×600mm 外箱: 1300×1950×1700mm	-40°C-150°C	升温速率: 1-3°C/min 降温速率: 1°C/min	高温试验、低温试验、自动防爆

2.3 实验方案设计

通过对电池的基本性能进行调研后，基于已有的电池测试平台，设计如图 2-3 所示的实验流程方案。具体来说，本文所采用的电池基本测试主要包括：容量测试，动态工况测试，电池加速老化循环等。其中，动态工况测试包括：动态压力测试（Dynamic Stress Test, DST）、联邦城市驾驶循环（The Federal Urban Driving Schedule, FUDS）、城市测功驾驶循环（Urban Dynamometer Driving Schedule, UDDS）、补充联邦测试规程（Supplemental Federal Test Procedure-US06, US06）和北京动态压力测试（Bei Jing Dynamic Stress Test, BJDST）。

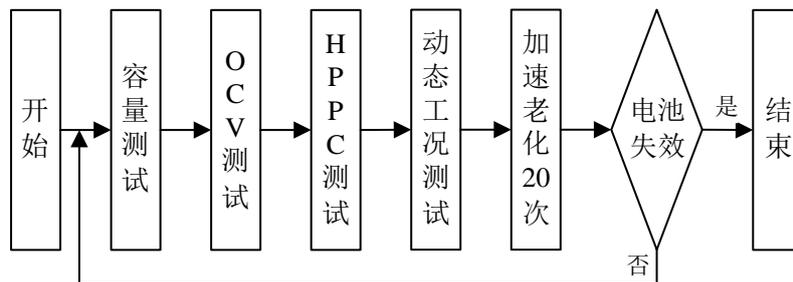


图2-3 电池测试实验流程

2.3.1 容量测试

锂离子电池容量分为理论容量、额定容量和实际容量^[48]。理论容量是电池厂商规定的最大容量，表示在最理想情况下电池能够放出的最大电量。额定容量是在特定放电环境下电池能够放出的最大电量，通常用来衡量电池的大小。实际容量是电池在实际工作中能够放出的最大电量，受到工作条件和环境等多种因素的影响。

容量测试是为了得到锂离子电池在当前条件下的额定容量，用于标定当前的健康状态 (State of health, SOH)。其实验流程为：1) 根据电池规格书要求的倍率 (本文采用 0.5C)，以恒流恒压充电的方式将电池充满；2) 充满电的电池，进行充分长时间的静置；3) 再以 0.5C 的电流恒流放电至下截止电压。该实验步骤连续重复三次，三次测试的恒流放电容量误差在规定的范围内 (取 2%) 认为测试结果准确有效，并取三次测试放电容量的平均值作为该电池在该时刻该条件下的最大可用容量。容量测试工况下电压电流随时间变化关系如图所示。

为确保测试结果的准确性和有效性，该实验步骤需要进行三次连续重复测试，额定容量取三次测试放电容量的平均值。在容量测试放电工况下，电压和电流随时间变化的关系如图 2-4 所示：

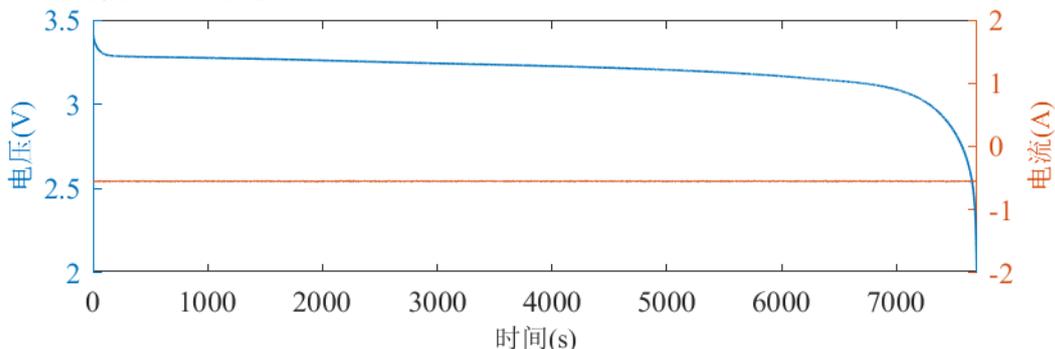


图2-4 容量测试工况下电压电流曲线

2.3.2 动态工况测试

动态工况测试是指通过模拟动力电池在电动汽车行驶工况中的电流激励而开展的特殊测试。本文选用了 DST、UDDS、FUDS、US06 和 BJDST 五种较能反应真实环境中驾驶时电池变化的动态工况，通过加载特定的充放电电流以获取电池全寿命周期内动态工况下的电压、电流、温度等数据，为数据驱动的电池状态估计模型的训练和测试提供支持。随着电流加载，以初始老化点为例，五种动态工况的电压变化如图 2-5 所示。另外，老化点表示电池老化过程中的特定时间点，未老化电池的初始老化点设置为 1，每经历 20 次加速老化实验后老化点数值加 1。

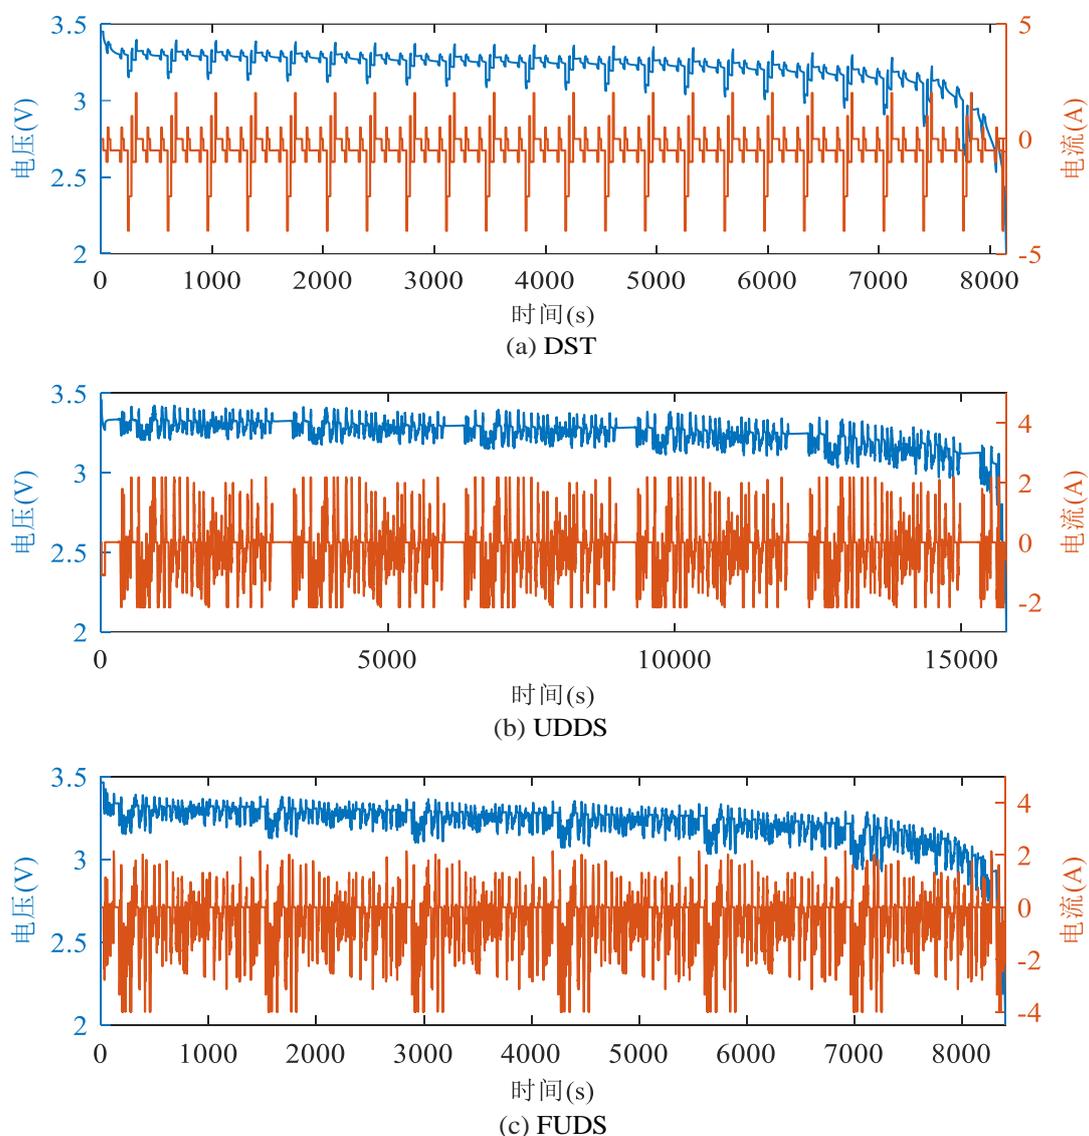


图 2-5 实验室动态工况下电压电流曲线

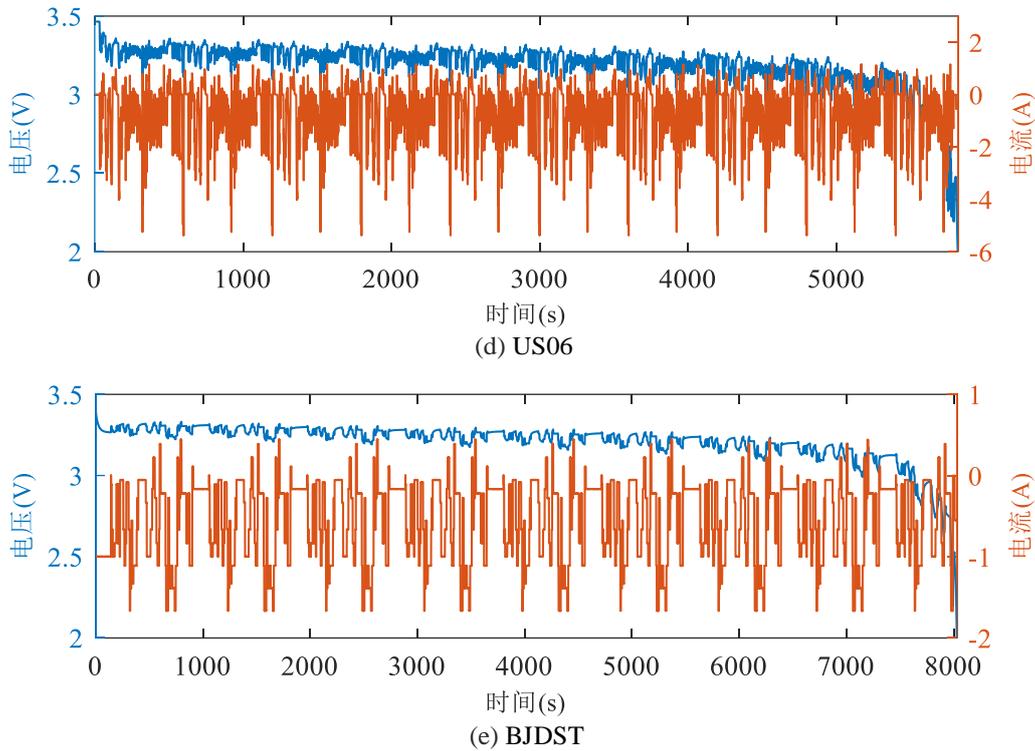


图2-5 实验室动态工况下电压电流曲线（续）

2.3.3 电池加速老化实验

由于实际自然充放电老化所需周期长，本文设计加速老化试验，通过在低温条件下对电池大倍率充放电引起其快速老化，以在较短时间获得电池全生命周期老化数据，具体的实验流程为：1) 以 2C 的恒流电流将电池充电至上截止电压 3.65V，后静置 0.5 小时；2) 以 2C 的恒流电流将电池放电至下截止电压 2V，后静置 0.5 小时；3) 将上述步骤 1 和步骤 2 在 10°C 下以 20 次为一个老化点单位来循环执行，直到电池的 SOH 低于 70%。注意，容量测试、OCV 测试和动态工况测试等在每个加速老化循环前均会进行一次。

以 DST 工况为例，电压随老化的变化轨迹如图 2-6 所示：

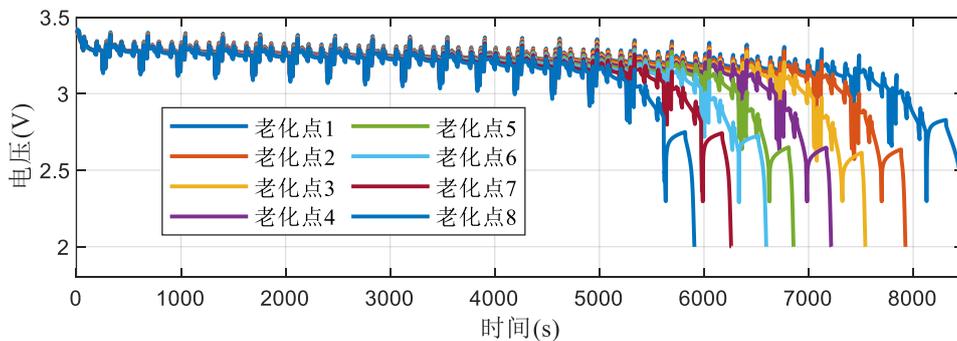


图2-6 电压随老化变化轨迹（以 DST 工况为例）

根据容量测试工况，得到电池老化趋势如图 2-7 所示：

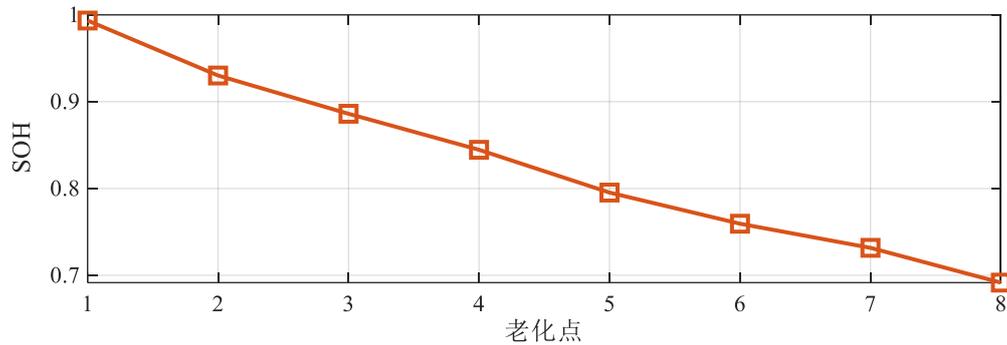


图2-7 全生命周期内 SOH 变化

2.4 松下公开数据集

松下电池公开数据由 Phillip^[49]从松下 NCR18650PF 锂离子电池记录，其标称容量为 2.32Ah。利用温度控制箱选定 25°C，10°C，0°C 三个不同环境温度下的动态驾驶工况对电池进行测试，其中用于测量电流和计算容量的电流传感器误差小于 25mA。实验过程中电池的电压、电流、电池内部温度、环境温度、时间戳等信息将被记录下来，并以 mat 文件的形式保存。

实验的流程如下：首先将温控箱设置为 25°C，然后静置 3 小时，保证电池内部温度为 25°C。然后用 1C 恒流和 4.2 V 恒压给电池充满电。当充电电流低于 50mA 时，这个充电过程终止。然后将温控箱设置为所需的温度，并等待另一个 3 小时，以使电池内部温度稳定。之后进行动态驾驶循环测试，包括 HWFET、HPPC、LA92、US06、UDDS 以及混合工况 Cycle4 和 NN，其电压电流曲线如图 2-8 所示。其中，NN 工况由 LA92 工况与 US06 工况的放电片段混合，专门设计用于模型验证；Cycle4 由 US06, HWFET, UDDS, LA92 的放电片段混合而成。这些动态工况测试为模型训练和验证提供广泛的现实驾驶条件。

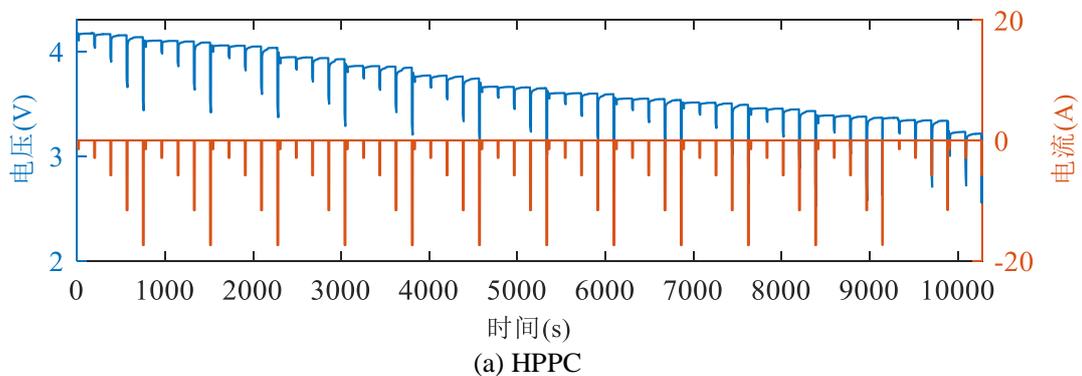


图 2-8 25°C 时松下电池多工况电压电流曲线

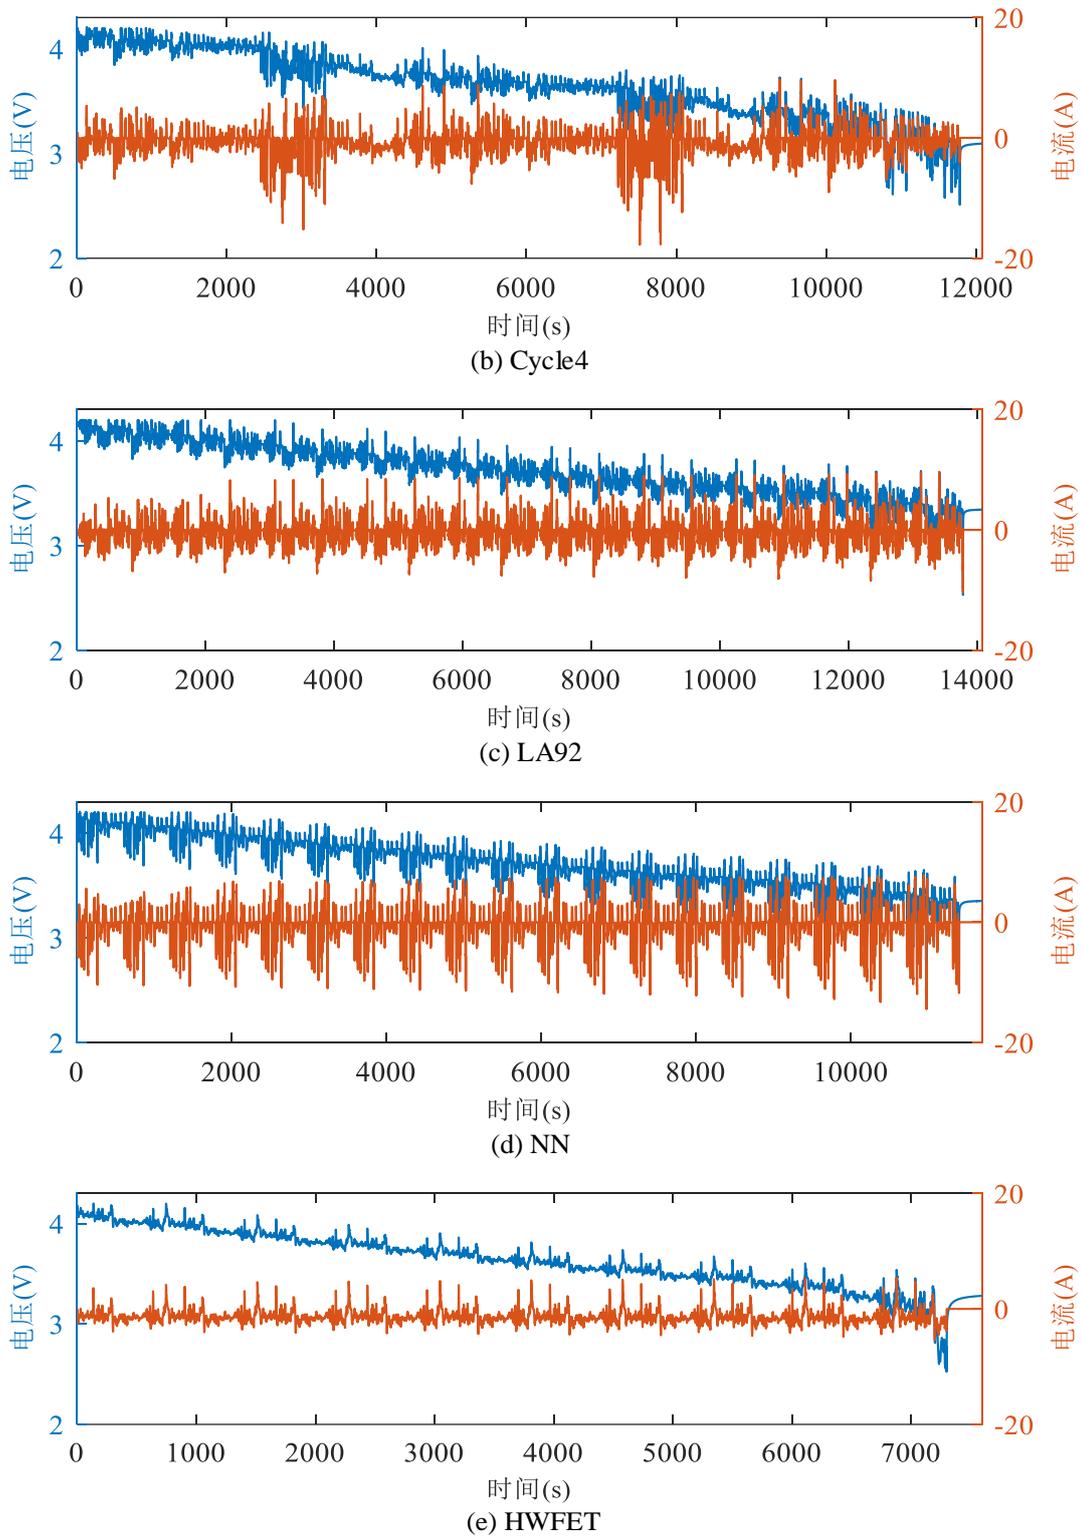


图 2-8 25°C时松下电池多工况电压电流曲线

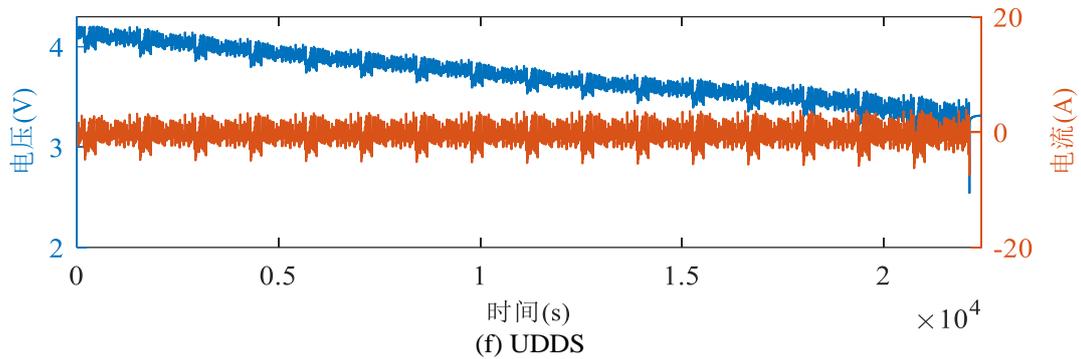


图2-8 25°C时松下电池多工况电压电流曲线（续）

以 HPPC 工况为例，电池在 0°C、10°C 和 25°C 环境温度下 SOC 变化如图 2-9 所示。温度会影响电池内部材料的性质和化学反应速率，进而影响电池的放电效率，导致电池在不同温度下 SOC 变化过程的差异。因此温度一般同样作为 SOC 估计过程中不可或缺的特征变量。

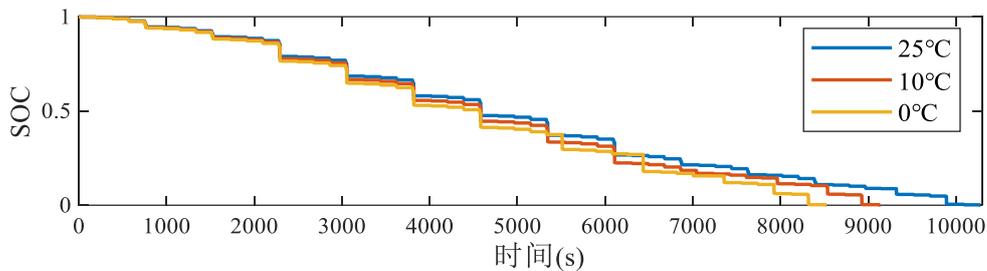


图2-9 不同温度下松下电池 SOC 变化曲线（HPPC 工况）

2.5 本章小结

本章首先阐释了锂离子电池的充放电原理，并对影响电池状态的因素作了更详细的分析；其次，对所使用的电池充放电测试平台进行了详细的说明；接着，设计并开展了包含动态测试工况的电池加速老化实验，获得了全生命周期 SOC 和 SOH 估计模型验证所需的数据集；最后，获取了松下电池公开数据集，为多温度下 SOC 估计模型验证及稀疏数据还原研究提供数据支撑。

第 3 章 基于深度迁移学习的 SOC 估计研究

可靠的 SOC 估计结果有利于电车驾驶员合理安排出行路线，减少电池的过充放以延长循环寿命。首先，根据 CNN、CNN-GRU、Ada-RNN 等基础模型，本章提出带误差反馈调节机制的深度迁移学习模型 FB-Ada-CNN-GRU-KF 以实现 SOC 准确且平稳的估计；然后，对所提出的模型进行具体地搭建；接着，以松下电池公开数据集在多温度下对所提出模型的有效性进行验证；最后，将模型进行简化为 Ada-CNN-GRU-KF 模型以适应多老化点下的 SOC 估计，并使用动态工况老化数据对多老化点下模型的有效性进行验证。

3.1 理论基础

3.1.1 卷积神经网络

CNN 是深度学习神经网络的一种，凭借着局部连接、权值共享等优点以及下采样降维的功能^[50]，CNN 已成功应用于自然语言处理、时间序列预测等多个领域，可以自适应提取特征，减少计算负担。一个完整的 CNN 由输入层、卷积层和输出层等组成。如图 3-1 所示，卷积层使用特定的卷积核和前一层网络的输出执行逐元素点积，从而提取到数据的特征信息。

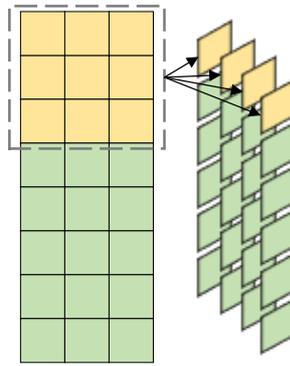


图3-1 CNN 卷积操作

假设卷积神经网络的输入和输出分别为 $x_{d,i+m,j+n}$ 和 $a_{i,j}$ ，则输入和输出之间的关系可以表示为式(3-1)：

$$a_{i,j} = f\left(\sum_{d=0}^{D-1} \sum_{w=0}^{W-1} \sum_{h=0}^{H-1} w_{d,w,h} x_{d,i+m,j+n} + b\right) \quad (3-1)$$

式中 D 、 W 、 H ——卷积核的输出深度、宽度和高度；
 $f()$ ——电池初始容量；

w 、 b ——卷积核中各神经元的权重和偏置，虽然对每个神经元而言都是唯一的，但在训练阶段会进行调整使其适用于给定问题。

卷积核大小会影响 CNN 的输出效果。通常小卷积核能够提取更多局部的特征信息；大卷积核关注数据的整体特征而会忽略部分局部信息，更适合处理大规模存在冗余的数据。在卷积层的输出结果中添加激活函数可以提高 CNN 的非线性拟合能力。常见激活函数的表达式和取值范围^[51]如表 3-1 所示：

表3-1 激活函数对比

激活函数	表达式	取值范围
<i>Relu</i>	$f(x) = \max(0, x)$	$[0, +\infty]$
<i>Tanh</i>	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	$[-1, 1]$
<i>Sigmoid</i>	$f(x) = \frac{1}{1 + e^{-x}}$	$[0, 1]$

由于 *Tanh* 和 *Sigmoid* 等激活函数会使网络收敛速度慢，且存在梯度消失的问题，训练过程中容易使网络陷入局部最优，故本文将所涉及的 CNN 网络均采用 *Relu* 函数作为卷积层的激活函数。

3.1.2 门控循环单元

GRU 由 Chung 等人于 2014 年首次提出^[52]。作为一种由传统循环神经网络（Recurrent Neural Network, RNN）和长短时记忆网络（Long Short Term Memory, LSTM）改进而来的循环神经网络，GRU 除了允许每个循环单元在不同时间长度上自适应地捕获序列依赖关系，还能避免梯度消失、减少训练过程所需参数量。图 3-2 显示了一个 GRU 单元，其中重置门决定了新输入信息与过去信息的结合方式，更新门决定了过去信息保存到当前时间步的量。

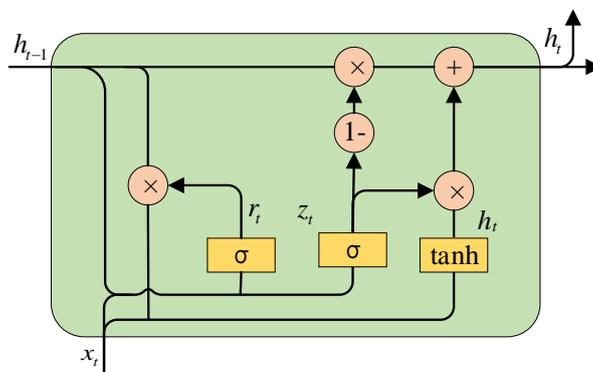


图3-2 GRU 原理图

如式(3-2)所示，在时间步长 t 时，GRU 单元的正向传递可描述为：

$$\begin{cases} r_t = \sigma(w_{xr}^T \cdot x_t + w_{hr}^T \cdot h_{t-1} + b_r) \\ z_t = \sigma(w_{xz}^T \cdot x_t + w_{hz}^T \cdot h_{t-1} + b_z) \\ \tilde{h}_t = \tanh(w_{x\tilde{h}}^T \cdot x_t + w_{h\tilde{h}}^T \cdot (r_t \otimes h_{t-1}) + b_{\tilde{h}}) \\ h_t = y_t = z_t \otimes \tilde{h}_t + (1 - z_t) \otimes h_{t-1} \end{cases} \quad (3-2)$$

式中 r_t 、 z_t ——复位门和更新门；
 x_t ——输入；
 w ——权重值；
 \tilde{h}_t 、 h_t ——候选隐藏状态和输出；
 $\sigma(\cdot)$ 、 $\tanh(\cdot)$ ——sigmoid 激活函数和 bitangent 激活函数；
 \otimes ——逐元素的乘法。

在模型训练过程中，首先需要进行参数初始化，然后不断调整模型参数值以学习数据的输入输出映射关系，使模型能够适应未来的新数据并推断新数据的结果。梯度下降是深度学习主要的训练方法，它通过反向传播算法来计算模型可训练参数的损失函数梯度，不断调整模型直到损失函数收敛或达到预期值。在得知损失函数 L 的前提下，可以通过求解损失函数在某个时间步的 GRU 参数梯度来得到模型预测输出的梯度。求得权重矩阵参数梯度后可以根据优化器算法来更新网络参数，此处不再赘述。

3.1.3 自适应循环神经网络

Ada-RNN 是一类迁移学习方法，它可以找到训练数据集中分布差异最大的数据段，并缩小这些数据段之间的分布差异，从而达到比传统的 RNN 模型更高的泛化和准确性。Ada-RNN 的结构如图 3-3 所示，它主要由两部分组成：时间分布表征（Temporal Distribution Characterization, TDC）和时间分布匹配（Temporal Distribution Matching, TDM）。

3.1.3.1 时间分布表征

TDC 算法的目标是找到分布差异最大的数据段，并根据最大熵原理将其分割开来，通过式(3-3)搜索彼此差异最大的时间段：

$$\begin{aligned} \max_{0 < K \leq K_0} \max_{n_1, \dots, n_K} \frac{1}{K} \sum_{1 \leq i \neq j \leq K} d(D_i, D_j) \\ st. \forall i, \Delta_1 < |D_i| < \Delta_2; \sum_i |D_i| = n \end{aligned} \quad (3-3)$$

式中 K ——周期数；

- K_0 ——避免过度分割的超参数；
- $d(\cdot, \cdot)$ ——距离度量；
- D ——时间序列分段；
- Δ_1 、 Δ_2 ——超参数，避免陷入局部最优解；
- $d(\cdot, \cdot)$ ——距离函数。

距离函数有多种选择，可以是最大均值差异（Maximum Mean Discrepancy, MMD）或余弦距离。本文将选取式(3-4)所示的 MMD 距离作为每对段之间的距离计算公式：

$$d_{mmd}(x_s, x_t) = \frac{1}{n_s} \sum_{i,j=1}^{n_s} k(x_{s_i}, x_{s_j}) + \frac{1}{n_t} \sum_{i,j=1}^{n_t} k(x_{t_i}, x_{t_j}) - \frac{2}{n_s n_t} \sum_{i,j=1}^{n_s+n_t} k(x_{s_i}, x_{t_j}) \quad (3-4)$$

式中 x_s 、 x_t ——源数据和目标数据；

$k(\cdot, \cdot)$ ——径向基函数（Radial Basis Function, RBF）核；

n_s 和 n_t ——两组数据的个数。

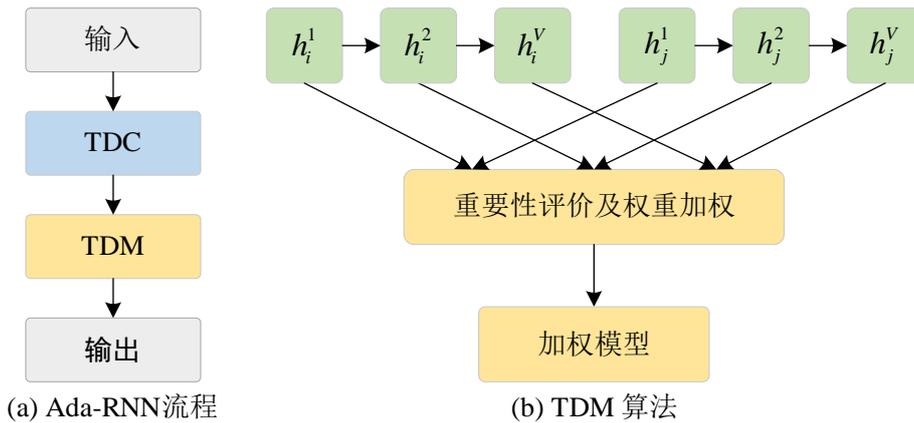


图3-3 Ada-RNN 模型

为了避免复杂的计算，TDC 算法将时间序列均匀地分成若干部分，其中每一部分都是最小的单元，不可分割。然后通过贪心算法在 $[2, N]$ 范围内确定合适的整数 K 。例如，如果我们设置数据的起点为 A ，终点为 B ， N 为 5。当 $K = 2$ 时，我们的目标是找到一个合适的点 C ，使距离 $d(S_{AC}, S_{CB})$ 最大化。TDC 算法一般应用于时间序列中没有明显分布差异的情况。如果一段时间序列本身有明显的分布差异限制，可以手动划分不同的数据段，也可以达到得到分布差异最大的数据段的目的。

3.1.3.2 时间分布匹配

TDM 算法如图 3-3(b)所示，通过使式(3-5)所示的损失函数最小化来实现对数据段的匹配，进而建立预测模型：

$$L(\theta, \alpha) = L_{pred}(\theta) + \lambda \frac{2}{K(K-1)} \sum_{i,j}^{i \neq j} L_{tdm}(D_i, D_j; \theta, \alpha) \quad (3-5)$$

式中 θ ——可学习模型参数；
 α ——每对数据段的重要性评价因子；
 λ ——权衡参数；

特别地， $L_{pred}(\theta)$ 可以用式(3-6)来计算：

$$L_{pred}(\theta) = \frac{1}{K} \sum_{j=1}^K \frac{1}{|D_j|} \sum_{i=1}^{|D_j|} l(y_i^j, M(x_i^j; \theta)) \quad (3-6)$$

式中 $l(\cdot, \cdot)$ ——MSE 损失函数；
 M ——预测模型；
 (x_i^j, y_i^j) ——序列 D_j 的第 i 个带标签数据。

给定一个时间序列对 (D_i, D_j) ，损失的时间分布匹配可以通过式(3-7)获得：

$$L_{tdm}(D_i, D_j; \theta, \alpha_{i,j}^t) = \sum_{i=1}^V \alpha_{i,j}^t d(h_i^t, h_j^t; \theta) \quad (3-7)$$

式中 (h_i^t, h_j^t) ——从序列 D_i 和 D_j 训练模型所得到的隐藏状态参数。

每对数据段的评价因子 $\alpha_{i,j}^t$ 旨在学习模型中 V 维隐藏状态的相对重要性，它由最初的少量循环通过式(3-8)计算得到：

$$\alpha_{i,j}^{t,(n+1)} \begin{cases} \alpha_{i,j}^{t,(n)} \times (1 + \sigma(d_{i,j}^{t,(n)} \times d_{i,j}^{t,(n-1)})) & d_{i,j}^{t,(n)} \geq d_{i,j}^{t,(n-1)} \\ \alpha_{i,j}^{t,(n)} & \text{其它} \end{cases} \quad (3-8)$$

式中 $d_{i,j}^{t,(n)}$ ——时间步 t 、第 n 轮训练时的分布距离，如果第 $n+1$ 个训练循环计算出的评价因子大于第 n 个训练循环的，则取第 n 个循环的评价因子用来减小分布差异。

通过 TDC 算法和 TDM 算法，Ada-RNN 同时考虑了多个数据段本身的分布差异，利用重要性评价赋予这些根据不同数据段训练出的模型参数以不同的权重，最终通过多个模型参数的加权获得一个迁移学习模型。但是该方法仍存在诸如未能考虑数据的空间特征、RNN 基础模型易发生梯度消失、模型存在系统性误差等问题，在电池状态估计领域的应用仍存在不小挑战。

3.1.4 卡尔曼滤波算法

卡尔曼滤波是一种时域滤波方法，可以处理多维和非平稳随机过程，实现对系统状态的最优估计。传统的卡尔曼滤波中，为建立线性动态系统的卡尔曼滤波方程，需首先建立如式(3-9)所示的系统状态空间表达式：

$$\begin{cases} \dot{x}(t) = Ax(t) + Bu(t) \\ y(t) = Cx(t) + Du(t) \end{cases} \quad (3-9)$$

通过求解微分方程，找到状态转移矩阵 F 和控制矩阵 G ，状态外推方程可以表示为式(3-10)：

$$\hat{x}_{n+1,n} = F\hat{x}_{n,n} + G\hat{u}_{n,n} \quad (3-10)$$

KF 算法利用前一时刻的估计值和当前时刻的观测值，得到当前时刻的最优估计。它由时间更新方程和状态更新方程两部分组成。时间更新方程如式(3-11)所示，用于在时间上外推当前状态变量的值和误差协方差估计，以构建下一个时间状态的先验估计：

$$\begin{cases} \hat{x}_{n+1,n} = F\hat{x}_{n,n} + Gu_n \\ P_{n+1,n} = FP_{n,n}F^T + Q \end{cases} \quad (3-11)$$

式中 $\hat{x}_{n,n}$ 、 $\hat{x}_{n+1,n}$ ——时间步 n 估计的系统状态向量和下一步的预测的系统状态向量；

u_n ——输入变量；

F 、 G ——状态转移矩阵和控制矩阵；

$P_{n,n}$ 、 $P_{n+1,n}$ ——时间步 n 的状态协方差矩阵和下一步状态协方差矩阵；

Q ——过程噪声的不确定性。

如公式(3-12)所示状态更新方程通过在先验估计中加入新的测量值的影响，得到最终改进后的后验估计：

$$\begin{cases} K_n = P_{n,n-1}H^T(HP_{n,n-1}H^T + R_n)^{-1} \\ \hat{x}_{n,n} = \hat{x}_{n,n-1} + K_n(z_n - H\hat{x}_{n,n-1}) \\ P_{n,n} = (I - K_nH)P_{n,n-1}(I - K_nH)^T + K_nR_nK_n^T \end{cases} \quad (3-12)$$

式中 K_n ——卡尔曼增益；

H ——观测矩阵；

R_n ——测量不确定度；

z_n ——测量值；

I ——单位矩阵。

3.2 FB-Ada-CNN-GRU-KF 模型

Ada-RNN 模型以 RNN 为基础，模型在训练过程中对于早期输入生成的网络权重容易产生梯度消失等问题，梯度被近距离梯度主导，难以解决长时间尺度预测问题。而 GRU 引入更新门和重置门来控制前一时刻的隐状态对当前时刻隐状态的影响，从而使得反向传播时梯度更好地传递。车用电池放电

中将产生较长的时间序列数据，为满足预测要求，本文将以 GRU 为基础搭建用作 SOC 估计的深度迁移学习模型。

另外，如第二章所介绍，电压、电流、温度等特征都会对电池状态产生影响，而这些特征在收集到的数据中并非沿时间线排列，而是在同一时间按空间排列。若将同时包含时间序列信息和空间信息的数据输入 GRU 模块，将造成空间信息的丢失，不利于原始电池数据信息的有效利用。故本文将在 GRU 层之前添加 CNN 卷积层，先利用 CNN 卷积层提取电池数据的空间信息，再利用 GRU 层解决时间序列问题中的梯度消失和梯度爆炸等问题。

对于深度学习模型，受训练数据分布以及模型本身结构的影响，训练出的模型可能存在系统误差，及对特定被预测序列，模型的预测结果出现某种保持恒定或按确定的方法变化的误差。由于系统误差具有确定性，故理论上系统误差可以被预测出来，基于此，本文提出用于深度迁移学习模型的误差反馈机制。通过对模型系统误差的预测，获得在实际测试环境中可能会出现的具体误差，达到修正目的。

深度学习模型参数众多，过多的参数除了容易造成模型过拟合问题外，还会使模型输出产生较大波动。添加 Dropout 层、BatchNorm 层、增大训练数据量等传统方法，的确能够一定程度解决过拟合问题，但是不能够很好地解决复杂预测问题中的预测波动。KF 算法同时考虑观测值以及预测值，能够较好地平衡二者的误差及波动。且 KF 算法在深度迁移学习模型的应用中，不需要考虑复杂的电池等效电路模型建模，可直接将深度迁移学习模型的输出结果作为观测值，降低了模型的应用难度。本文将采取 KF 算法作为降低模型预测波动的后处理器。

本文提出的 SOC 估计 FB-Ada-CNN-GRU-KF 模型框架如图 3-4 所示，主要由 3 个步骤组成：

第一步：划分数据集为训练集、验证集和测试集，并根据工况的不同，进一步在训练集中分出不同的训练片段。以电压、电流、温度作为输入，SOC 值作为输出，按照训练片段对 Ada-CNN-GRU 模型进行预训练，得到初步预测的 SOC。该 SOC 预测值存在系统性误差，由于数据集标签已知，可以根据参考 SOC 计算出训练集与验证集上的 SOC 误差，该 SOC 误差值在一定程度上反映了模型的系统性精度。

第二步：将第一步得出来的 SOC 系统误差进行数据清洗，去除异常值，作为训练集与验证集的标签，进行预测 SOC 系统误差的 Ada-CNN-GRU 模型的训练。训练完成的模型可以预测测试集中可能会出现的具体 SOC 系统误差。

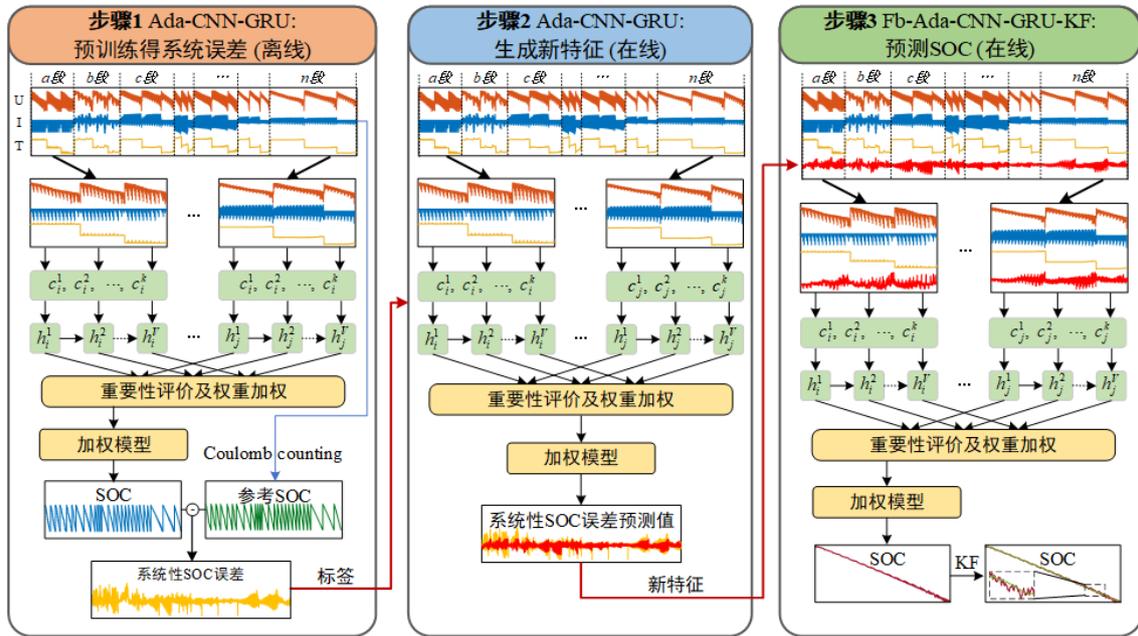


图3-4 FB-Ada-CNN-GRU-KF 模型框架

第三步：将第二步训练过程中训练集和验证集中的 SOC 误差以及测试集中预测出的 SOC 误差作为 SOC 预测模型的除电压、电流、温度外的第四个特征，以 SOC 值作为标签，实现基于深度迁移学习模型的 SOC 预测。最后使用 KF 算法对模型输出做后处理，将模型预测值作为观测值，将安时积分法作为更新方程，得到平稳的 SOC 最终输出。

为了更好地对模型预测效果进行评价，本文选择最大绝对误差 (Maximum error, MAX)、平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE) 作为模型的评价指标。其中，MAX 是指一个预测序列中预测值和真实值间残差绝对值的最大值；MAE 衡量的是预测值和参考值间残差绝对值的平均值；RMSE 衡量预测值和参考值间残差的标准偏差，相对 MAE 来说，RMSE 对大误差值更为敏感。三个评价指标的计算过程如式(3-13)所示：

$$\begin{cases} \text{MAX} = \max(|y_i - \hat{y}_i|) \\ \text{MAE} = \frac{1}{m} \sum_{i=1}^m |y_i - \hat{y}_i| \\ \text{RMSE} = \sqrt{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2} \end{cases} \quad (3-13)$$

3.3 多温度下 SOC 估计验证

根据 1.2 节的分析，温度将会对电池的荷电状态产生较大影响，是电池 SOC 估计时不可忽略的一个因素。受限于电池老化实验中温度变化的单一，本小节将采用松下电池公开数据集进行多温度下 SOC 估计效果的验证。

PyTorch 是一个基于 Torch 库的开源机器学习框架，用于计算机视觉和自然语言处理等应用。许多深度学习软件都建立在 PyTorch 的基础上，包括特斯拉 Autopilot、Uber 等。PyTorch 提供了两个高级特性：1.张量计算，通过图形处理单元（GPU）实现强加速；2.自动求导系统的深度神经网络系统。故本文使用 PyTorch 框架搭建网络模型。

为与传统深度学习模型 CNN-GRU 作对比，同时验证 FB-Ada-CNN-GRU-KF 模型的空间特征提取模块、误差反馈模块和后处理器模块的有效性，对各模型进行如表 3-2 所示参数设置，Ada-CNN-GRU 模型和 FB-Ada-CNN-GRU 模型的网络参数设置均与 FB-Ada-CNN-GRU-KF 模型相同，不再赘述。

表3-2 网络结构及其参数设置

网络层	CNN-GRU	Ada-GRU	FB-Ada-CNN-GRU-KF
CNN 层	(1, 8, (8, 3))	-	(1, 8, (8, 3))
CNN 层	(8, 32, 8)	-	(8, 32, 8)
GRU 层	(32,32,2)	(4,32,2)	(32,32,2)
FC 层	(32, 8)	(3, 1)	(32, 8)
FC 层	(8, 1)	无	(8, 1)

经多次反复调整，设置批量大小为 64，窗口大小为 120，学习率为 1e-4，学习轮数为 1000，则输入数据的维度为 (64, 120, 3)。CNN 卷积核参数设置为 (1, 8, (8, 3))，表示将维度为 (批量 64，输入层数 1，长度 120，特征维度 3)的一个输入数据，通过一个大小为 (8, 3) 的卷积核，转化为 (批量 64，输出层数 8，长度 113，特征维度 1)的输出数据；同理，CNN-GRU 和 CNN-LSTM 模型经过第二个卷积层，生成维度为(批量 64，输出层数 32，长度 106)的输出。以 CNN-GRU 中的 RNN 层为例，第一个 32 表示输入 RNN 的输入特征数，第二个 32 表示 RNN 的隐藏状态维度，也是其输出维度，2 表示有两层 RNN 层。然后取最后一个 RNN 模块的输出状态，得到维度为(批量 64，输出神经元 32)的输出。FC 层中，(32, 8) 表示输入的维度为 32，输出的维度为 8。因用于得到最终预测值，故最终输出维度均为 1。

电池数据划分为训练集、验证集和测试集。SOC 估计训练数据集由 HPPC、Cycle 4、LA92、US06 4 个动态驾驶循环对应的数据组成，验证数据

集由 NN 循环对应的数据组成，测试数据集包括 HWFET 循环和 UDDS 循环记录的数据。由于电池的特性受温度影响较大，因此所有数据都包含了电池在 25°C、10°C 和 0°C 温度下的信息。在 FB-Ada-CNN-GRU-KF 深度迁移学习模型中，由于本文使用的数据来自实验室，采用手工的 TDC 方法对时间序列进行分割，很容易识别出所有数据集的分布差异，结果如图 3-5 所示。

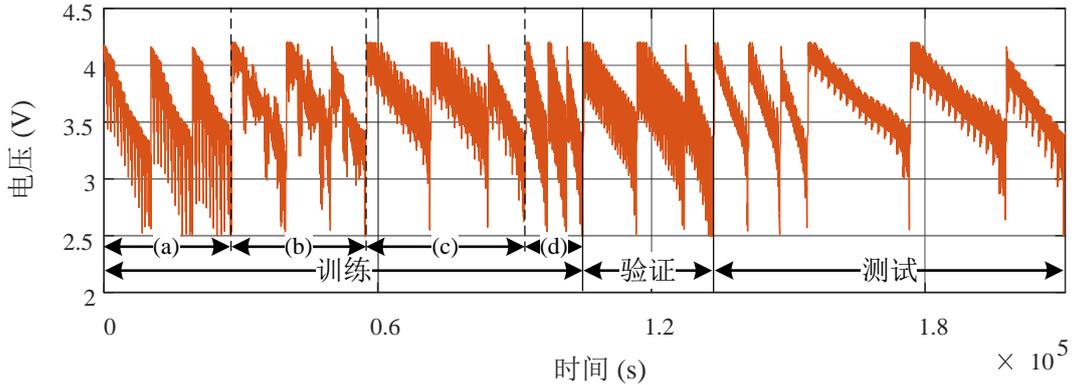


图3-5 电池数据的数据集划分和 TDC 操作

模型输入输出可由式(3-14)表示，输入为固定维度大小为 120×3 的矩阵，输出为 1×1 的 SOC 值：

$$\left\{ \begin{array}{l} input_i = \begin{pmatrix} U_i & I_i & T_i \\ U_{i+1} & I_{i+1} & T_{i+1} \\ \vdots & \vdots & \vdots \\ U_{i+119} & I_{i+119} & T_{i+119} \end{pmatrix}_{120 \times 3} \\ output_i = (SOC_i)_{1 \times 1} \end{array} \right. \quad (3-14)$$

式中 U_i ——第 i 个采样点的电压；

I_i ——第 i 个采样点的电流；

T_i ——第 i 个采样点的温度；

SOC_i ——第 i 个采样点的荷电状态，120 行表示输入窗口包含 120 个采样点；

图 3-6 展示了经过步骤 2 之后所有训练集、验证集和测试集的 SOC 误差预测值。对于训练集和验证集，SOC 误差预测值无实际预测意义，此处用训练好的模型提取出其在训练集和验证集的 SOC 误差特征，为后续的训练和验证提供数据基础。在第 3 步中，SOC 误差预测值将其作为新的反馈特征应用于 FB-Ada-CNN-GRU 模型和 FB-Ada-CNN-GRU-KF 模型的验证。需要注意，因为测试集中的 SOC 误差是基于电压、电流和温度来预测的，所以可以在未知条件下该特征同样可以应用。

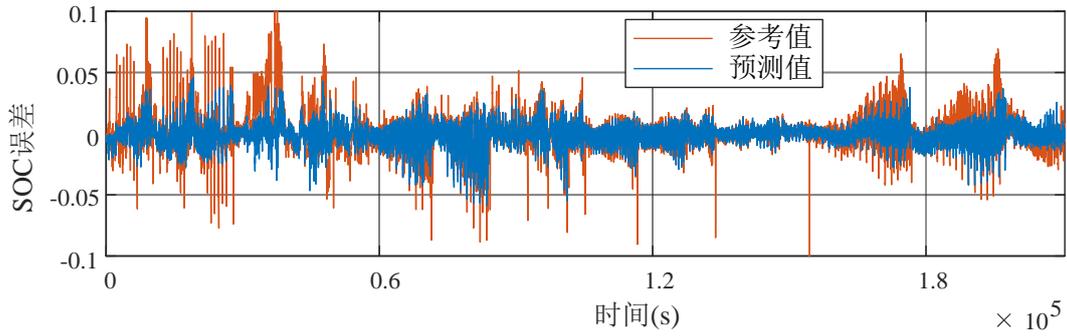


图3-6 SOC 误差预测

所有对比模型和本文提出的模型在不同温度下 HWFET 和 UDDS 动态驾驶工况下的 SOC 预测结果分别如图 3-7 和图 3-8 所示，其误差指标统计结果分别对应表 3-3 和表 3-4。

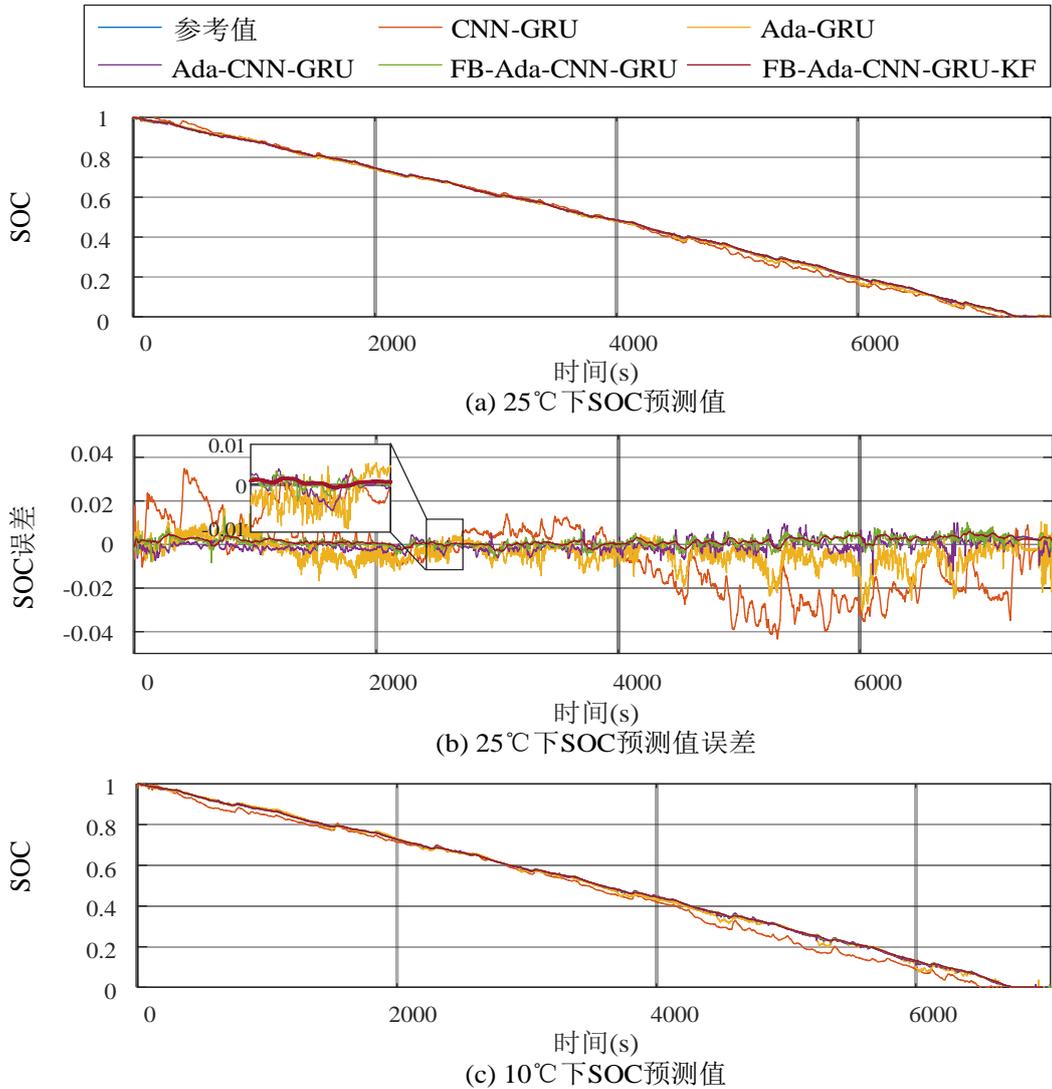
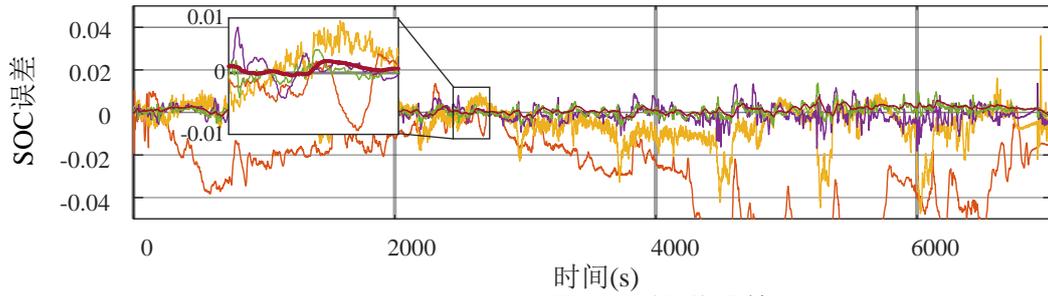
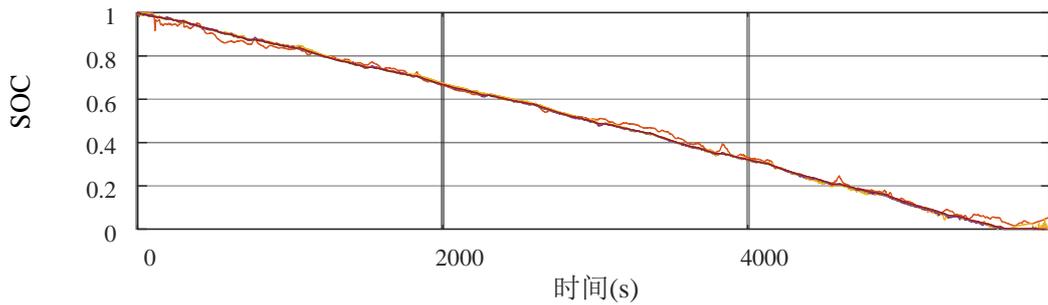


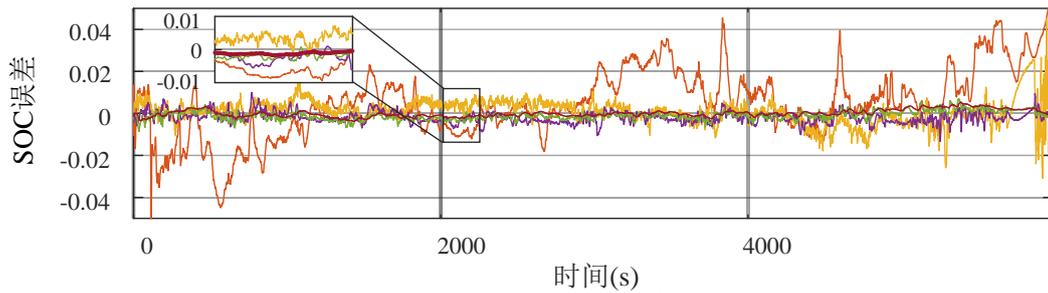
图 3-7 HWFET 工况 SOC 预测结果



(d) 10°C下SOC预测值误差



(e) 0°C下SOC预测值



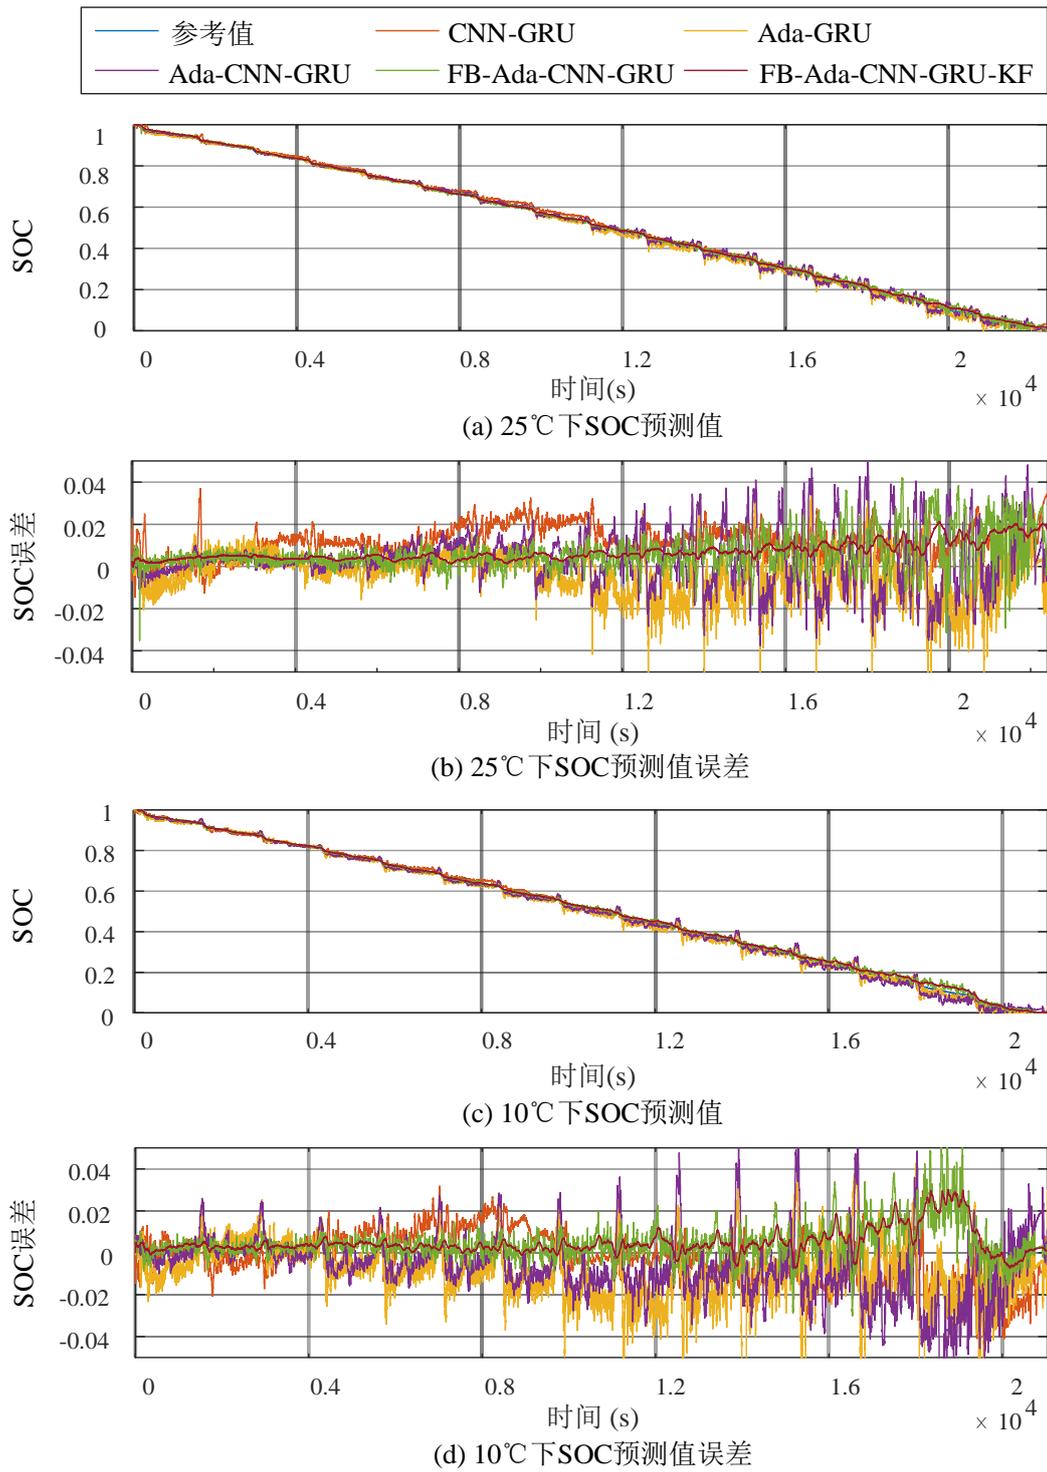
(f) 0°C下SOC预测值误差

图3-7 HWFET 工况 SOC 预测结果 (续)

表3-3 HWFET 循环下的评价结果

模型	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
#1	1.29	1.67	4.34	2.80	3.41	7.52	1.31	1.72	6.55
#2	0.59	2.24	3.06	0.79	2.81	4.75	0.50	2.23	4.52
#3	0.22	1.16	1.38	0.30	1.77	1.81	0.40	3.47	4.33
#4	0.19	0.24	1.29	0.17	0.23	1.38	0.19	0.23	0.86
#5	0.18	0.22	0.60	0.16	0.20	0.73	0.13	0.17	0.54

注意：#1：CNN-GRU，#2：Ada-GRU，#3 Ada-CNN-GRU，#4：FB-Ada-CNN-GRU，#5：FB-Ada-CNN-GRU-KF。表 3-4 中也使用了相同的编号。



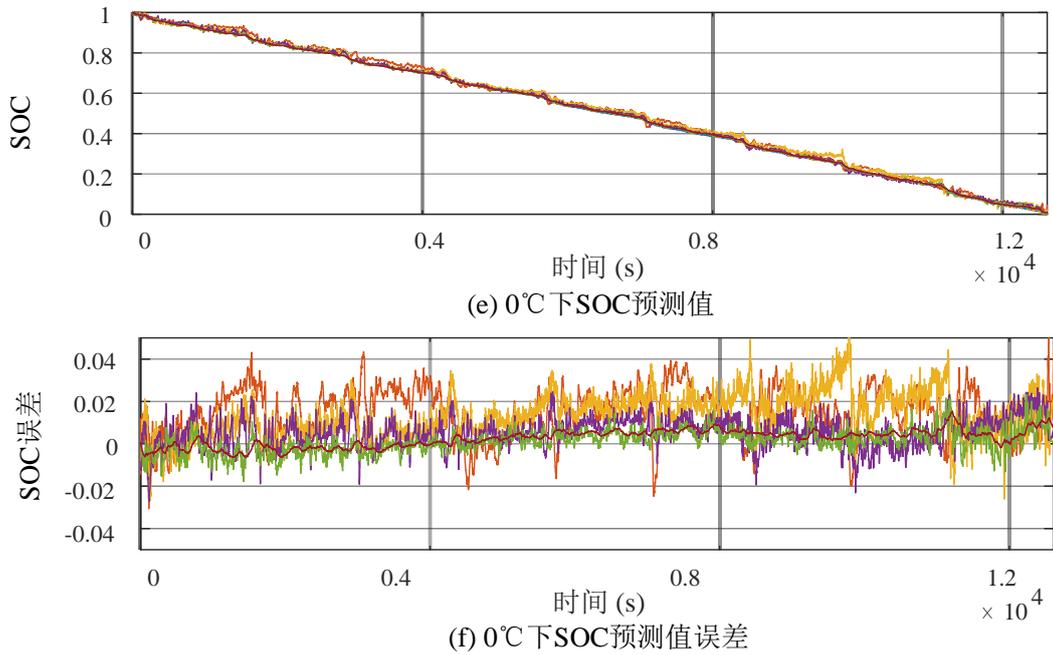


图3-8 UDDS 工况 SOC 预测结果（续）

表3-4 UDDS 循环下的评价结果

模型	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
#1	1.22	1.39	3.69	1.00	1.28	4.66	1.64	1.88	5.22
#2	0.86	1.62	6.59	1.29	2.16	7.71	1.47	1.73	7.59
#3	0.98	1.48	4.94	1.25	1.93	7.05	0.71	0.87	2.72
#4	0.74	1.04	4.20	0.62	0.93	5.26	0.42	0.53	2.32
#5	0.70	0.82	2.12	0.54	0.78	2.98	0.39	0.47	1.52

从图表中可以看出，在 HWFET 和 UDDS 动态驾驶循环下，各工况下 CNN-GRU 模型的 MAE、RMSE 和 MAX 误差始终最大。相比之下，具有迁移学习的 Ada-GRU 模型的 MAE 和 RMSE 相对较小，但仍然存在较大的波动。Ada-CNN-GRU 方法在 Ada-GRU 模型中 GRU 层前添加 CNN 层，考虑了数据的空间特征，可以在 HWFET 动态驾驶循环下 MAE 为 0.5%，UDDS 动态驾驶循环下 MAE 为 1.5%。通过在 Ada-CNN-GRU 模型中引入反馈机制，可以实现 HWFET 驾驶循环下的 MAE 为 0.2%，UDDS 动态驾驶循环下的 MAE 为 0.8%，这意味着精度进一步提高。采用 KF 作为后处理器的 FB-Ada-CNN-GRU-KF 模型在 HWFET 动态驾驶循环下 MAE 小于 0.2%，最大误差小于 0.8%；在 UDDS 动态驾驶循环下 MAE 小于 0.8%，最大误差小于 3%。

综上，与传统的 CNN-GRU 模型相比，通过引入迁移学习、空间特征提取、反馈机制和 KF 作为后处理器，本文提出的 FB-Ada-CNN-GRU-KF 模型

在锂离子电池 SOC 估计的准确性、泛化性和稳定性方面都有了显著提高。

3.4 多老化点下 SOC 估计验证

随着电池的老化，电池的容量会逐渐下降，导致 SOC 估计精度的下降。现存的 SOC 估计方法往往只考虑单一健康状态的 SOC 估计，无法应用电池的全生命周期估计。本小结将电池的 SOH 考虑在内，利用第 2 章所完成的带动态工况测试的电池老化试验，进行多老化点下的 SOC 估计验证。同时，为简化模型的训练过程，提高预测效率，搭建简化掉误差反馈模块的 Ada-CNN-GRU-KF 模型，其结构如图 3-9 所示。

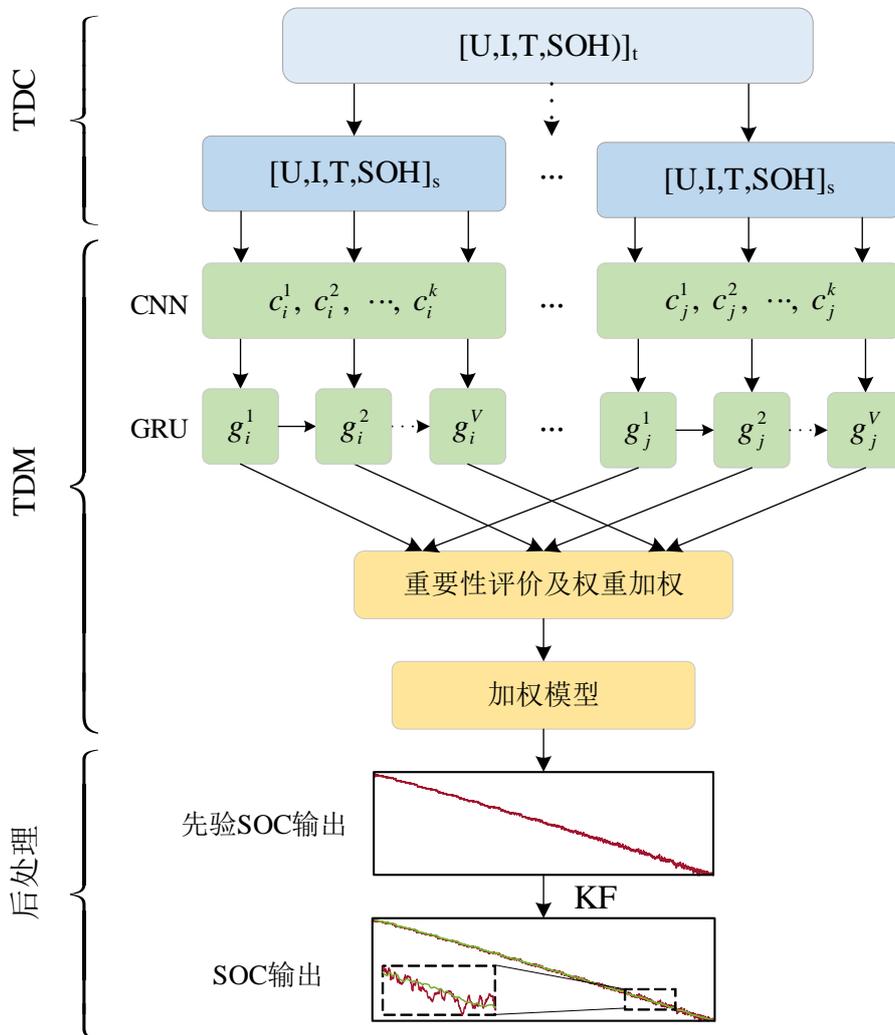


图3-9 Ada-CNN-GRU-KF 模型

为验证该模型在多老化点 SOC 估计任务中的有效性。首先将数据划分为训练集、验证集与测试集，其中，Cap（容量测试工况）、DST、UDDS、

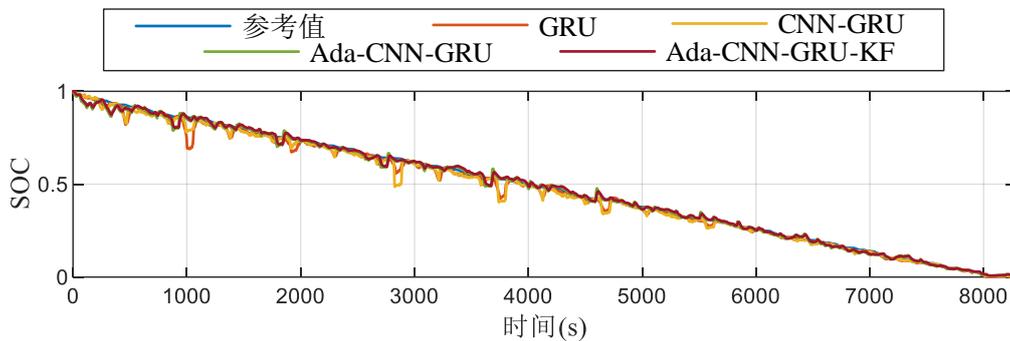
FUDS 等 4 个工况数据作为训练集、US06 作为验证集、BJDST 作为测试集。再根据训练集中工况的不同，即数据分布的不同，手动划分出 4 个分布差异较大的时间序列片段。

对于模型训练、验证及测试所需的数据，仍以窗口的方式进行输入，窗口大小为 120，特征数为 4，其数学表达式见公式(3-15)：

$$\begin{cases} input_i = \begin{pmatrix} U_i & I_i & T_i & SOH_i \\ U_{i+1} & I_{i+1} & T_{i+1} & SOH_{i+1} \\ \vdots & \vdots & \vdots & \vdots \\ U_{i+119} & I_{i+119} & T_{i+119} & SOH_{i+119} \end{pmatrix}_{120 \times 4} \\ output_i = (SOC_i)_{1 \times 1} \end{cases} \quad (3-15)$$

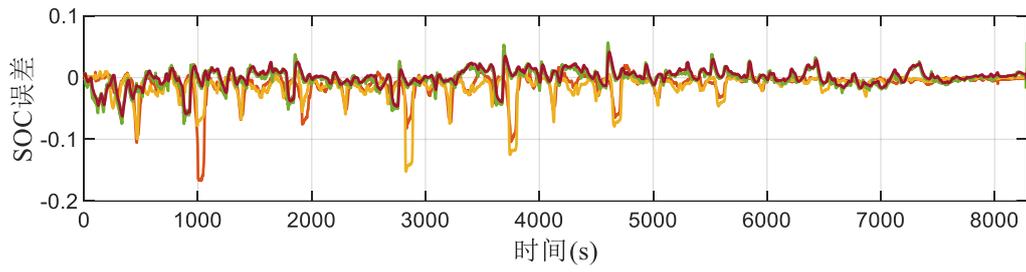
需要注意的是，虽然在测试过程中电池位于温度控制箱内，但电池温度仍会受放电倍率影响而产生变化，故温度将同样作为模型输入。另外，为了第 4 章进行 SOC 和 SOH 的联合估计，用于 SOC 估计的模型不宜过于复杂。而带反馈的 FB-Ada-CNN-GRU-KF 需要对模型进行三次训练目标不同的训练；另外，在预测 SOC 值时也需要先预测出 SOC 估计中可能会出现误差，然后再进行以 SOC 值为目标的 SOC 估计。为了简化模型，在做多老化点 SOC 估计时舍弃误差反馈机制。

根据验证集中的 KF 调参经验，设置量测噪音 R 为 10^{-3} ，过程噪音 Q 为 10^{-5} 。另外，对于所有用于对比及验证多老化点 SOC 估计的模型，其网络超参数除需根据输入维度进行必要调整外，基本与 3.4 节所建立模型保持一致，并进行模型的重新训练，得到 BJDST 工况下多老化点的 SOC 估计结果如图 3-10 所示，各老化点下的误差指标见表 3-5 与表 3-6。

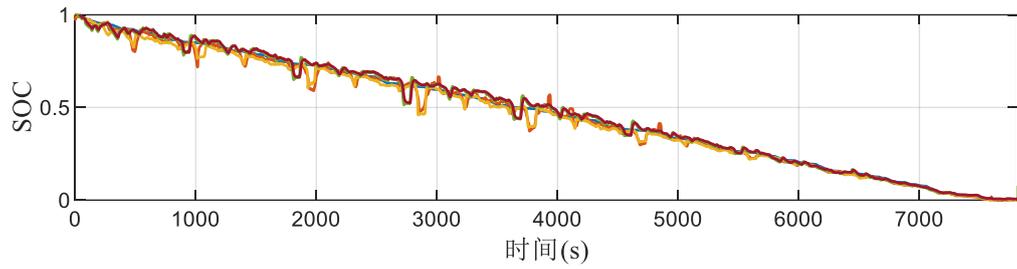


(a) 老化点1下SOC预测值

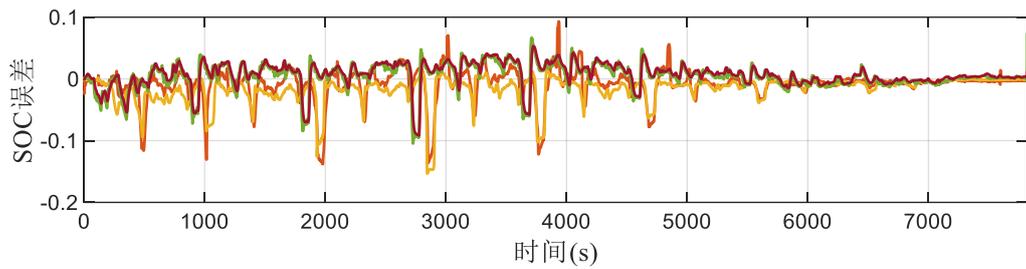
图 3-10 BJDST 工况下全生命周期内 SOC 估计结果



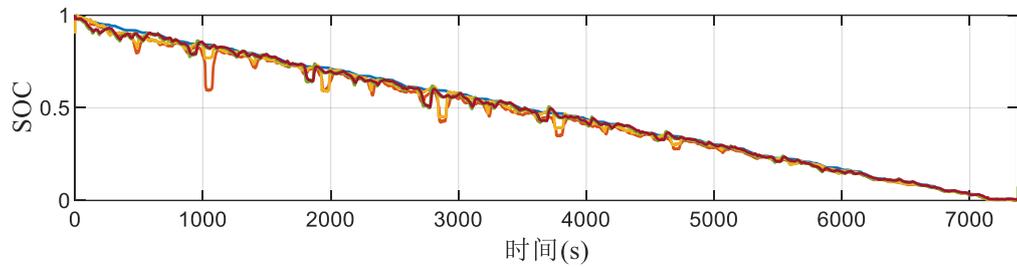
(b) 老化点1下SOC预测值误差



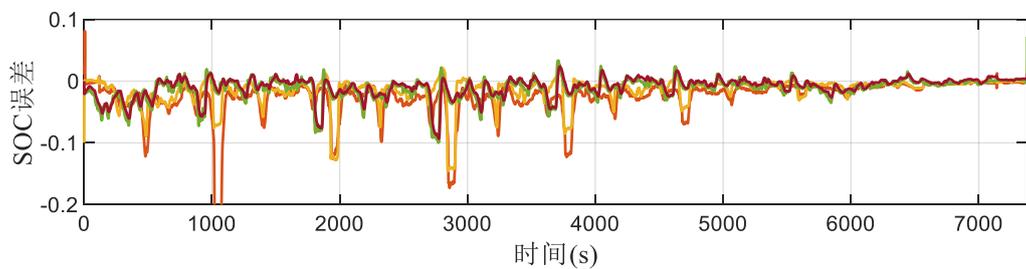
(c) 老化点2下SOC预测值



(d) 老化点2下SOC预测值误差

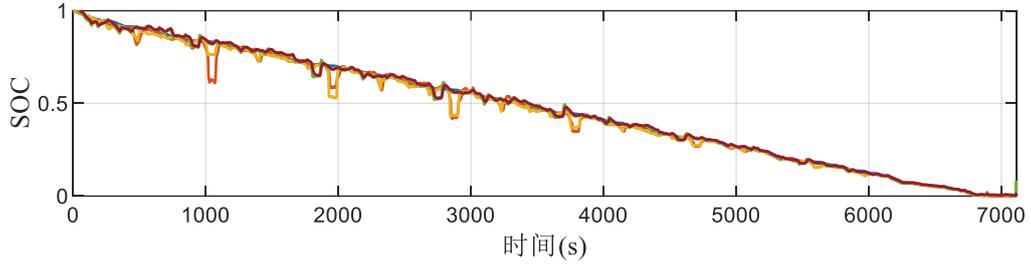


(e) 老化点3下SOC预测值

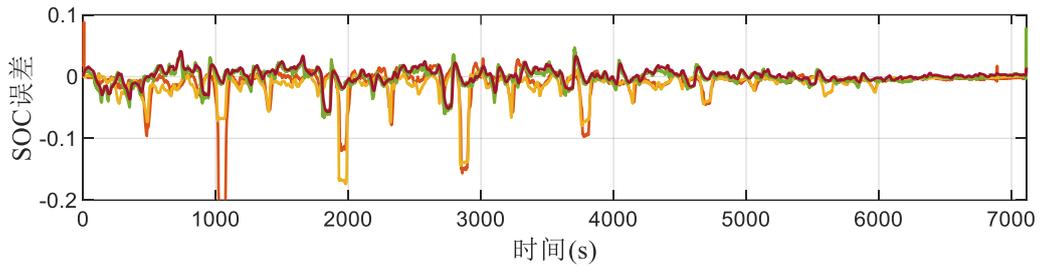


(f) 老化点3下SOC预测值误差

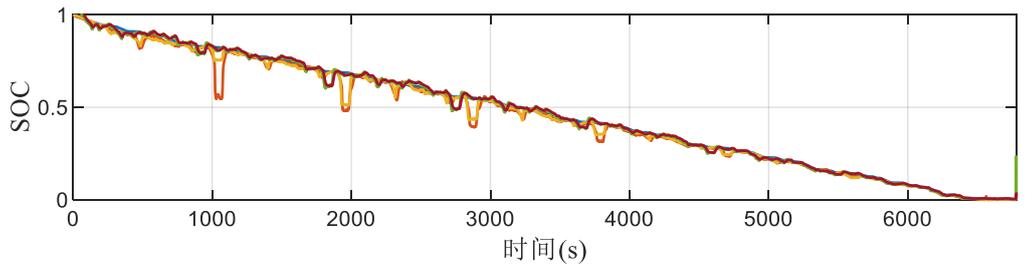
图 3-10 BJDST 工况下全生命周期内 SOC 估计结果 (续)



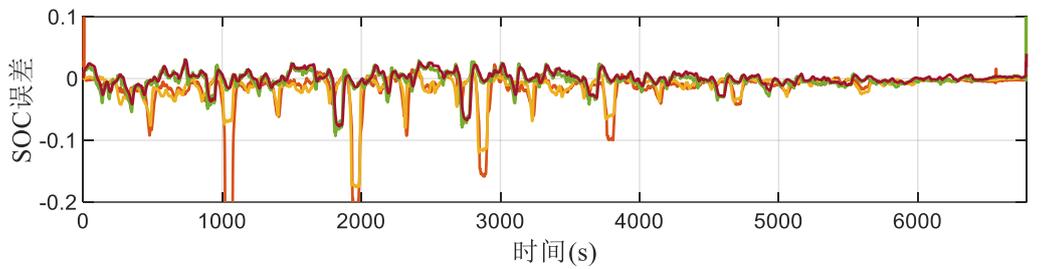
(g) 老化点4下SOC预测值



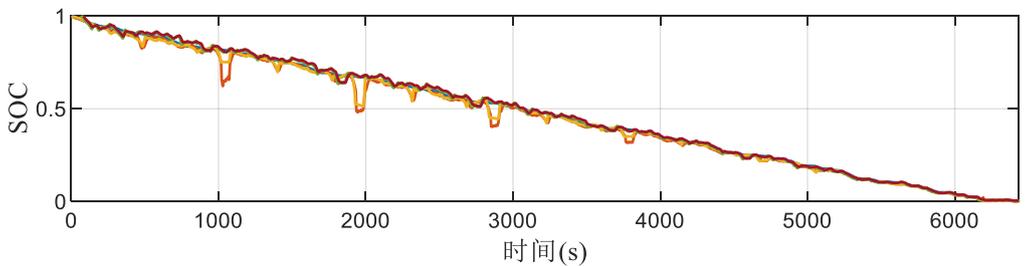
(h) 老化点4下SOC预测值误差



(i) 老化点5下SOC预测值

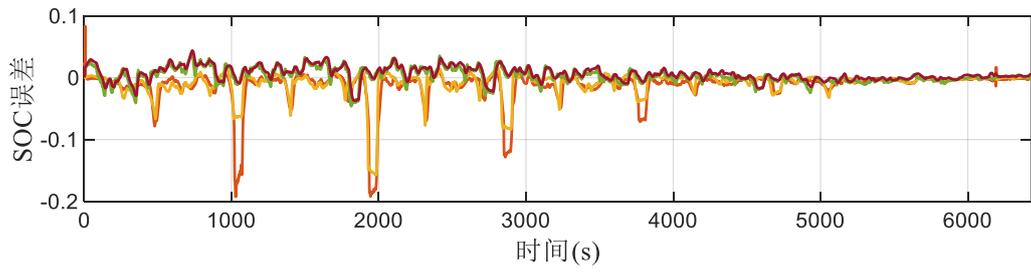


(j) 老化点5下SOC预测值误差

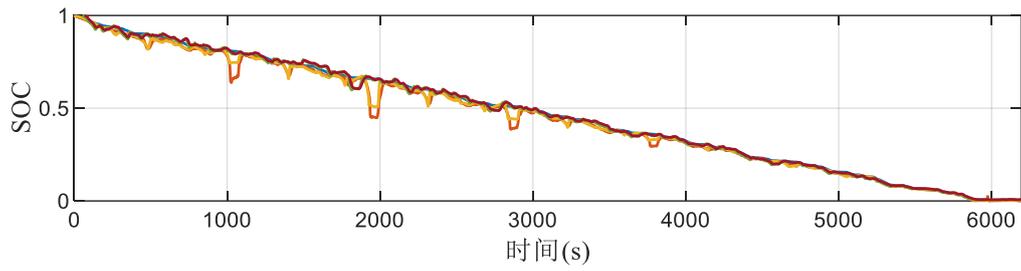


(k) 老化点6下SOC预测值

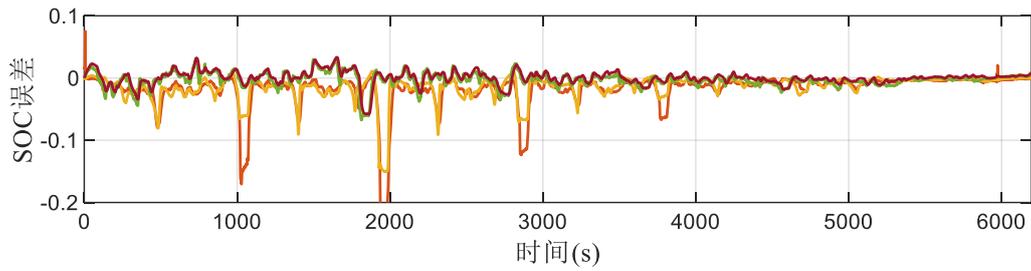
图 3-10 BJDST 工况下全生命周期内 SOC 估计结果 (续)



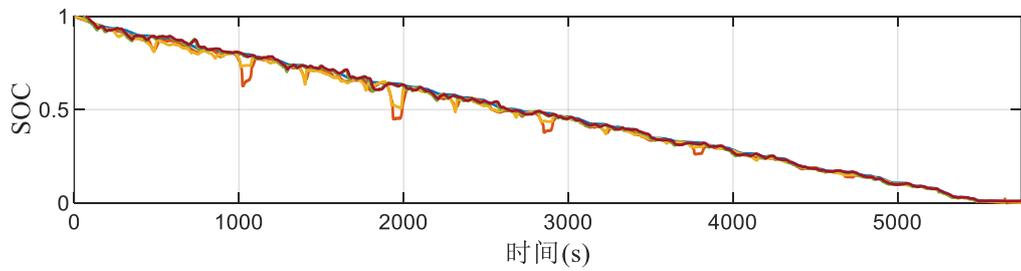
(l) 老化点6下SOC预测值误差



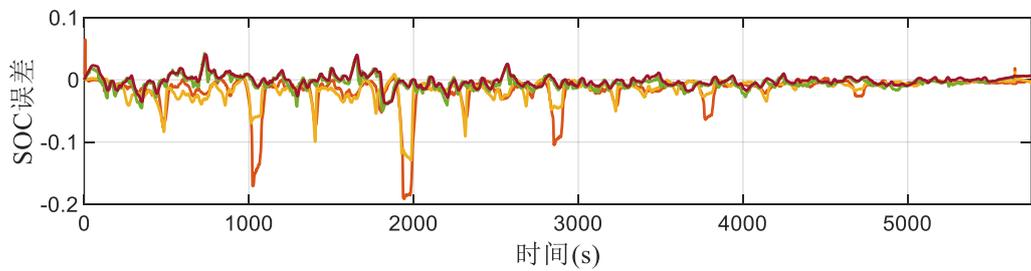
(m) 老化点7下SOC预测值



(n) 老化点7下SOC预测值误差



(o) 老化点8下SOC预测值



(p) 老化点8下SOC预测值误差

图3-10 BJDST 工况下全生命周期内 SOC 估计结果 (续)

表3-5 多老化点 BJDST 工况 GRU 与 CNN-GRU 模型评价

老化点	参考 SOH	GRU			CNN-GRU		
		MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
1	1.00	1.28	2.40	16.71	1.39	2.46	15.05
2	0.93	1.55	2.93	13.77	1.67	2.69	15.34
3	0.89	2.61	4.18	24.42	1.47	2.57	14.56
4	0.85	1.37	3.23	22.02	1.36	2.67	20.32
5	0.80	1.80	4.05	27.93	1.37	2.65	17.56
6	0.77	1.38	3.22	19.21	1.05	2.20	15.76
7	0.74	1.78	3.49	20.72	1.42	2.40	15.06
8	0.70	1.69	3.37	19.03	1.52	2.49	69.26

表3-6 多老化点 BJDST 工况 Ada-CNN-GRU 与 Ada-CNN-GRU-KF 模型评价

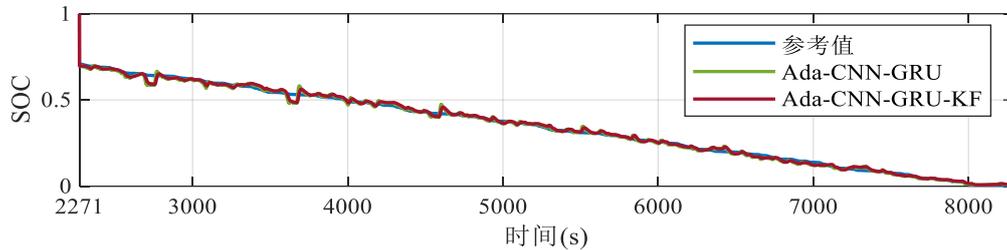
老化点	参考 SOH	Ada-CNN-GRU			Ada-CNN-GRU-KF		
		MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
1	1.00	1.07	1.54	7.47	1.00	1.40	6.36
2	0.93	1.53	2.15	10.48	1.52	2.05	9.19
3	0.89	1.41	2.12	9.97	1.19	1.85	9.36
4	0.85	0.92	1.34	7.82	0.86	1.23	5.71
5	0.80	0.99	1.59	23.47	0.90	1.40	7.72
6	0.77	0.92	1.22	4.64	0.96	1.28	4.38
7	0.74	0.80	1.19	6.74	0.72	1.08	5.80
8	0.70	0.85	1.14	4.91	0.71	0.99	4.11

由图表知，在多老化点 BJDST 工况下的 SOC 估计中，GRU 模型与 CNN-GRU 模型虽然能够取得一个较低的 MAE 值，但是其波动较大，最大误差普遍超过 15%，不适用于实际场景。CNN-GRU 模型整体估计效果优于 GRU 模型，再次证明了 CNN 模块的空间信息挖掘能力能够对 GRU 模型起到优化作用。采用迁移学习的 Ada-CNN-GRU 模型，能够将 MAE 控制在约 1.5% 以内，RMSE 也相对 CNN-GRU 模型有了明显下降，但是仍有部分老化点下的最大 SOC 误差超过 10% 甚至是 20%，表现为模型预测结果中异常值。使用 KF 做后处理器的 Ada-CNN-GRU 模型，在去除模型异常值的同时，对模型起到了稳定性加强的作用，将最大误差控制在了 10% 以内，8 个老化点下的 MAE 平均值达到了 0.98%，RMSE 平均值达 1.41%。整体来看，与传统的深度学习模型相比，所提出模型的准确性、泛化性和稳定性在电池全生命周期的 SOC 估计中再次得到验证。

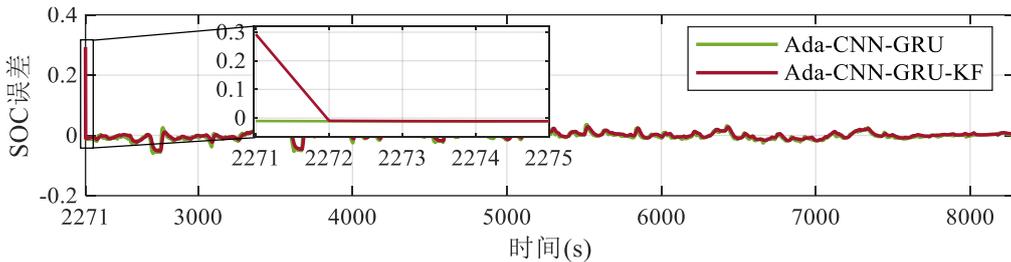
另外，为验证本方法在非满放条件下的估计效果，本小节选取电池第一个老化点 BJDST 放电工况分别从 2271 秒开始和从 5652 秒开始进行 SOC 估计，该时间点对应的参考 SOC 值分别为 0.7 和 0.3。Ada-CNN-GRU 模型的估计效果如图 3-10 所示。由于模型训练完成后其参数不变，输入数据的形式为

固定大小的窗口，不受窗口以外的前期数据影响，所以在非满充电条件下 Ada-CNN-GRU 在特定放电区间内的估计效果同满电条件下一致。

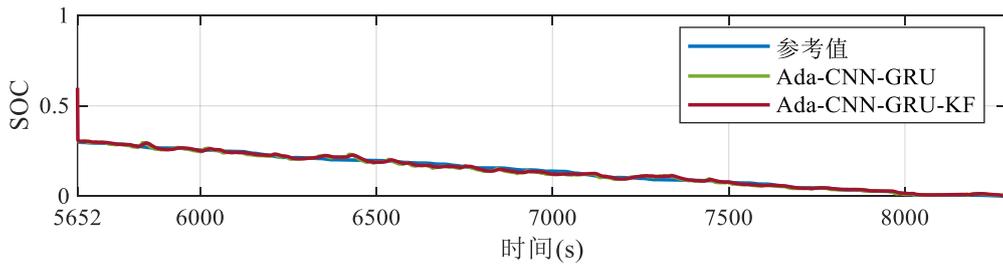
同时为验证 Ada-CNN-GRU-KF 模型在 KF 初值不准时的鲁棒性，设置极限 KF 初值偏差进行 SOC 估计实验。基于 Ada-CNN-GRU 模型在多老化点 SOC 估计任务中出现的最大估计误差为 23.47%，设置 KF 后处理器的初始偏差为 0.3 以模拟初始观测值的极限误差，即分别设置观测初值为 1 和 0.6。从图 3-11 中看出，Ada-CNN-GRU-KF 模型的估计结果可以在 2 秒内收敛到正常误差范围内，模型的鲁棒性得到验证。



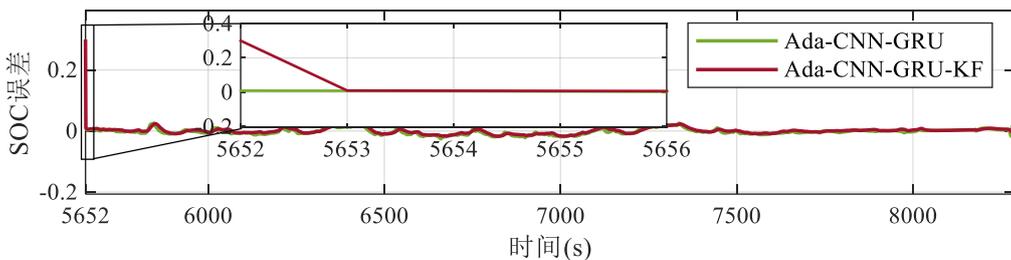
(a) SOC初始值为0.7、KF观测初值设为1时的SOC估计值



(b) SOC初始值为0.7、KF观测初值设为1时的SOC估计值误差



(c) SOC初始值为0.3、KF观测初值设为0.6时的SOC估计值



(d) SOC初始值为0.3、KF观测初值设为0.6时的SOC估计值误差

图3-11 第 1 个老化点在非满放以及 KF 观测初值有误时的 SOC 估计效果

3.5 本章小结

本章提出了一种结合迁移学习和深度学习优点的 FB-Ada-CNN-GRU-KF 模型。引入反馈机制预测 SOC 误差作为模型训练的新特征以消除系统性误差，并以 KF 作为后处理器提供稳定平滑的 SOC 估计结果。在不同环境温度下所提模型预测结果的平均 MAE 和 RMSE 分别为 0.78%和 0.82%，其准确性、鲁棒性以及各改进模块的有效性得到对比验证。又提出小体量的 Ada-CNN-GRU-KF 模型用于多老化点下 SOC 估计。模型在 BJDST 工况下的 MAE 平均值为 0.98%，RMSE 平均值达 1.41%，最大误差控制在 10%以内，为 SOC 与 SOH 的联合估计提供了基础。

第 4 章 SOC 和 SOH 的联合估计研究

准确预测电池 SOH 值可以为 BMS 提供电池极限容量信息，提高电池 SOC 等其他状态的估计算法精度，使电池工作在安全范围内并得到有效利用，并提高电动汽车的安全性和可靠性；SOC 同样需要在全生命周期内被准确估计。本章将在第一节建立双时间尺度输入的 Ada-CNN-GRU-Ave 模型用于小计算成本的 SOH 估计；在第二节中，不同输入特征及所提模型的有效性将被验证；基于第三章所建立的多老化点 SOC 估计模型以及本章第一节建立的 SOH 估计模型，SOC 与 SOH 的联合估计模型将在本章第三节建立；第四节将对联合估计模型的有效性进行验证。

4.1 SOH 估计模型与验证

4.1.1 Ada-CNN-GRU-Ave 模型

双时间尺度输入的 Ada-CNN-GRU-Ave 估计模型结构如图 4-1 所示，它由 TDC 模块、TDM 模块和后处理模块组成。TDC 算法和 TDM 算法已在 2.1.1 节中介绍。由于 SOH 是电池全寿命中变化极其缓慢的变量，且全生命周期内数据量极大，存在严重的数据冗余现象，因此 Ada-CNN-GRU-Ave 模型所需的数据以 0.1Hz 频率进行采样，即每隔 10 秒采集一组特征数据。

传统基于深度学习估计 SOH 的模型，往往仅采用电压、电流、温度三个特征作为输入，往往不能够对复杂动态工况下的 SOH 进行有效估计。如第二章所分析，SOH 与 SOC、累积放电容量（Accumulated Discharged Capacity, ADC）之间存在较强的相关性，因此除 U、I、T 外，选择 SOC 和 ADC 作为模型输入的特征。实验室测试仪精度足够高，为保证训练出高精度模型，本章采用库仑计数法计算 SOC 值。累积放电容量通过频率为 1Hz 的简单的电流积分得到，以 0.1Hz 的频率进行采样。这样既能保证输入特征间维度的一致，又能避免计算量的陡增与数据的冗余。最后，模型输入可由式(4-1)表示：

$$\left\{ \begin{array}{l} input_i = \begin{pmatrix} U_i & I_i & T_i & SOC_i & ADC_i \\ U_{i+1} & I_{i+1} & T_{i+1} & SOC_{i+1} & ADC_{i+1} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ U_{i+29} & I_{i+29} & T_{i+29} & SOC_{i+29} & ADC_{i+29} \end{pmatrix}_{30 \times 5} \\ output_i = (SOH_i)_{1 \times 1} \end{array} \right. \quad (4-1)$$

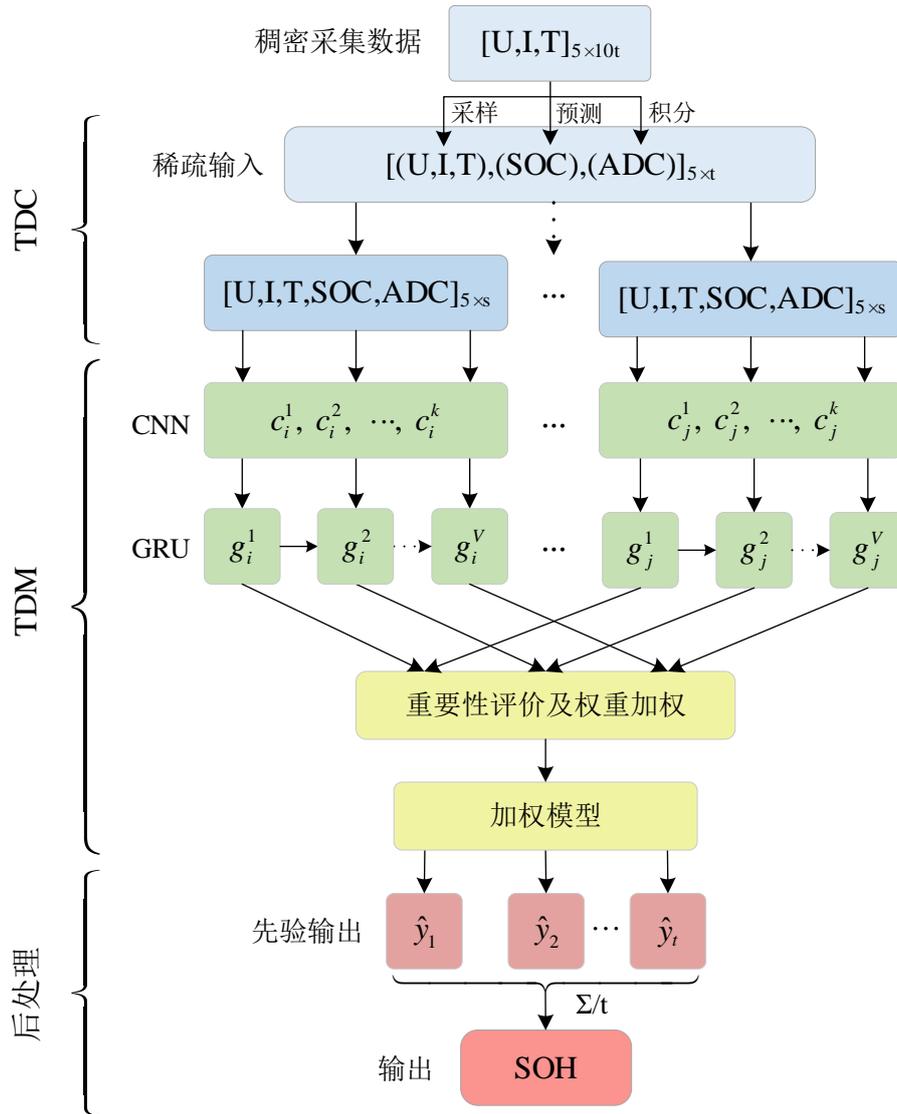


图4-1 Ada-CNN-GRU-Ave 模型结构

其中， i 与 $i+1$ 之间的时间间隔为 10s。

通常认为实验室记录的电流是准确可靠的，将放电结束时刻的电流积分值设置为参考容量。由式(4-2)可得模型的 SOH 参考值：

$$SOH_{ref} = \frac{C_{aged}}{C_{fresh}} \times 100\% \quad (4-2)$$

式中 SOH_{ref} —— SOH 参考值；

C_{fresh} —— 电池标称容量；

C_{aged} —— 当前老化容量；

SOH 估计模型的输入为一定窗口大小的多对一时间序列，为减小模型训练和预测负担，同时考虑到模型预测精度，时间窗口大小一般选取 30，60 等

较小值。一个完整的放电过程往往有成百上千个时间点的序列数据，因此在一个老化点可得到多个 SOH 估计值，模型先验输出长度可由式(4-3)计算得：

$$S_{pri} = S_t - S_{win} \quad (4-3)$$

式中 S_{pri} —— 先验输出值长度；

S_t —— 一个放电序列的输入数据长度；

S_{win} —— 窗口长度。

因为电池老化过程缓慢，SOH 的时刻更新会空耗算力，同时为了稳定先验输出，在每次放电结束时或一定行驶历程后更新一次 SOH 值，作为当前行驶状态的 SOH 最终输出。SOH 的最终输出结果由式(4-4)得：

$$SOH = (\sum_{i=1}^t \hat{y}_i) / t \quad (4-4)$$

4.1.2 SOH 估计效果验证与讨论

为实现全生命周期的 SOH 估计，同时为 4.3 节的 SOC 与 SOH 联合估计验证做模型准备，本小结将采用第二章收集到的磷酸铁锂电池全生命周期数据进行模型的训练与验证。

首先，将搜集到的数据转化成需要的维度，即通过积分、间隔采样等办法，获取 0.1Hz 的特征数据与标签值。然后将数据划分为训练集、验证集和测试集，采用与 3.2 节相同的数据集划分方式，即将 Cap、DST、UDDS、FUDS 等 4 个工况数据作为训练集、US06 作为验证集、BJDST 作为测试集，完成数据的前期准备。

4.1.2.1 特征有效性验证

为验证 SOC 与 ADC 作为新特征对 SOH 估计效果的影响，本小节将以 CNN-GRU 模型，对三种不同的输入特征进行模型训练与验证，分别为：三特征输入 $X_a = [U, I, T]_{120 \times 3}$ ，四特征输入 $X_b = [U, I, T, SOC]_{120 \times 4}$ ，五特征输入 $X_c = [U, I, T, SOC, ADC]_{120 \times 5}$ 。模型结构设置与第三章中 CNN-GRU 模型基本一致，第一层 CNN 层中的二维卷积核维度根据输入特征维度做相应调整。超参数 batch 设为 32，学习率 lr 设为 10^{-3} 。以不同特征训练完成的模型在 BJDST 工况下测试结果如图 4-2 所示，具体误差参数见表 4-1。另外，表中的平均值由 8 个老化点下的误差指标加权取平均得到。

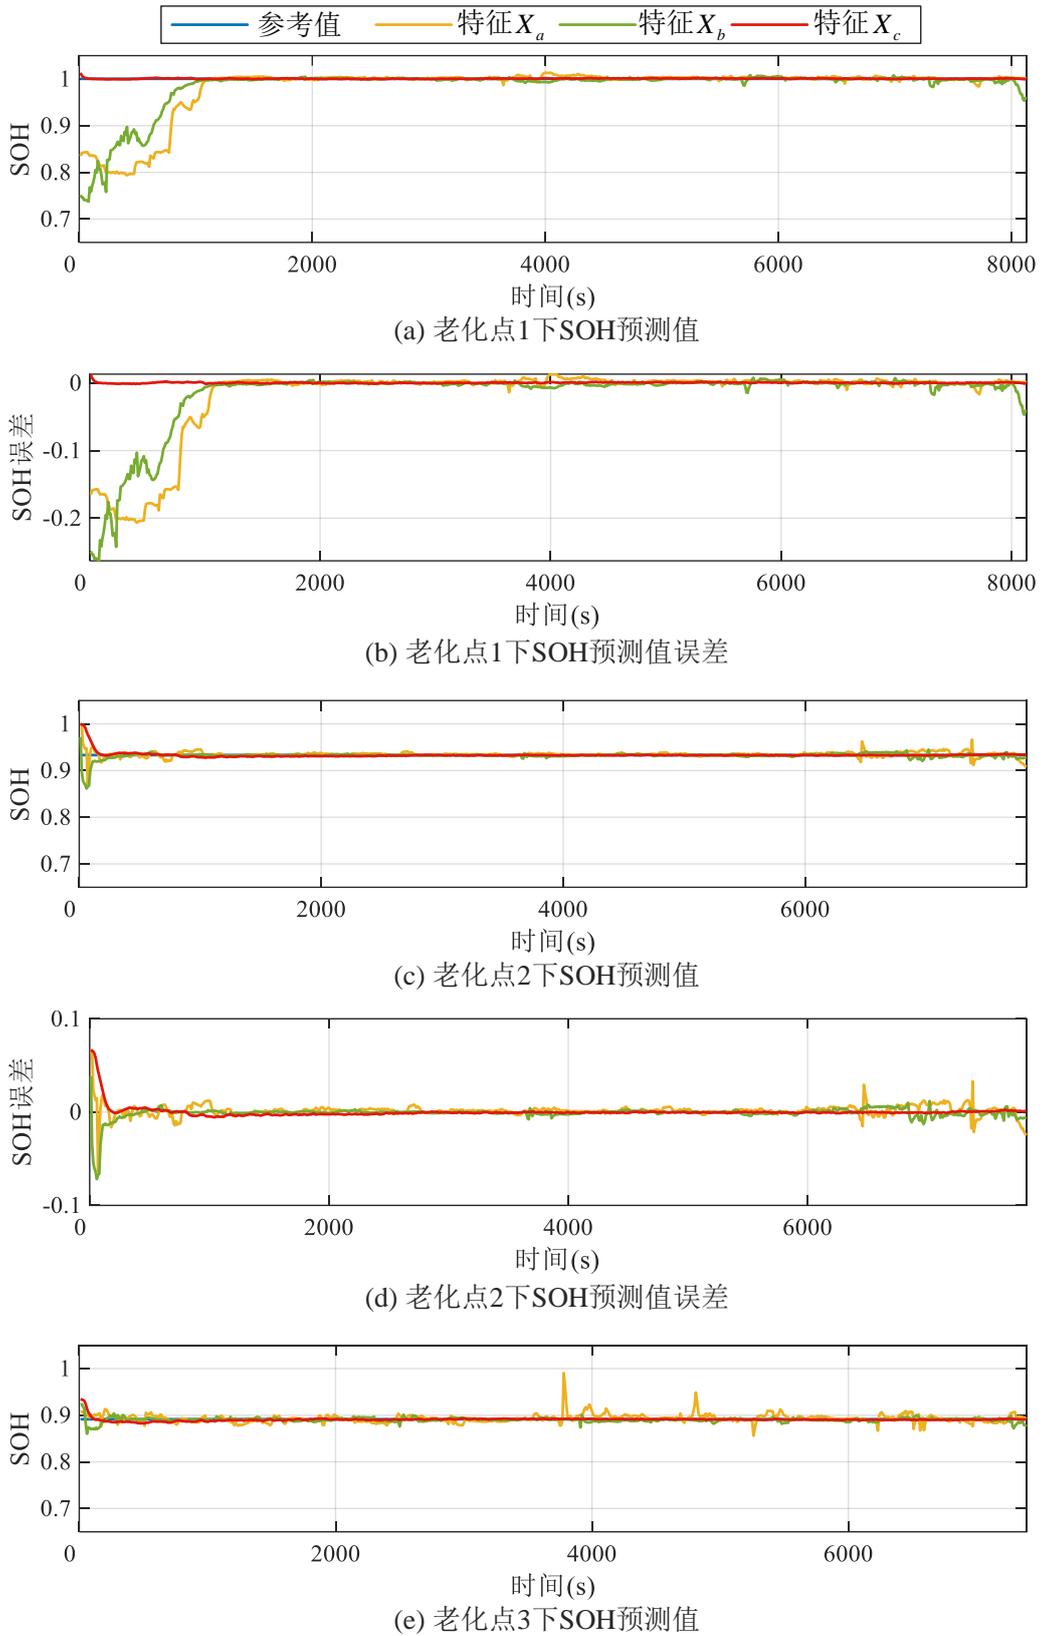
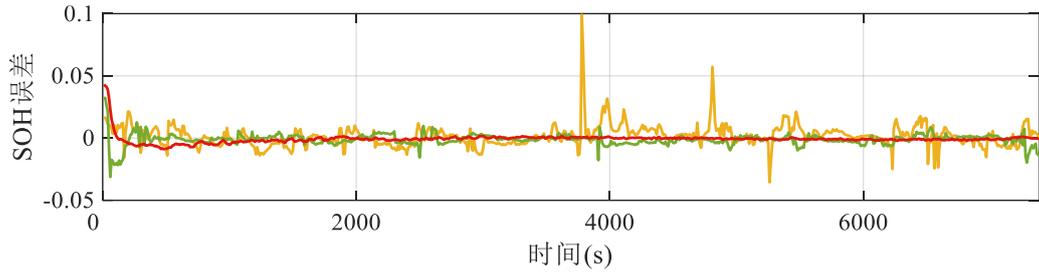
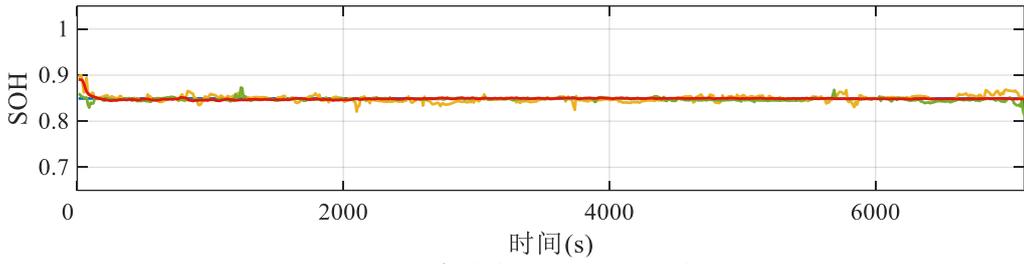


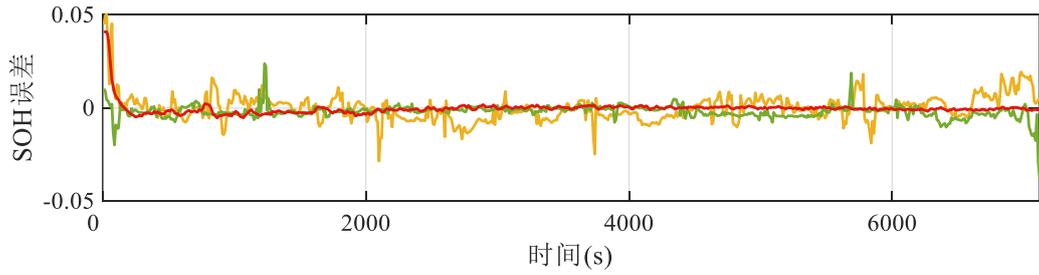
图 4-2 CNN-GRU 模型在 BJDST 工况下多老化点的 SOH 估计结果



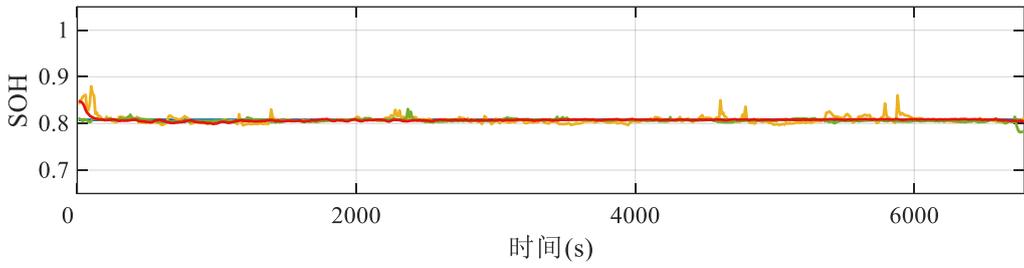
(f) 老化点3下SOH预测值误差



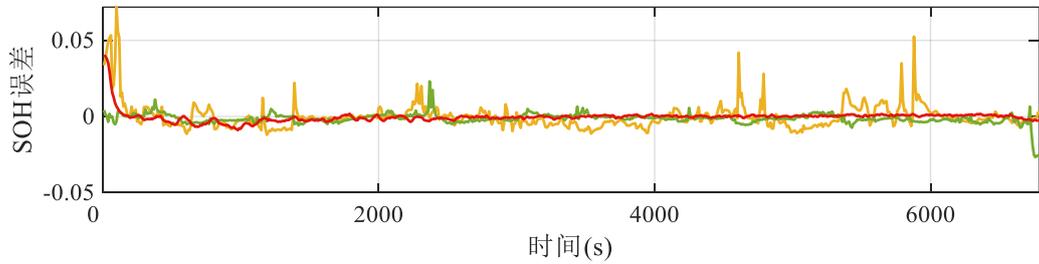
(g) 老化点4下SOH预测值



(h) 老化点4下SOH预测值误差



(i) 老化点5下SOH预测值



(j) 老化点5下SOH预测值误差

图 4-2 CNN-GRU 模型在 BJDST 工况下多老化点的 SOH 估计结果 (续)

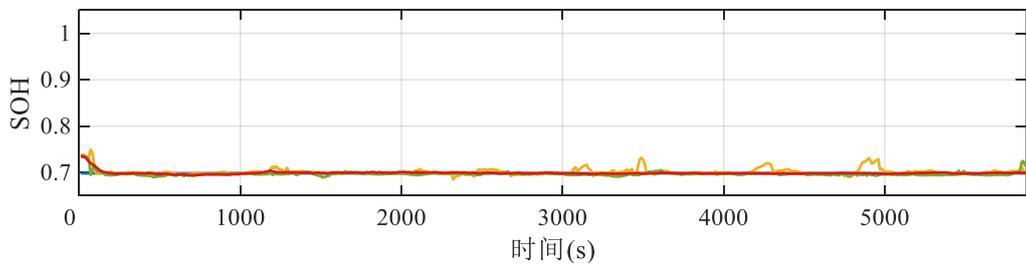
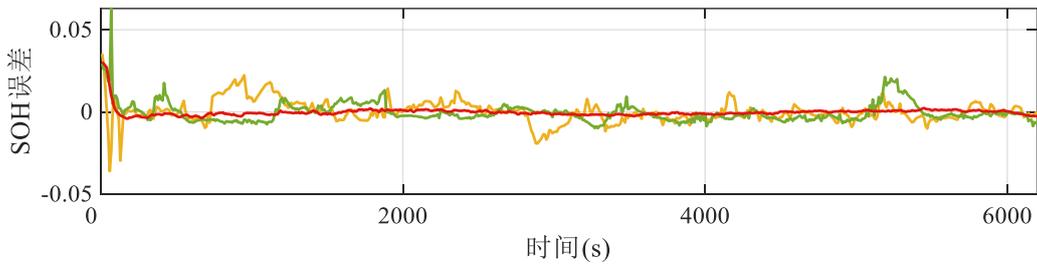
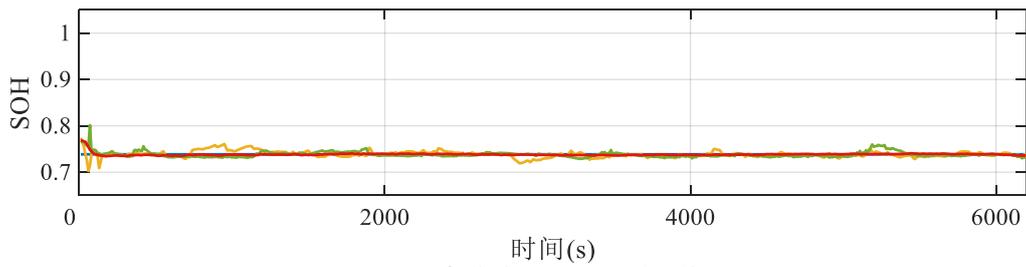
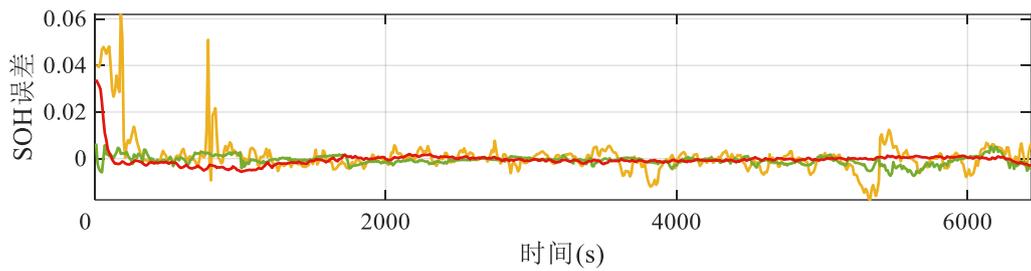
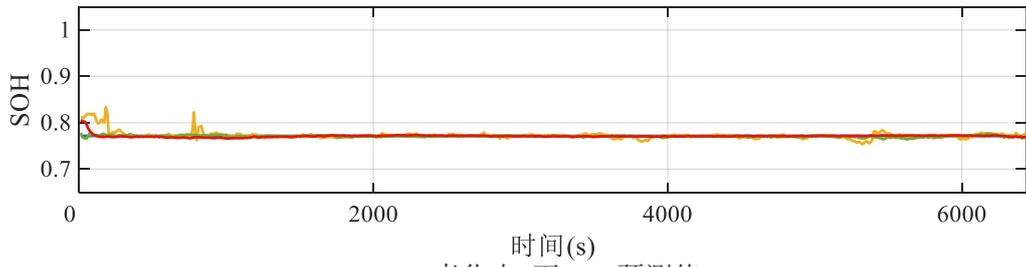
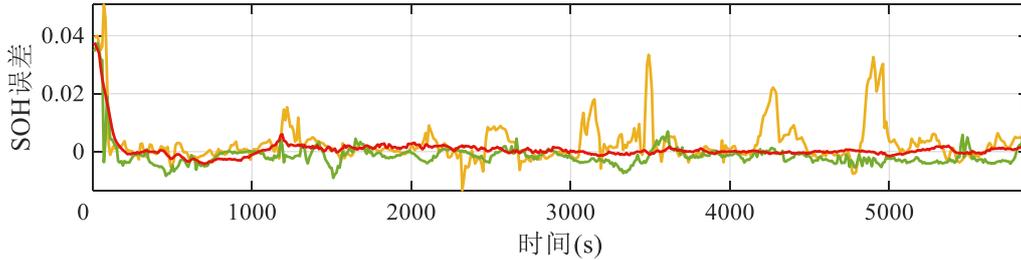


图 4-2 CNN-GRU 模型在 BJDST 工况下多老化点的 SOH 估计结果 (续)



(p) 老化点8下SOC预测值误差

图4-2 CNN-GRU 模型在 BJDST 工况下多老化点的 SOH 估计结果 (续)

表4-1 三种不同输入时 CNN-GRU 模型在 BJDST 工况的 SOH 估计结果评价

老化点	参考 SOH	X_a			X_b			X_c		
		MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
1	1.00	2.15	5.69	20.67	1.70	5.03	26.31	0.06	0.09	1.27
2	0.93	0.37	0.67	6.72	0.25	0.68	7.18	0.19	0.63	6.68
3	0.89	0.59	0.91	9.91	0.30	0.49	3.24	0.18	0.41	4.31
4	0.85	0.51	0.73	5.02	0.27	0.42	3.72	0.15	0.38	4.13
5	0.80	0.51	0.87	7.18	0.24	0.37	2.67	0.17	0.39	4.04
6	0.77	0.41	0.86	6.19	0.15	0.20	0.74	0.15	0.33	3.39
7	0.74	0.47	0.67	3.61	0.42	0.61	6.29	0.14	0.29	3.04
8	0.70	0.42	0.80	5.07	0.29	0.50	3.75	0.15	0.40	3.76
平均	-	0.67	1.40	8.04	0.45	1.03	6.73	0.14	0.37	3.83

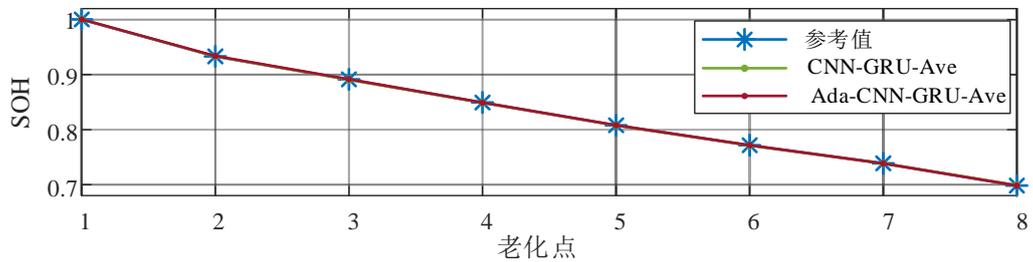
从图表中可以看出，对于不同输入特征，训练出来的模型估计效果是不同的。相对于仅以电压、电流、温度为特征输入，特征 SOC 的加入可以将 MAE 平均值从 0.67% 降低到 0.45%，RMSE 平均值从 1.4% 下降到 1.03%。特征累计放电量的添加，使得模型估计精度进一步大幅提高，MAE 平均值达 0.14%，RMSE 达 0.37%，另外，从图中可以看出，以电压、电流、温度、SOC、累计放电量为输入的模型，有着更快的收敛速度，8 个老化点下均在 15s 内将估计误差控制在 0.5% 以内。需要注意的是，尽管累计电量在放电结束时的值同容量值相同，但这并不意味着模型在估计 SOH 值时受到累计电量放电结束时的值的影响。因为明显可以看出，一个完整的放电区间里，SOH 值并不是在放电结束时才收敛到准确可信的范围内，而是在放电开始后很快趋于收敛。即在训练与测试的过程中，ADC 特征不会产生信息泄露，模型可以于在线放电过程完成可靠的 SOH 估计。

4.1.1.2.2 模型有效性验证

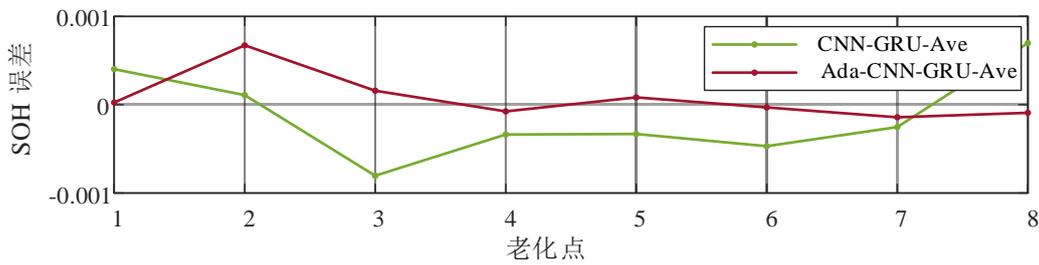
因为 SOH 值变化缓慢，通常在一个老化点上认为是恒定值。同时，为了使模型有着更加稳定的输出，后文将对每个老化点的估计值做平均处理。即在每次放电结束后，输出一个 SOH 平均值，放电过程中的 SOH 值取上一个

放电循环估计出的 SOH 值。注意，本文为加速电池老化，快速获得实验数据，电池全生命周期内仅取 8 个老化点，每个老化点对应的 SOH 值差距较大。而真实情况下每个老化点对应的 SOH 值为更加连续，取上次放电循环结束后的平均 SOH 值作为下次放电过程中的 SOH 值具备可行性。

为了验证 Ada-CNN-GRU 模型相对于传统 CNN-GRU 模型的优越性，同时避免输出 SOH 值的波动与冗余，本小节分别建立 Ada-CNN-GRU-Ave 模型与 CNN-GRU-Ave 模型。建模过程已在 4.1.1 节叙述，输入特征取 $X_c = [U, I, T, SOC, ADC]_{120 \times 5}$ ，模型结构除必要维度变化外，与前文基本一致。模型在 BJDST 工况下的 SOH 估计结果如图 4-3 所示，误差指标见表 4-2。



(a) 多老化点下SOH预测值



(b) 多老化点下SOH预测值误差

图4-3 BJDST 工况下多老化点 SOH 估计结果

表4-2 BJDST 工况下多老化点 SOH 估计误差评价指标

模型	MAE (%)	RMSE (%)	MAX (%)
CNN-GRU-Ave	0.04	0.05	0.08
Ada-CNN-GRU-Ave	0.02	0.03	0.07

通过表格可以看出，Ada-CNN-GRU-Ave 在所有三个指标上的表现都优于 CNN-GRU-Ave。具体而言，Ada-CNN-GRU-Ave 模型的 MAE 和 RMSE 分别为 0.02%和 0.03%，低于 CNN-GRU-Ave 模型的 0.04%和 0.05%；同时，Ada-CNN-GRU-Ave 的最大误差较 CNN-GRU-Ave 模型也得到了降低。同时，Ada-CNN-GRU-Ave 模型的优越性得到验证，高精度的 SOH 估计模型为 SOC 和 SOH 的联合估计打下基础。

4.2 SOC 与 SOH 的联合估计

至此，已完成全生命周期动态工况下电池 SOC 估计模型与 SOH 模型的搭建。虽然 SOC 模型的输入特征中包含 SOH，SOH 模型的输入特征中包含 SOC，但是在上述章节中两个模型测试中，所输入的特征均为理想情况的特征，即 SOC 估计模型中输入的 SOH 为理想值，SOH 估计模型中输入的 SOC 也为理想值，还未完成完整的联合估计测试。在一个完整的全生命周期放电过程中，两个模型的输出的 SOC 值与 SOH 值需要互为输入，实现更加贴近现实情况的 SOC 与 SOH 的联合估计。联合估计的过程如图 4-4 所示。

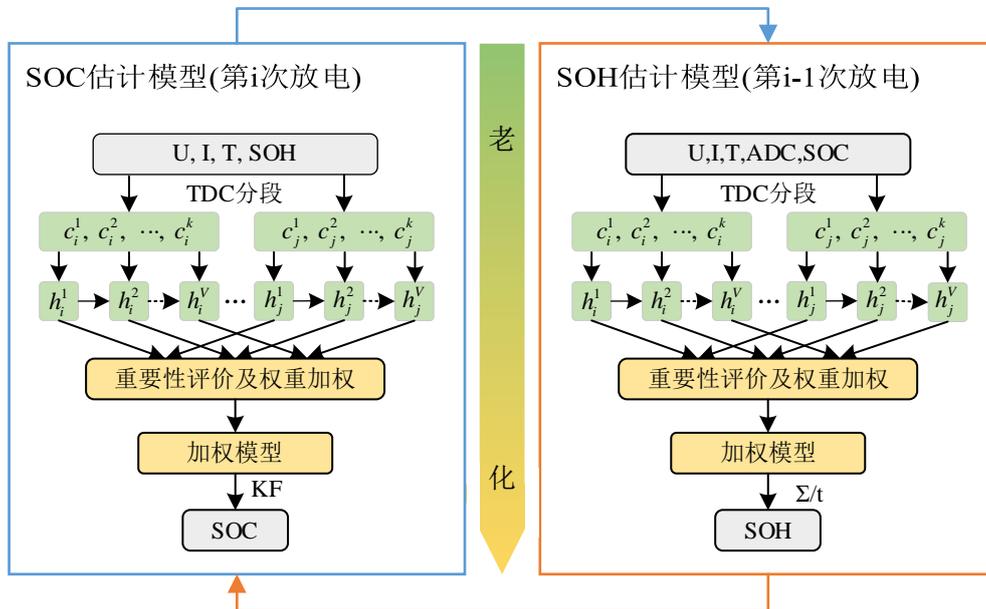


图4-4 联合估计模型（过程简化）

其中，SOH 估计器为 3.4 节训练得到的 Ada-CNN-GRU-KF 模型，SOC 估计器为 4.1.2.2 训练得到的 Ada-CNN-GRU-Ave 模型。

4.3 联合估计效果验证与讨论

鉴于电池实验中每两个老化点之间存在 30 个充放电循环，导致相邻两个 SOH 之间数值过于离散，上一个循环结束估计的 SOH 值无法用作当前循环的 SOH 值。为继续验证 SOC 与 SOH 联合估计模型的有效性，本小结将依据 Ada-CNN-GRU-Ave 模型的结果，为 SOH 设置偏差为 5% 的不准确初值，得到前 600s 的存在更大误差的 SOC 估计值，同时模拟了在联合估计中 SOC 与 SOH 的误差累积。SOC 估计值用于获取当前循环中 SOH 的收敛值。注意，

对于 SOH 估计而言，600s 的数据对应 60 个采样点。

其中，设定不准确初值偏差为 5%，是因为实验电池全生命周期共经历 210 次充放电循环，而根据 Ada-CNN-GRU-Ave 模型在理想情况下 0.02% 的 MAE 误差，模型最终的累计误差偏差极限为 $210 \times 0.02\% = 4.2\%$ 。同时为进一步加强测试难度，验证不准确 SOH 初值估计出的 SOC 应用于 SOH 估计中的收敛能力，取 SOH 初值偏差为 5%，具体设置如表 4-3 所示。

表4-3 SOH 初值设置

SOH 初值设置	老化点							
	1	2	3	4	5	6	7	8
参考值	1.00	0.93	0.89	0.85	0.80	0.77	0.74	0.70
偏差初值	0.95	0.88	0.84	0.81	0.75	0.72	0.69	0.65

利用不准确初值以及 SOH 参考值，估计出各老化点前 600s 的 SOC 变化如图 4-5 所示。

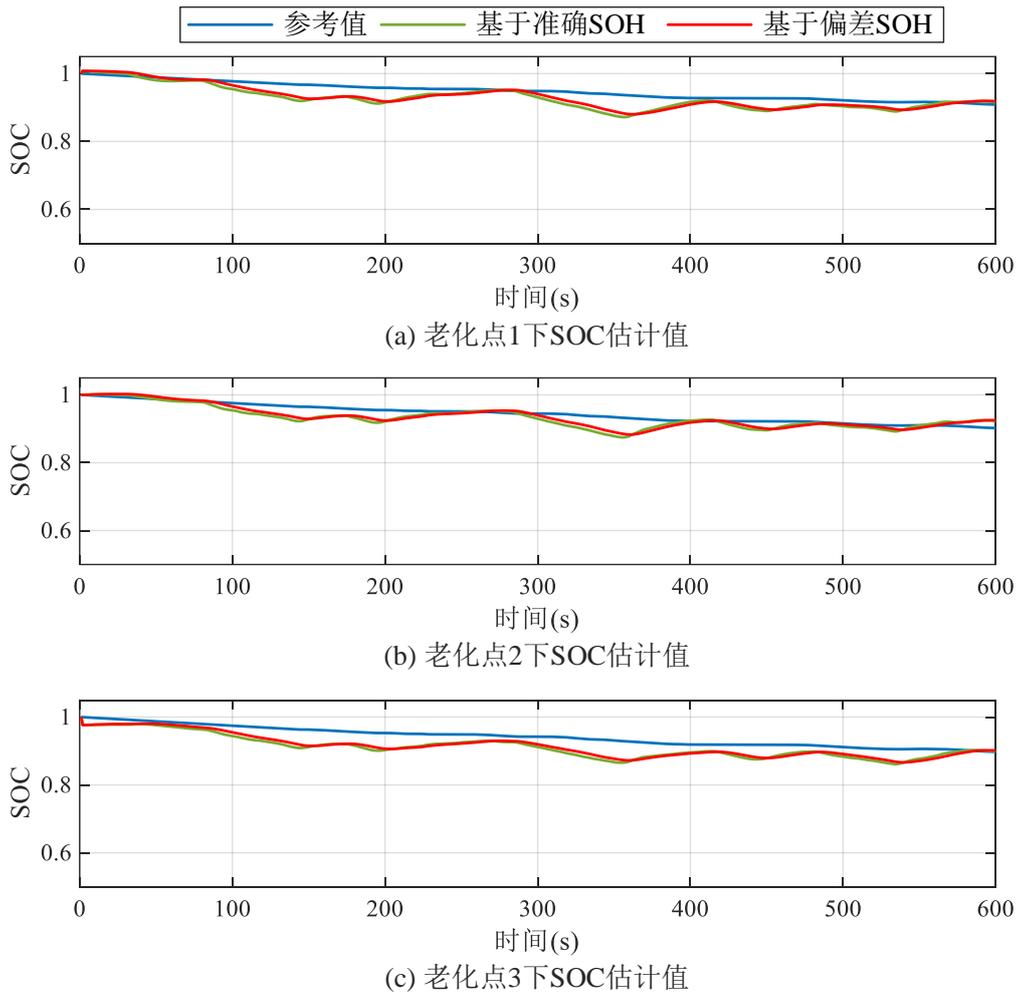


图 4-5 基于偏差 SOH 所得前 600 秒内的 SOC 估计值

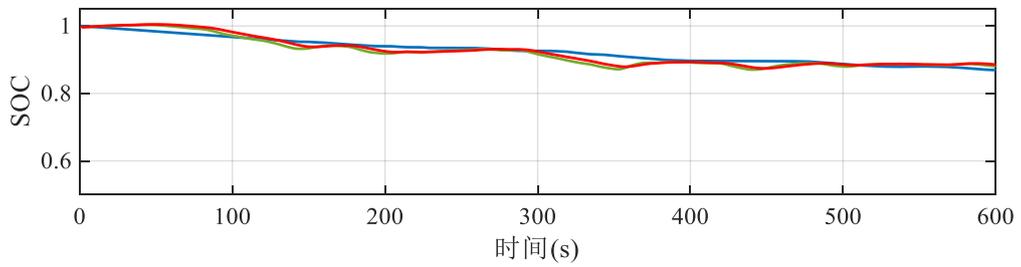
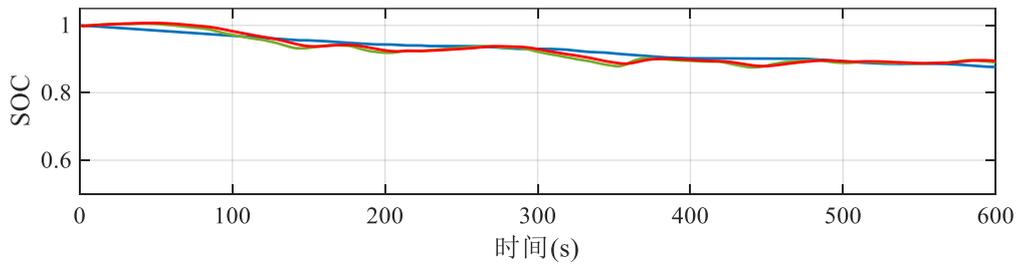
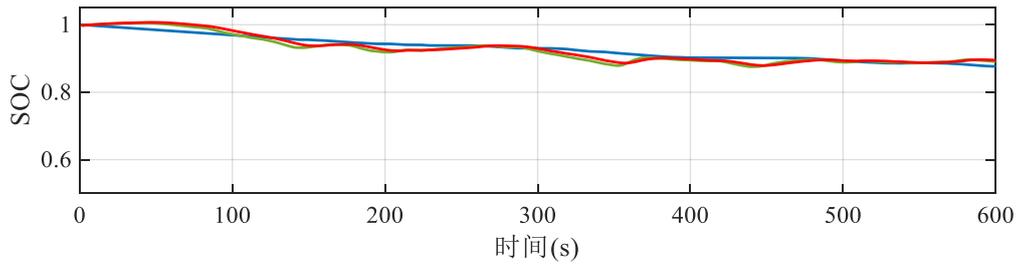
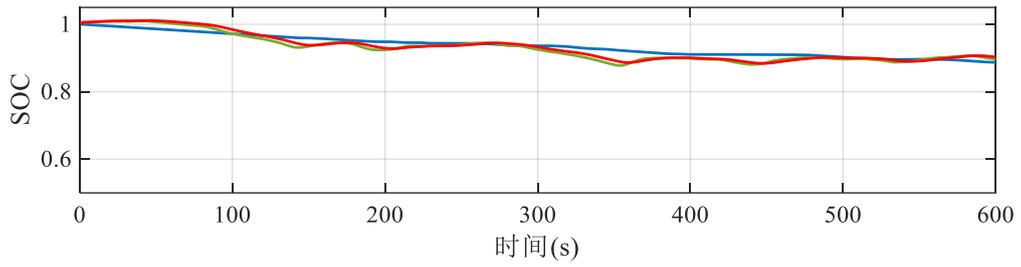
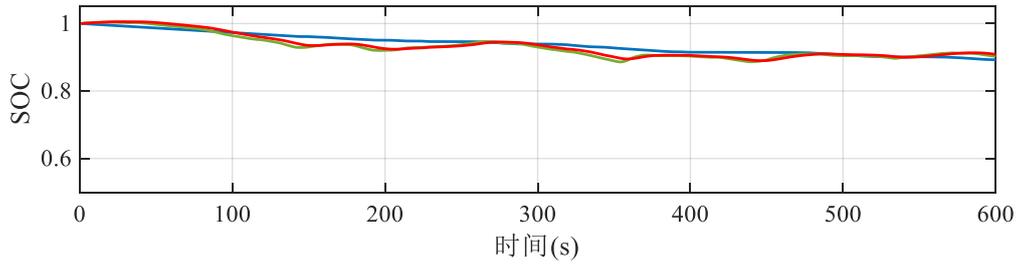
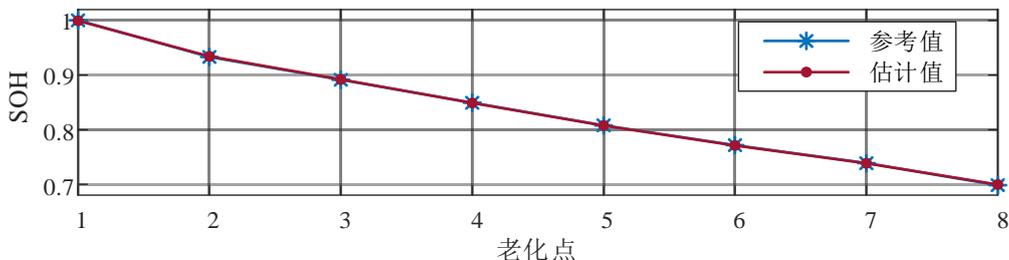


图4-5 基于偏差 SOH 所得前 600 秒内的 SOC 估计值（续）

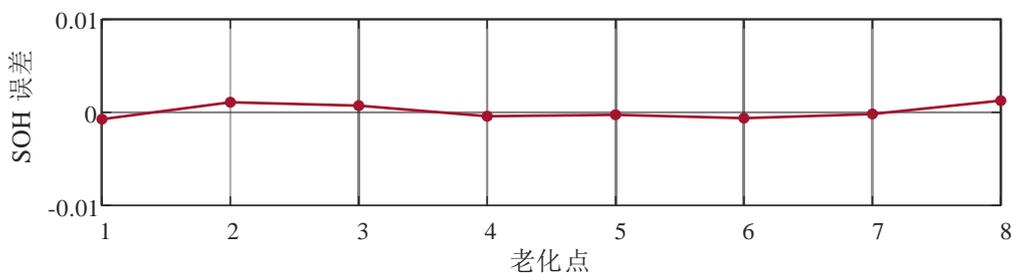
经对比，利用不准确 SOH 初值估计出的前 600s 的 SOC，能够基本反映

SOC 的变化趋势，理论上能够作为 SOH 估计模型的输入特征之一，估计出较为准确的 SOH 值。

将不准确初值估计出的 SOC，应用于 SOH 的估计中，得到 SOH 估计效果如图 4-6 所示。



(a) 多老化点下SOH估计值



(b) 多老化点下SOH估计值误差

图4-6 基于偏差数据所得 BJDST 工况下 SOH 估计结果

可以看到模型的 SOH 估计值在极端情况下仍然会收敛到较为准确的范围内。利用不准确 SOC 值估计出的全生命周期 SOH 的 MAE 为 0.07%，RMSE 为 0.07%，MAX 为 0.13%。

以该 SOH 值作为特征，用训练好的 Ada-CNN-GRU-KF 模型做 SOC 估计，得到 SOC 估计结果如图 4-7 所示，误差评价指标见表 4-4。

在 BJDST 工况下多老化点的 SOC 估计测试结果中，通过图表可以看出，相比于 3.4 节以理想 SOH 值作为特征输入，模拟 SOH 与 SOC 均存在误差的联合估计模型的误差指标 MAE、RMSE、MAX 平均值分别仅上升 0.01%，0.03%与 0.46%，取得了令人满意的效果。证明了模型在锂电池全生命周期中 SOC、SOH 估计中的可行性。

另外，每条数据的生成时间约为 0.06 毫秒，能够实现电池状态的实时预测。训练完成的 FB-Ada-CNN-GRU-KF 模型占用存储空间约为 40Mb，Ada-CNN-GRU-KF 和 Ada-CNN-GRU-Ave 模型占用存储空间均约为 13Mb，联合估计模型占用空间约为 26Mb。而车载芯片的存储空间多在 8Mb 以下，要实现模型在车端的应用，需要对模型的体量进一步轻量化，或借助于车云协同

技术实现车端数据的云端计算。

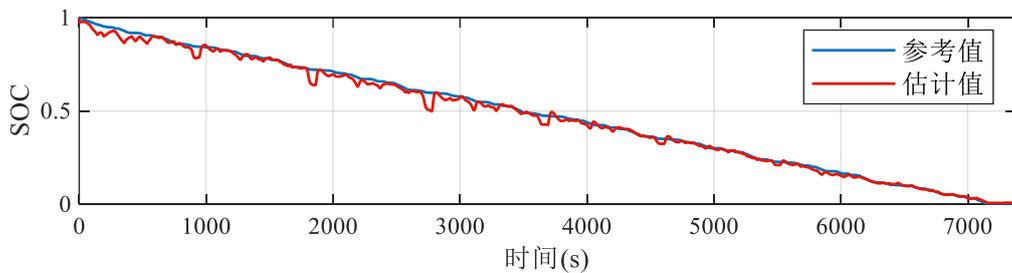
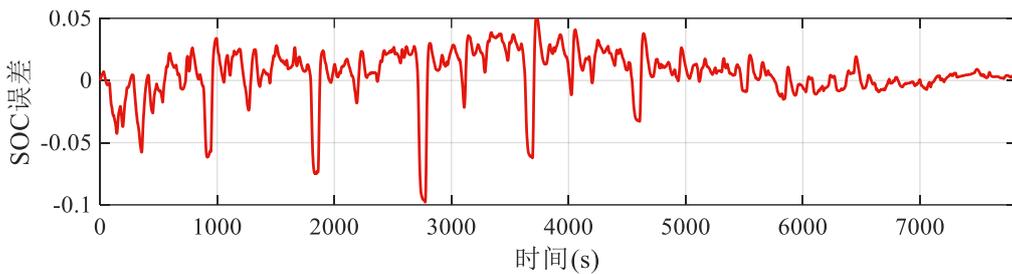
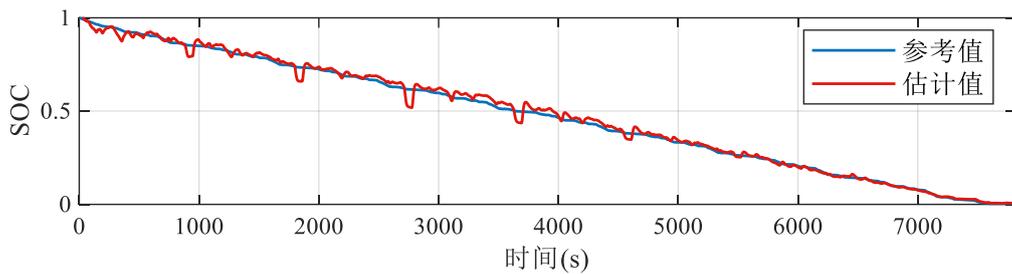
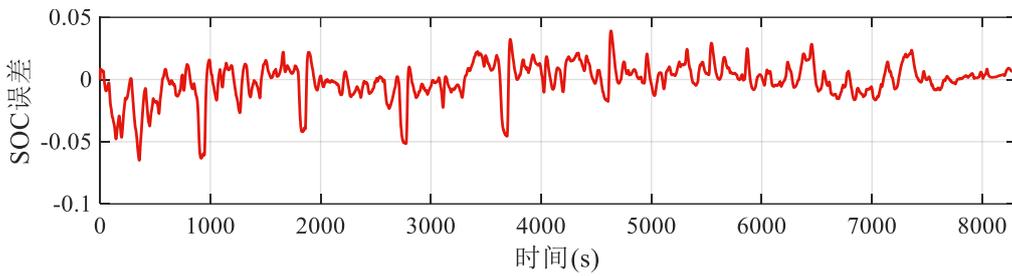
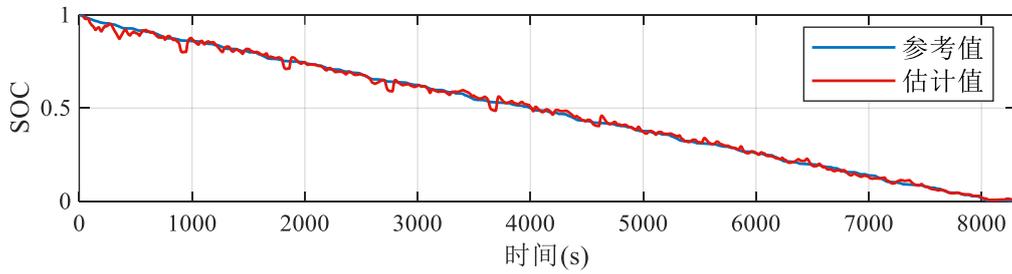
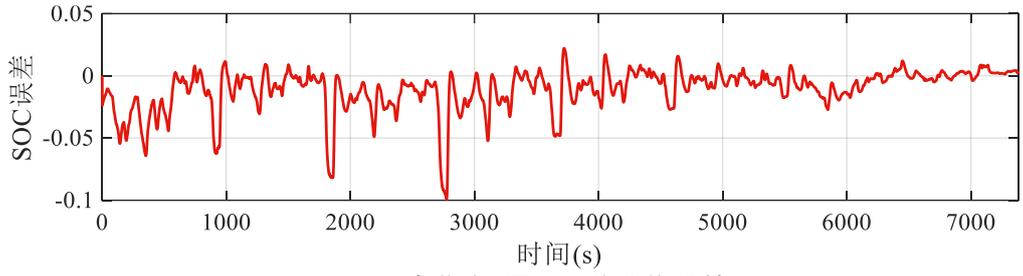
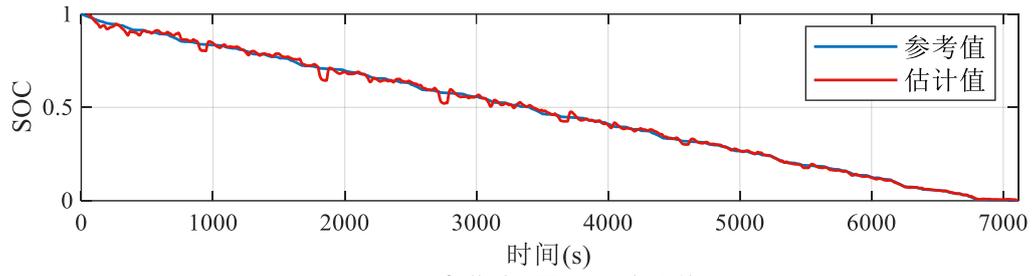


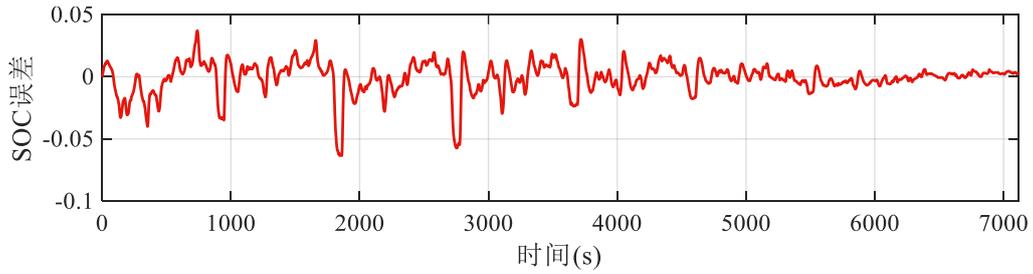
图 4-7 模拟联合估计中 SOC 估计结果 (续)



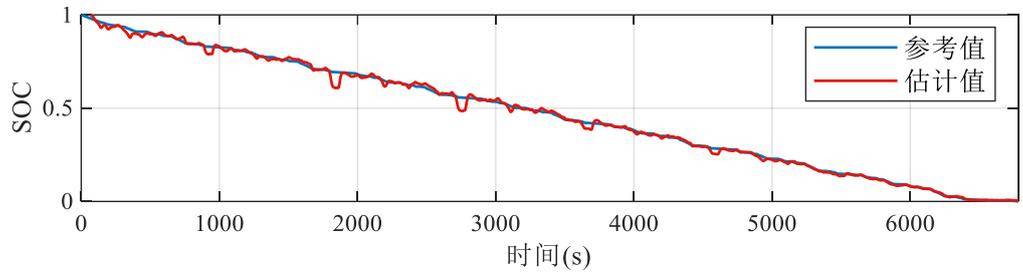
(f) 老化点3下SOC估计值误差



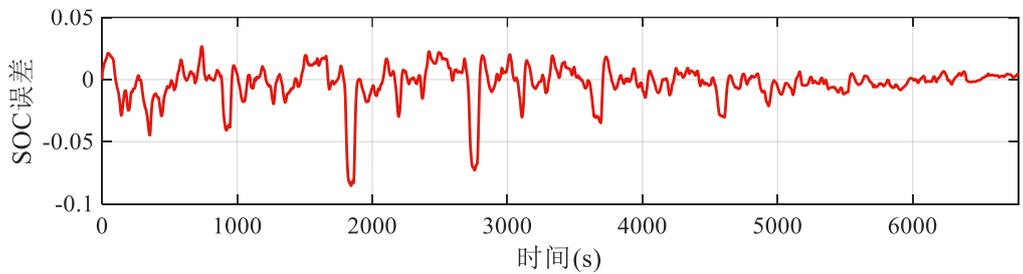
(g) 老化点4下SOC估计值



(h) 老化点4下SOC估计值误差

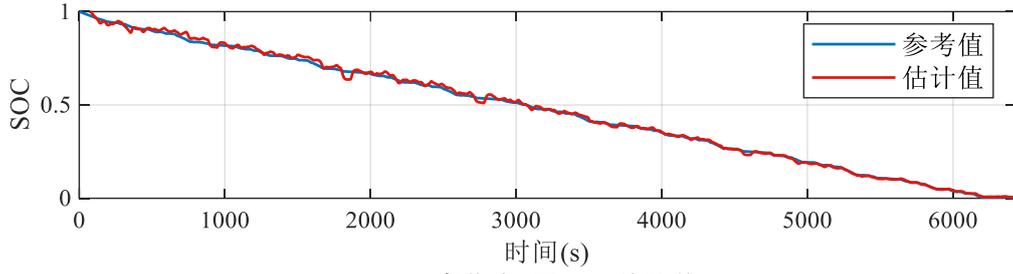


(i) 老化点5下SOC估计值

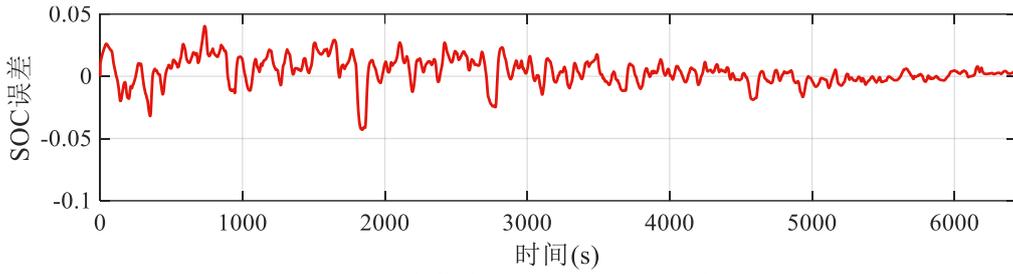


(j) 老化点5下SOC估计值误差

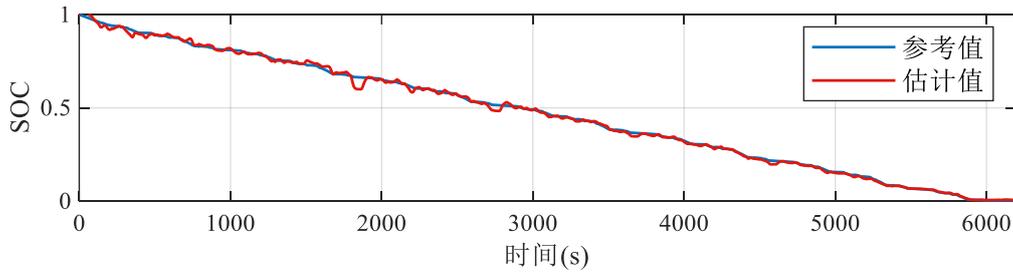
图 4-7 模拟联合估计中 SOC 估计结果 (续)



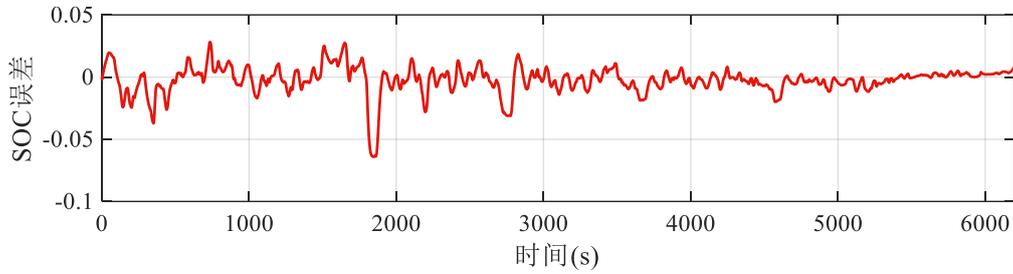
(k) 老化点6下SOC估计值



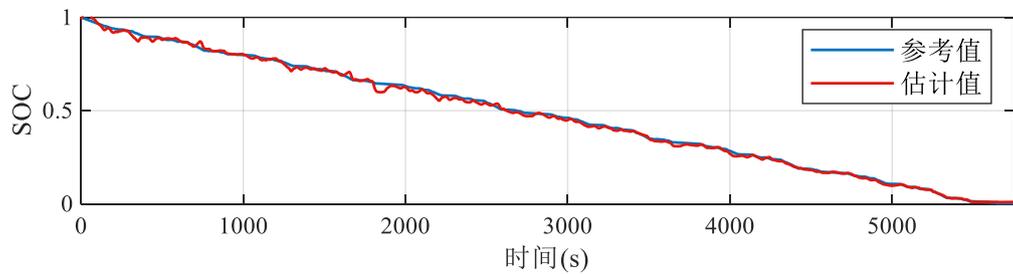
(l) 老化点6下SOC估计值误差



(m) 老化点7下SOC估计值

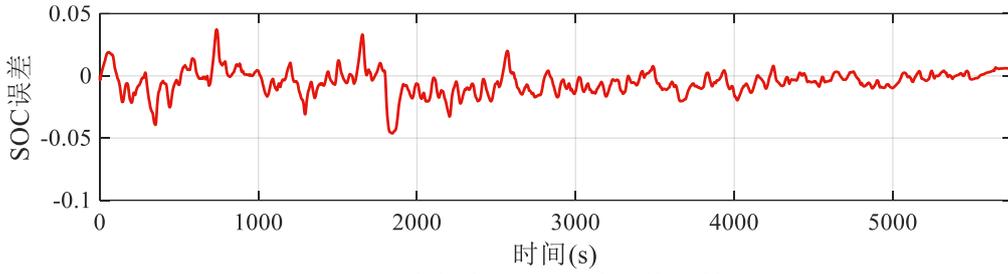


(n) 老化点7下SOC估计值误差



(o) 老化点8下SOC估计值

图 4-7 模拟联合估计中 SOC 估计结果 (续)



(p) 老化点8下SOC估计值误差

图4-7 模拟联合估计中 SOC 估计结果（续）

表4-4 理想工况中与模拟联合估计中 SOC 估计结果对比

老化点	参考 SOH	基于理想 SOH 值			基于偏差 SOH 值(模拟联合估计)		
		MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
1	1.00	1.00	1.40	6.36	1.02	1.45	6.50
2	0.93	1.52	2.05	9.19	1.46	2.03	9.78
3	0.89	1.19	1.85	9.36	1.28	1.98	9.91
4	0.85	0.86	1.23	5.71	0.85	1.25	6.34
5	0.80	0.90	1.40	7.72	0.88	1.45	8.54
6	0.77	0.96	1.28	4.38	0.85	1.13	4.28
7	0.74	0.72	1.08	5.80	0.71	1.10	6.41
8	0.70	0.71	0.99	4.11	0.83	1.12	4.62
平均	-	0.98	1.41	6.58	0.99	1.44	7.04

4.4 本章小结

本章提出并建立了双时间尺度输入的 Ada-CNN-GRU-Ave 模型，用于估算动态驾驶工况下锂离子电池的 SOH。模型以电压、电流、温度、SOC 和 ADC 为特征输入，实验表明特征 SOC 及 ADC 可以提高 SOH 估计精度与模型收敛速度。Ada-CNN-GRU-Ave 模型相对于 CNN-GRU-Ave 模型的优越性亦得到验证。在 SOC 估计模型与 SOH 估计模型的基础上，搭建 SOC 和 SOH 的联合估计模型。为验证联合估计精度，设置 SOH 偏差初值模拟联合估计中极限条件下的状态累计误差。在联合估计中，SOH 估计值的 MAE 与 RMSE 均为 0.07%，SOC 估计结果的 MAE 为 0.99%，RMSE 为 1.44%，联合估计模型的泛化性和准确性得到了很好的验证。

第 5 章 车云协同状态估计研究

面对 BMS 内存空间有限和估计模型在车端应用时不能及时更新的问题，车云协同技术提供了解决方案。然而，车端数据上传云端过程中存在的延迟和数据缺失问题给电池状态的车云协同估计带来巨大挑战。本章提出在云端对稀疏特征数据进行还原并估算电池状态的解决方案。首先，本章将对掩码自编码器理论进行简要介绍；接着，建立带外推器的掩码自编码模型用于电池稀疏特征的还原；最后，将对稀疏特征数据的还原效果及在状态估计任务中稀疏还原数据的表现效果进行验证。

5.1 理论基础

掩码自动编码器（Masked Autoencoders, MAE）是由 Kaiming He 于 2021 年提出的用于计算机视觉领域的自编码模型，其结构如图 5-1 所示。因为 MAE 的目的在于重建输入，所以不需要为数据打标签，从而具有自监督学习的特点及优点。其基本思想是：随机遮挡输入图像的一些区域，从而为模型提供一个不完整的图像；然后用一个编码器-解码器结构来重建缺失的像素。编码器只处理可见的图像区域（即未被遮掩的像素块），解码器则根据编码器输出的潜在表示和遮掩令牌来重建原始图像。这样可以减少计算量和内存消耗，提高训练效率。

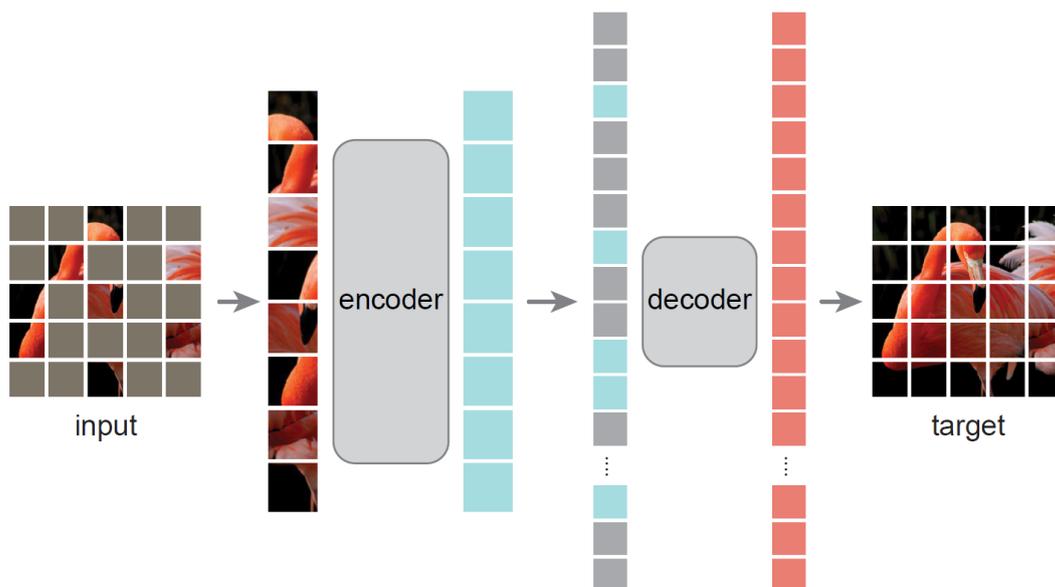


图5-1 MAE 结构

MAE 首先对输入图像进行掩码操作，即随机删除（遮挡）一部分像素补

了。作者发现，较高的遮挡比例可以使自监督学习任务更有难度和意义，在文中给出的例子中，模型的遮挡比例达到 75% 左右；因为需要处理的图像补丁更少，所以模型的训练速度也加快了 3 倍；另外，由于遮挡的方式为随机的，所以同一个图像可以有多种遮挡方式以供输入训练，相当于对数据进行了增强处理，进而提高了模型的泛化性。

对输入图像掩码操作后，编码器将图像按照位置信息将未被遮挡的补丁排列好，只对图像的非掩码部分进行编码处理。编码器的输出是输入图像补丁的潜在向量表征，即图中编码器后边的蓝色方块。

为了下一步的解码重建初始图像，在编码器后边加入掩码令牌，即图中灰色方块。每个掩码令牌都是一个共享的、可学习的向量，表示待预测的缺失的补丁。为了使解码器有更多可以利用的信息以构建出准确的图像，位置嵌入 (Positional Embeddings)，即每一个掩码令牌或潜在表征的位置信息，会被添加到解码器的输入信息中。

解码器接收潜在表征以及掩码令牌作为输入，并输出每个补丁的像素值。通过对相应位置的像素进行拼接，可以得到利用部分像素块还原出来的目标图像。目标图像重建完成后，测量其与原始输入图像的差值，并将其作为损失，利用反馈算法不断修正模型参数，从而实现更好的目标图像重构。

另外，MAE 本身被设计为一个预训练模型，即在模型训练完成后，解码器被丢弃，只保留编码器，用作视觉转换器。细分领域中可以直接使用编码器的权重信息，只对解码器做微调便能适应新任务的要求。而编码器和解码器的结构可以是非对称的，即可以根据任务复杂度，适当选择合适的编码器和解码器的模型复杂度。

MAE 可以用最少的领域知识来学习强大的特征，它在计算机视觉领域取得的巨大成功，展示了自编码类方法 (BERT、MAE 等) 在更多领域的应用潜力，推动了掩码自编码类框架的发展。但是 MAE 模型目前尚不能直接用于时间序列预测

5.2 基于 ExtraMAE 的电池稀疏数据还原

带外推器的掩码自编码器^[53] (Masked Autoencoder with Extrapolator, ExtraMAE) 是一种简单有效、可扩展的时间序列生成自监督模型，由 Mengyue Zha 于 2022 年提出。通过对输入时间序列的随机掩码，ExtraMAE 模型将从未被掩码的输入序列中推断出缺失的数据，从而实现对时间序列有效的数据还原。目前，车联网数据传输带宽不足的问题普遍存在。为此，通

常采用的方法是降低数据传输频率，但这会进一步导致数据信息丢失。本节建立 ExtraMAE 模型，用以还原动力电池稀疏特征数据，解决云端模型训练所用数据的非随机缺失问题。

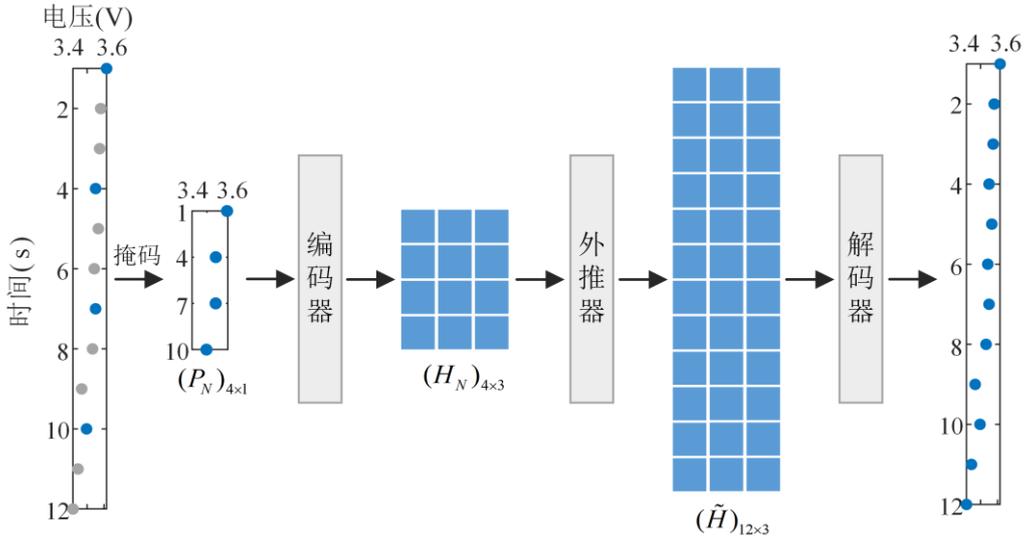


图5-2 ExtraMAE 结构（以电压还原为例）

如图 5-2 所示为以还原放电过程中的电压稀疏数据为例的 ExtraMAE 模型，模型由编码器、外推器和解码器组成。首先，部分时间序列将被遮掩，模拟缺失数据，这一过程称为掩码。要被掩码的时间序列由图中灰点表示。编码器将对未被掩码的时间序列进行编码操作，映射到更高维度的潜在表征。外推器将未被掩码时间序列的潜在表征外推为所有时间序列的潜在表征。最后，解码器将完整的潜在表征映射回特征空间，完成数据的还原。模型的结构及输入数据的具体介绍如下：

对于特定的时间序列还原任务，模型的输入为包含 d 个特征的多元时间序列 $X = [x_1, x_2, \dots, x_d] \in \mathbb{R}^{d \times L}$ ，每个特征的长度为 L 。为减小掩码解码等操作的计算量，多元时间序列将被切片为 T 个规则不重叠补丁，以补丁代替的时间点作为输入的最小单位。第 j 个补丁 $P_j \in \mathbb{R}^{d \times l}$ 由 $l = L/T$ 个连续观测值 $P_j = [x_{(j-1)l+1}, x_{(j-1)l+2}, \dots, x_{jl+1}]$ 组成，其中 $j = 1, 2, \dots, T$ 。在图所示电池稀疏数据还原任务中，输入序列 $X = U_i \in \mathbb{R}^{1 \times 12}$ 。另外，由于云端平台接受到的稀疏数据为每秒 1 个，为了保证后续工作中被掩码补丁与未被掩码补丁维度的一致，取补丁大小为 1。

然后，对 m 个补丁的一个子集进行采样，去除掉被掩码补丁的信息，并保留其余补丁。被遮挡的补丁的索引集 $M = \{j_1, j_2, \dots, j_m\} \subset \{1, 2, \dots, T\}$ ，未被掩码补丁的索引集为 $N = \{1, 2, \dots, T\} \setminus M = \{k_1, k_2, \dots, k_n\}$ ，其中 $M + N = T$ 。简单起

见，将不可见的被掩码补丁 $[P_{j_1}, P_{j_2}, \dots, P_{j_m}]$ 表示为 P_M ，将可见的未被掩码的补丁 $[P_{k_1}, P_{k_2}, \dots, P_{k_n}]$ 表示为 P_N 。被掩码的补丁 $P_j \in \mathbb{R}^{d \times l}$ 中的所有元素将被整体去除，其中 $j \in M = \{j_1, j_2, \dots, j_m\}$ 。在图中，随机掩码 $m=8$ 个补丁，将剩下的 $n=4$ 个补丁拼接得到 P_N ，被掩码补丁的索引集 $M = \{2, 3, 5, 6, 8, 9, 11, 12\}$ ，未被掩码补丁的索引集 $N = \{1, 4, 7, 10\}$ 。

编码器将未被掩码的补丁 $P_N \in \mathbb{R}^{d \times (n \cdot l)}$ 映射到其潜在表征 $H_N \in \mathbb{R}^{h \times (n \cdot l)}$ ，其中 h 是隐空间的维度。在图 5-2 中，编码器将 $P_N = [P_1, P_4, P_7, P_{10}]$ 映射到潜在表征空间，由 4×3 蓝色方块表示。如式(5-1)和式(5-2)所示，用函数 E 表示编码器将未被遮盖补丁 P_N 到其潜在表征 H_N 的过程：

$$H_N = E(P_N) \quad (5-1)$$

$$E: \prod_{k=1}^{n \cdot l} (\mathbb{R}^d)_k \rightarrow \prod_{k=1}^{n \cdot l} (\mathbb{R}^h)_k \quad (5-2)$$

外推器用来恢复掩码位置的潜在表征。如式(5-3)和式(5-4)所示，用函数 I 表示将外推器从可见相邻表征外推缺失潜在表征的过程。在图 15 中，外推器从未被遮盖补丁的潜在表征 H_N 推断出所有补丁的潜在表征 \tilde{H} 。

$$\tilde{H} = I(H_N) \quad (5-3)$$

$$I: \prod_{k=1}^{n \cdot l} (\mathbb{R}^h)_k \rightarrow \prod_{k=1}^{T \cdot l} (\mathbb{R}^h)_k \quad (5-4)$$

解码器从外推的完整潜在表征中重建原始信号。如式(5-5)和式(5-6)所示，解码器将潜在表征 $\tilde{H} \in \mathbb{R}^{h \times (T \cdot l)}$ 映射为生成时间序列 $\hat{X} \in \mathbb{R}^{h \times (T \cdot l)}$ 的过程可由函数 D 表示。在图 15 中，解码器根据所有补丁的潜在表征 \tilde{H} 生成稠密电压序列。

$$\hat{X} = D(\tilde{H}) \quad (5-5)$$

$$\prod_{k=1}^{T \cdot l} (\mathbb{R}^h)_k \rightarrow \prod_{k=1}^{T \cdot l} (\mathbb{R}^d)_k \quad (5-6)$$

编码器、外推器与解码器是由 RNN 层与全连接层构成的神经网络结构，具体结构参数如表 5-1 所示。仍以图 5-2 中电压数据还原为例，特征数为 1，时间序列长度为 12，被掩码的补丁数为 8，未被掩码的补丁数为 4。其中，GRU 各参数分别为输入特征数、隐藏层节点数、层数，FC 层各参数分别为输入特征数和输出特征数。

表5-1 ExtraMAE 结构参数示例

模块	第一层	第二层
编码器	GRU(1, 5, 3)	FC(5, 5)
外推器	FC(4, 12)	FC(5, 5)
解码器	GRU(5, 5, 3)	FC(5, 1)

训练过程中，首先对原始时间序列 X 中的一些补丁进行规则掩码，然后

ExtraMAE 利用未被掩码的补丁 P_N 生成重建的时间序列 \hat{x} ，并计算重建时间序列 \hat{x} 在 $\mathbb{R}^{d \times L}$ 中与原始时间序列 x 之间的均方误差 MSE。模型重建序列的损失函数见公式(5-7)：

$$L_{recon} = \frac{1}{L} (X - \hat{X})^2 \quad (5-7)$$

与传统 MAE 只计算掩码补丁的损失不同，ExtraMAE 计算所有补丁的损失。整体重构损失 L_{recon} 保证了重构后的时间序列 \hat{x} 保持了原始时间序列 x 的连续性。但是因为未被掩码数据在编码、外推、解码的过程中同样会产生误差，而该数据在实际应用中是可见的，所以生成数据结果中将以稀疏数据的真实值代替未被掩码位置的生成数据，以提高生成数据的精度。

传统 MAE 中，解码器主要具备两个功能：恢复丢失位置信息以及将潜在表征映射回特征空间。这种解码器以不完全潜在表征 $H_N \in \mathbb{R}^{h \times (n-l)}$ 为输入，因此需要掩码标记来表示掩码补丁的存在和位置。与文本数据高度离散的潜在空间相比，时间序列数据的潜在空间趋于高度连续。因此，虽然掩码标记在自然语言处理模型中工作良好，但在时间序列中，掩码标记导致合成时间序列过于离散，不适合时间序列生成。为避免使用掩码标记，ExtraMAE 提出了一种外推器来恢复掩模补丁的潜在表征 $H_M \in \mathbb{R}^{h \times (m-l)}$ 。然后，解码器可以将完整的潜在表征 $\tilde{H} \in \mathbb{R}^{h \times L}$ 映射回特征空间，不再需要掩码标记。

5.3 还原数据的状态估计有效性验证

本节中，以松下电池数据集进行模型训练，并验证其数据还原能力与还原数据在 SOC 估计中的效果，数据集划分方式同 3.3 节相同。模型输入序列 $X = (U_i, I_i, T_i) \in \mathbb{R}^{3 \times 20}$ 。其中，序列长度设置为 20 是综合考虑算力、计算速度与单次输入数据信息量后的结果。分别设置掩码率为 80% 和 90%，将 0.2Hz 或 0.1Hz 的数据还原为 1Hz 的数据。

以 80% 的掩码率为例，在 20 个时间点中，被掩码补丁数为 16，未被掩码补丁数为 4。编码器、外推器和解码器的结构参数设置如表 5-2 所示。

表5-2 ExtraMAE 结构参数设置

模块	第一层	第二层
编码器	GRU(3, 12, 3)	FC(12, 12)
外推器	FC(4, 20)	FC(12, 12)
解码器	GRU(12, 12, 3)	FC(12, 3)

经过 50000epoch 的训练，得到测试集中的数据还原结果如图 5-3 所示，还原数据的误差指标见表 5-3 和表 5-4。其中，稀疏还原数据定义为利用稀疏

数据还原得到的稠密数据。

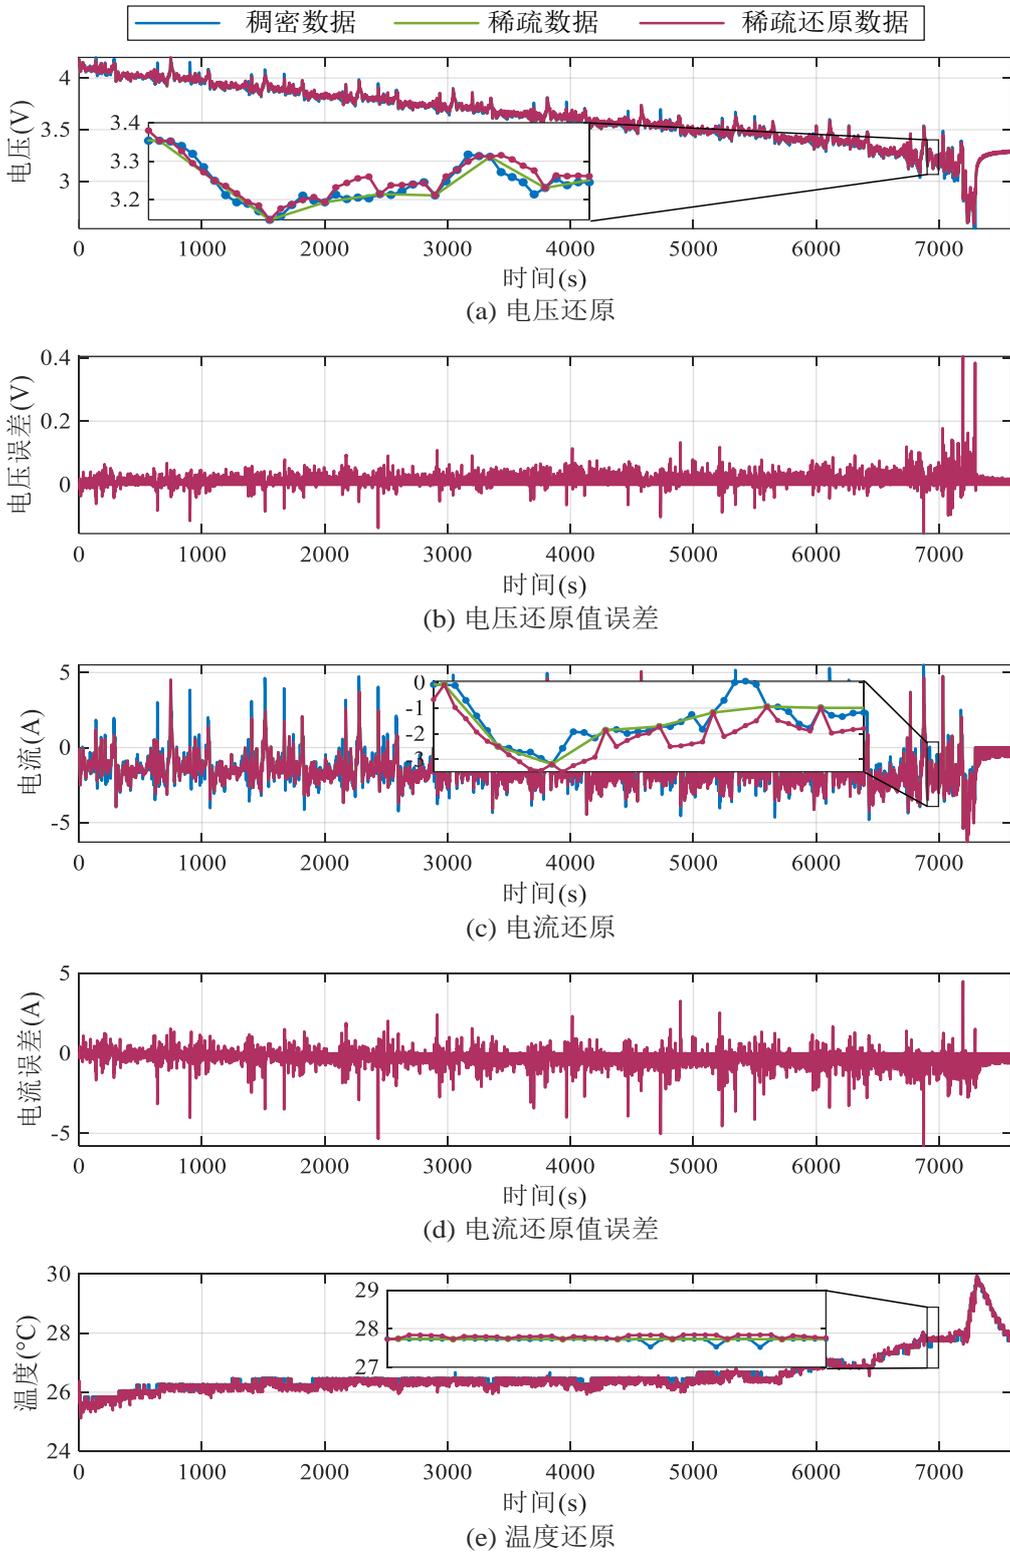
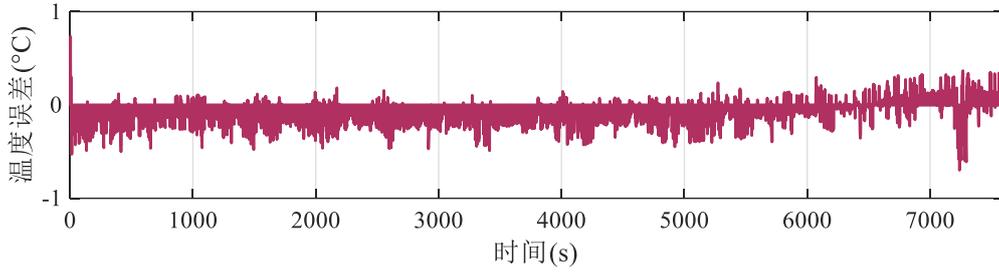


图 5-3 25°C HWFET 工况下数据还原结果



(f) 温度还原值误差

图5-3 25°C HWFET 工况下数据还原结果（续）

表5-3 HWFET 工况下数据还原评价指标

特征	25°C			10°C			0°C		
	MAE	RMSE	MAX	MAE	RMSE	MAX	MAE	RMSE	MAX
电压(V)	0.019	0.028	0.404	0.022	0.033	0.281	0.018	0.030	0.391
电流(A)	0.435	0.651	5.781	0.499	0.725	5.965	0.310	0.455	3.314
温度(°C)	0.121	0.157	0.734	0.062	0.099	0.471	0.085	0.118	0.465

表5-4 UDDS 工况下数据还原评价指标

特征	25°C			10°C			0°C		
	MAE	RMSE	MAX	MAE	RMSE	MAX	MAE	RMSE	MAX
电压(V)	0.013	0.021	0.398	0.017	0.029	0.395	0.018	0.032	0.347
电流(A)	0.366	0.595	4.832	0.370	0.584	4.655	0.266	0.442	2.973
温度(°C)	0.091	0.122	0.641	0.061	0.097	0.643	0.105	0.141	1.822

从图表可以看出，在 HWFET 工况下，还原电压数据的 MAE 在 0.022V 以内，还原电流数据的 MAE 在 0.499A 以内，还原温度数据的 MAE 在 0.121°C 以内。在 UDDS 工况下，还原电压数据的 MAE 在 0.018V 以内，还原电流数据的 MAE 在 0.370A 以内，还原温度数据的 MAE 在 0.105°C 以内。整体来看，电压、电流、温度的还原精度较高。还原电流数据的 MAE 相较于电压和温度来说较高，这是由于电流数据本身的波动范围较大导致。另外，由还原数据的误差图上可以看出，还原数据的误差呈现出高斯分布特征。

为了对还原数据在状态估计中应用的有效性进行验证，同时保证训练集、验证集、测试集的数据分布相似，在数据集划分方面，本节将利用训练好的模型输出训练集、验证集、测试集的结果，即同时得到三个集合各自还原出的数据，然后再按照 3.3 节中的数据集划分方式对还原数据进行划分。在验证方式上，本节将分别使用稀疏数据、稠密数据和稀疏还原数据来训练估计锂电池 SOC 的 CNN-GRU 模型，通过误差指标评价三种数据的优劣。

CNN-GRU 模型的结构参数如表 5-5 所示，设置 batch 大小 64，时间窗口大小为 120，学习率为 9×10^{-3} 。

表5-5 网络结构及其参数设置

网络层	参数
CNN 层	(1, 8, (8, 3))
CNN 层	(8, 32, 8)
RNN 层	(106,32,2)
FC 层	(32, 8)
FC 层	(8, 1)

经过 1000 个 epoch 的训练，得到如图 5-4 和图 5-5 所示两种工况三种不同输入数据时测试集的 SOC 估计结果，误差指标分别见表 5-6 和表 5-7。

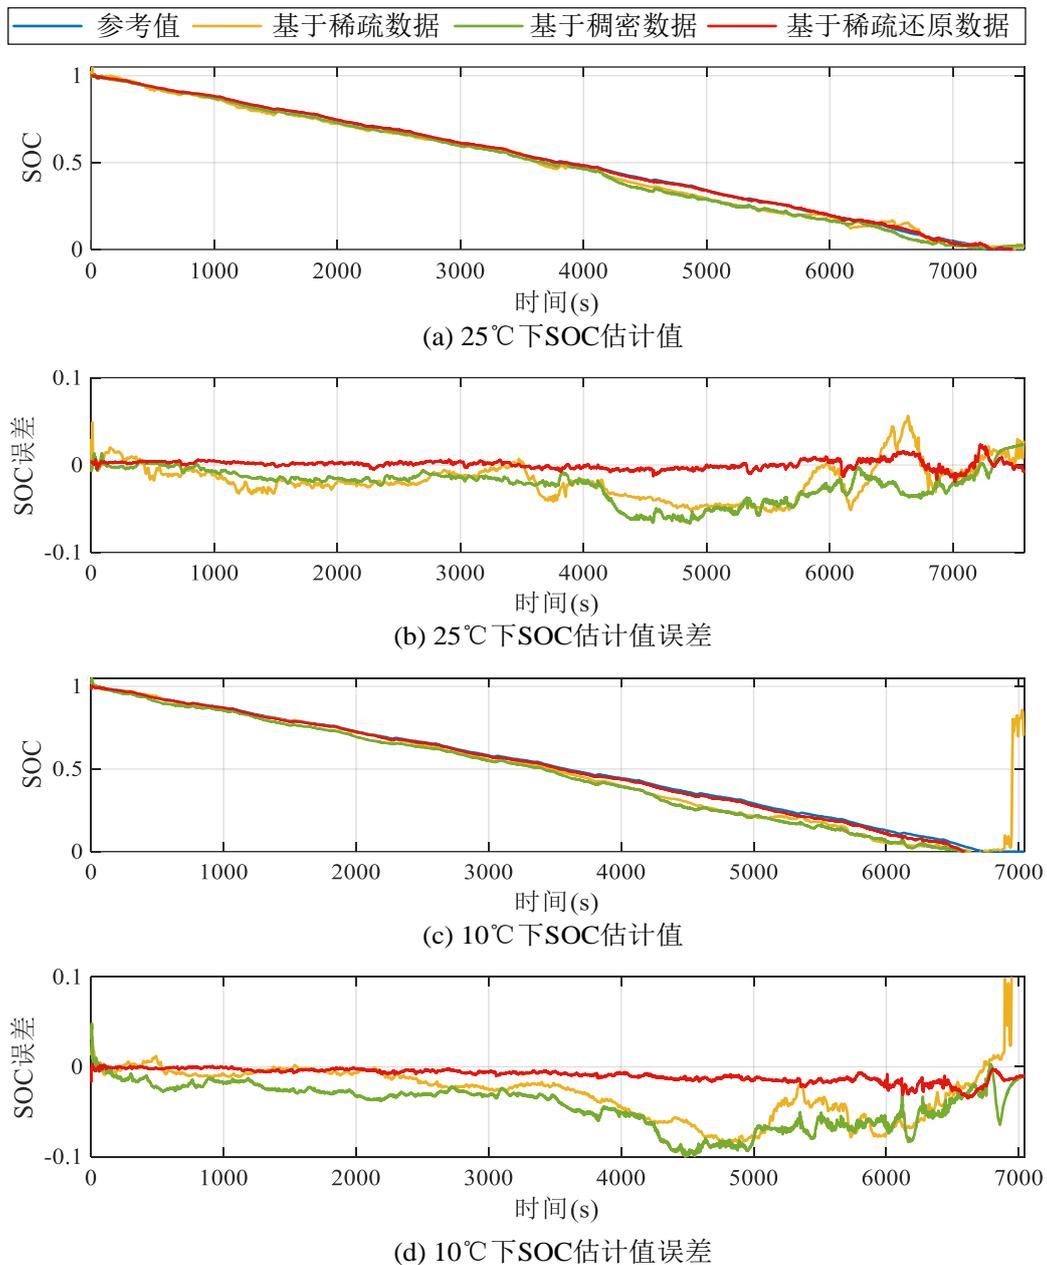
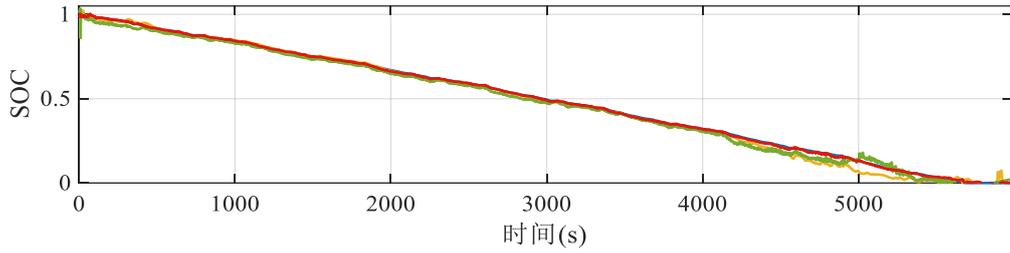
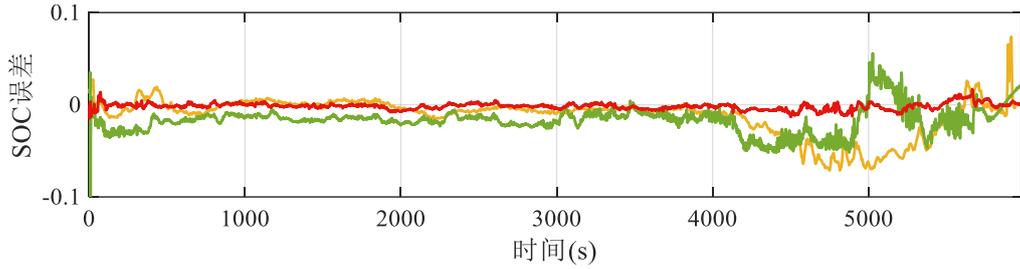


图 5-4 HWFET 工况下 SOC 估计结果 (0.2Hz 稀疏数据)



(e) 0°C下SOC估计值

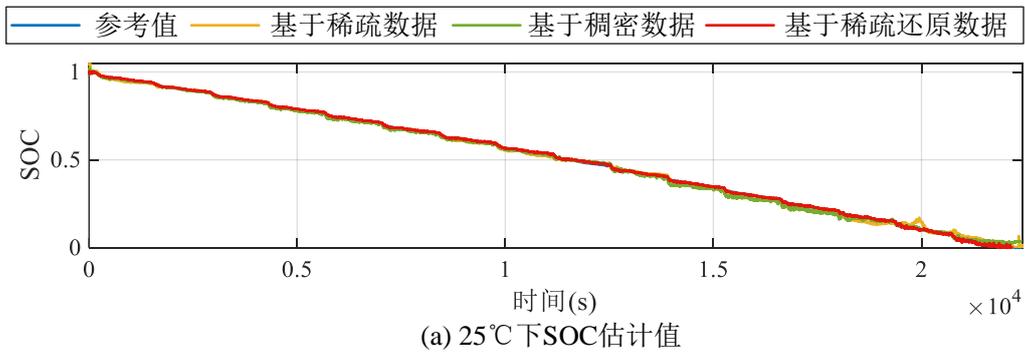


(f) 0°C下SOC估计值误差

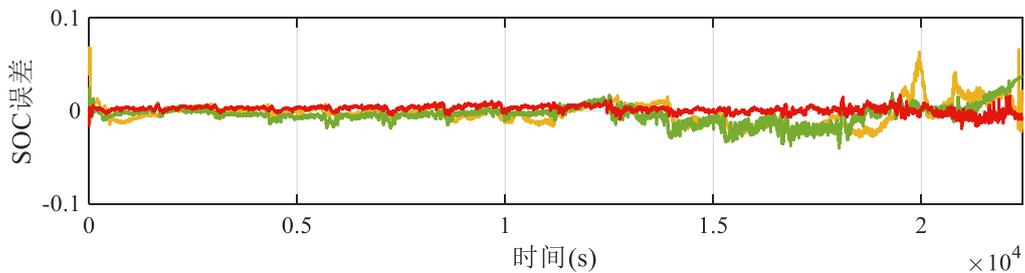
图5-4 HWFET 工况下 SOC 估计结果 (0.2Hz 稀疏数据, 续)

表5-6 HWFET 工况下还原结果的评价指标

模型输入	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
稀疏数据	2.26	2.69	5.64	3.98	9.63	85.76	1.50	2.36	7.38
稠密数据	2.33	2.90	6.68	4.26	4.88	10.00	1.91	2.19	13.94
稀疏还原数据	0.39	0.51	2.36	0.92	1.15	3.49	0.29	0.39	1.70

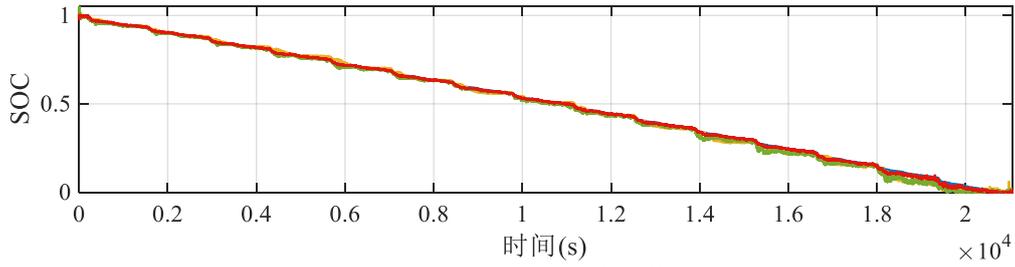


(a) 25°C下SOC估计值

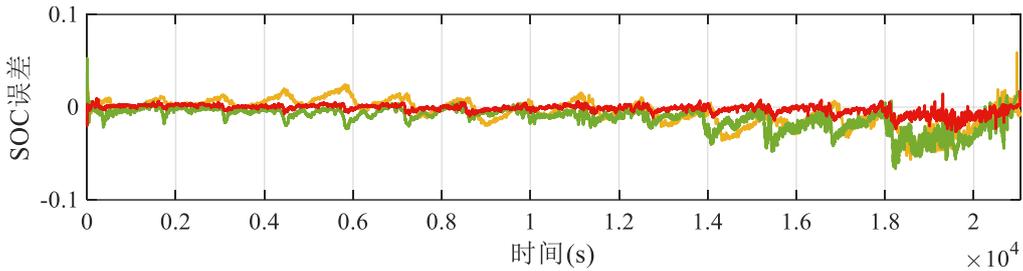


(b) 25°C下SOC估计值误差

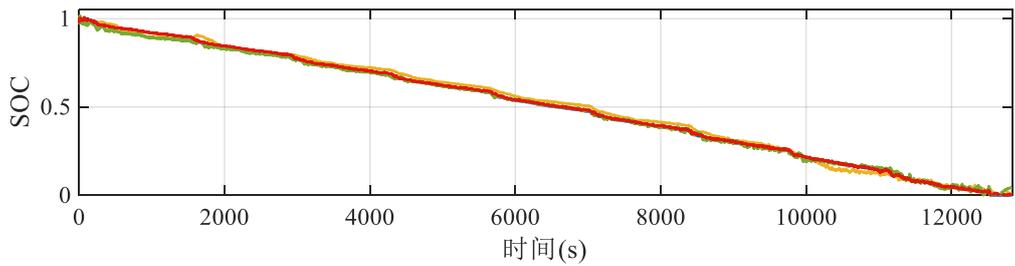
图 5-5 UDDS 工况下 SOC 估计结果 (0.2Hz 稀疏数据)



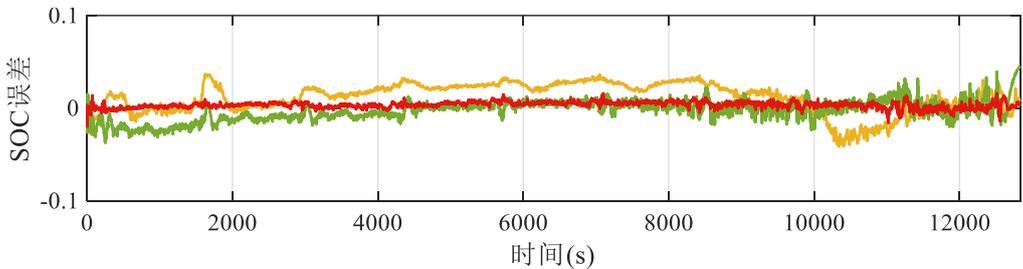
(c) 10°C下SOC估计值



(d) 10°C下SOC估计值误差



(e) 0°C下SOC估计值



(f) 0°C下SOC估计值误差

图5-5 UDSS 工况下 SOC 估计结果 (0.2Hz 稀疏数据, 续)

表5-7 UDSS 工况下还原结果的评价指标

模型输入	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
稀疏数据	0.90	1.20	6.84	1.12	1.52	5.88	1.70	1.98	4.15
稠密数据	0.78	1.08	4.05	1.22	1.67	6.64	0.86	1.12	4.54
稀疏还原数据	0.34	0.42	1.95	0.33	0.50	2.66	0.41	0.48	1.98

从图表中可以看出, 在 HWFET 工况下, 基于稠密数据的 SOC 估计精度低于基于稀疏数据的 SOC 估计精度。在 UDSS 工况下, 25°C和 10°C环境中

基于稠密的 SOC 估计精度高于基于稀疏数据，0℃环境中反之。分析原因是 1Hz 的稠密数据存在数据冗余，反而使模型在训练集过拟合，测试集表现差于 0.2Hz 的稀疏数据。相较于稀疏数据，稀疏还原数据填补了稀疏数据中缺失的数据；相较于稠密数据，稀疏还原数据相当于在稠密数据中添加了噪音，进行了数据增强。在 3 种不同环境温度两种不同工况下，利用稀疏还原数据得到的 SOC 估计结果的平均 MAE 为 0.45%，平均 RMSE 为 0.58%，最大误差为 3.49%，均低于基于稀疏数据和基于稠密数据估计得到的 SOC 误差。

从 0.1Hz 的数据还原 1Hz 数据的过程不再赘述。利用从 0.1Hz 的稀疏数据得到的稀疏还原数据，同样基于 CNN-GRU 模型进行 SOC 估计训练和验证，依据表 5-5 进行模型的超参数设置。经过 1000epoch 的训练得到的模型在 HWFET 工况和 UDDS 工况下的 SOC 估计结果如图 5-6 和图 5-7 所示，误差指标如表 5-8 和表 5-9 所示。

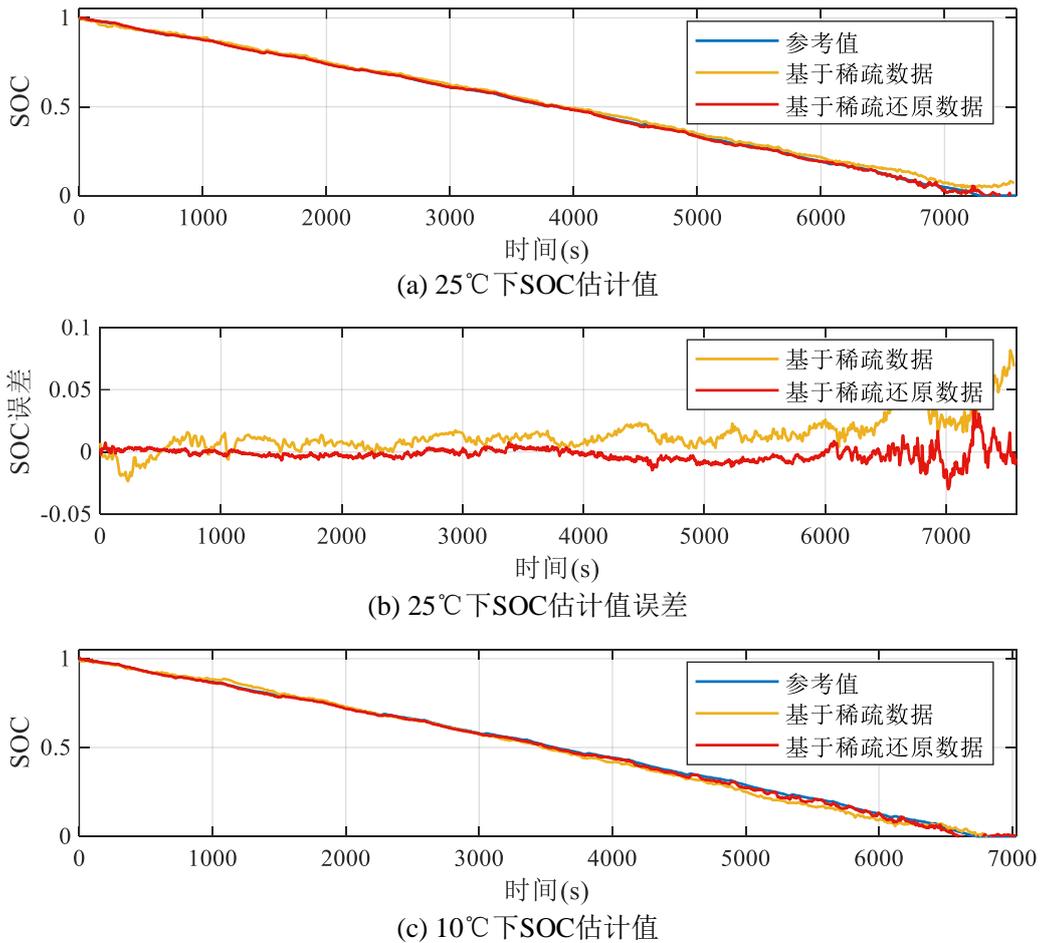
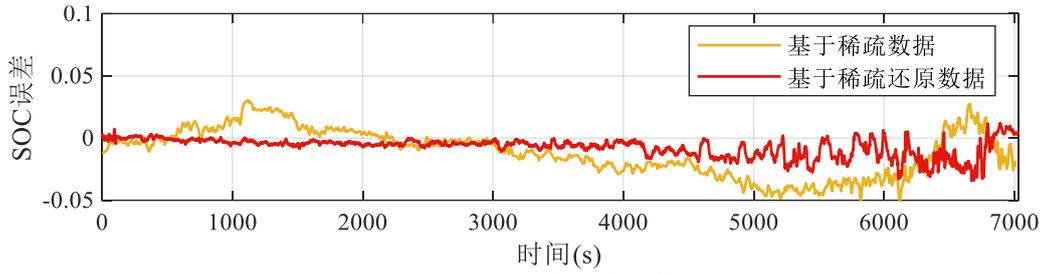
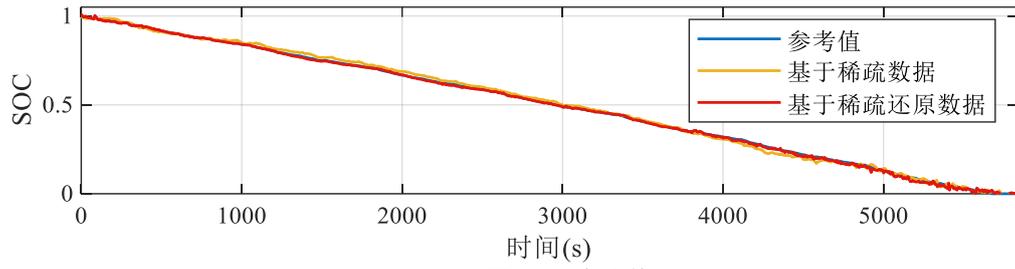


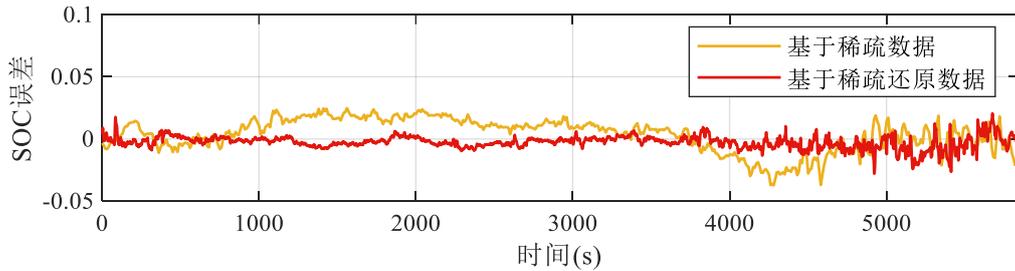
图 5-6 HWFET 工况下 SOC 估计结果 (0.1Hz 稀疏数据)



(d) 10°C下SOC估计值误差



(e) 0°C下SOC估计值

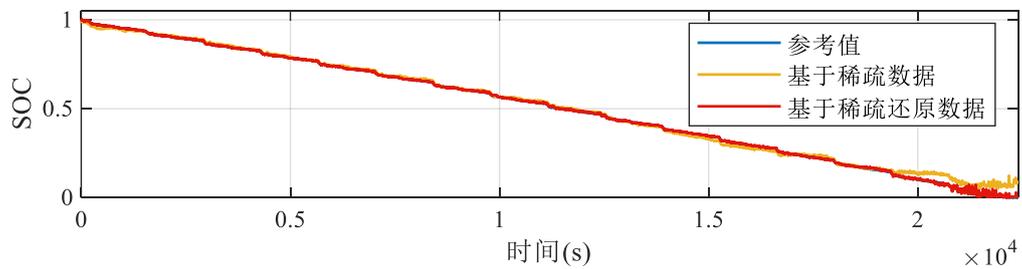


(f) 0°C下SOC估计值误差

图5-6 HWFET 工况下 SOC 估计结果 (0.1Hz 稀疏数据, 续)

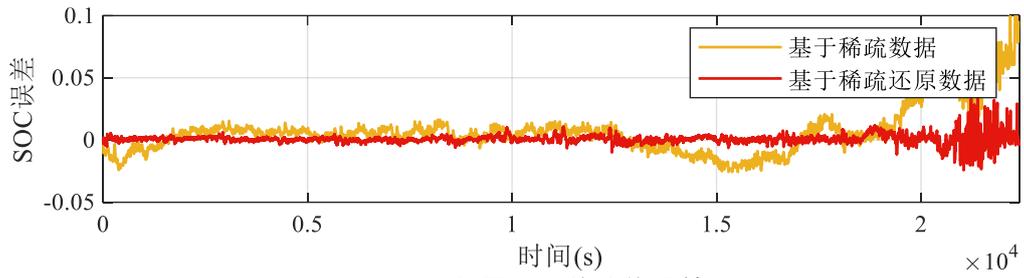
表5-8 HWFET 工况下还原结果的评价指标

模型输入	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
稀疏数据	1.49	1.96	8.16	1.75	2.18	5.48	1.16	1.37	3.72
稀疏还原数据	0.43	0.59	4.42	0.77	1.03	3.44	0.41	0.56	2.79

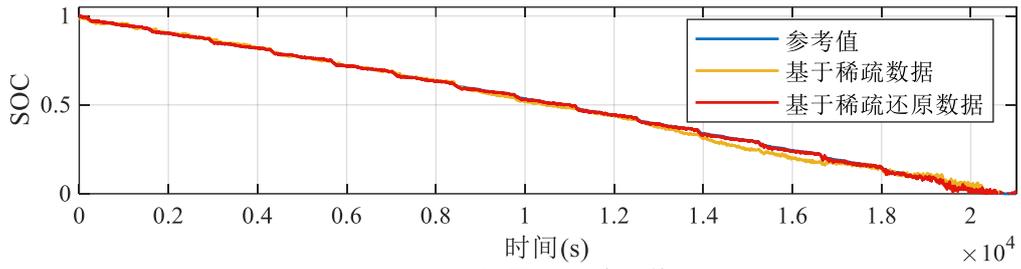


(a) 25°C下SOC估计值

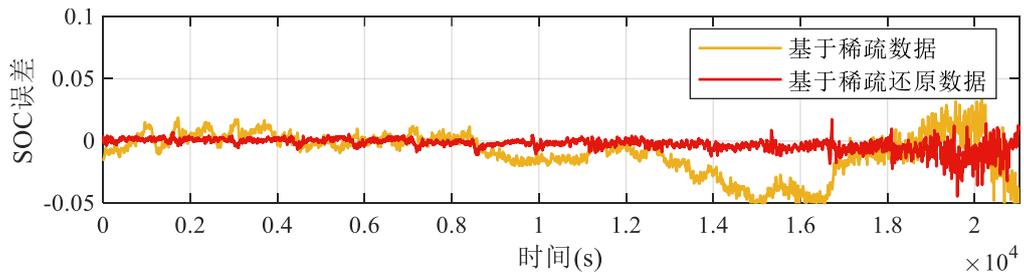
图 5-7 HWFET 工况下 SOC 估计结果 (0.1Hz 稀疏数据)



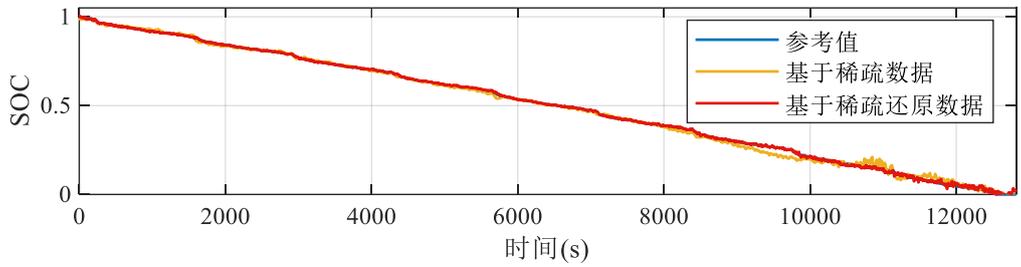
(b) 25°C下SOC估计值误差



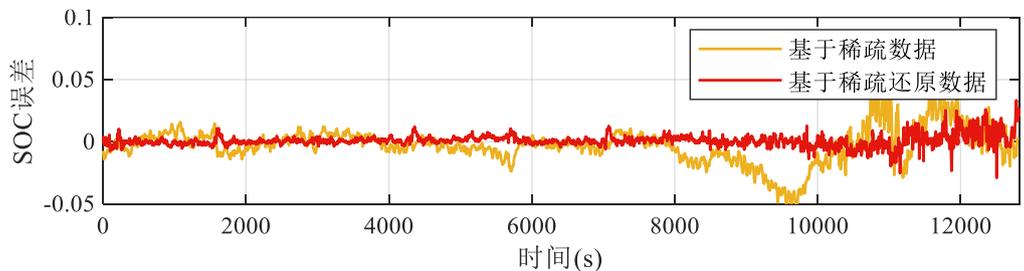
(c) 10°C下SOC估计值



(d) 10°C下SOC估计值误差



(e) 0°C下SOC估计值



(f) 0°C下SOC估计值误差

图5-7 UDDS 工况下 SOC 估计结果 (0.1Hz 稀疏数据, 续)

表5-9 UDDS 工况下还原结果的评价指标

模型输入	25°C			10°C			0°C		
	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)	MAE (%)	RMSE (%)	MAX (%)
稀疏数据	1.31	2.01	12.35	1.36	1.91	7.70	1.01	1.45	5.88
稀疏还原数据	0.23	0.38	4.14	0.36	0.55	4.45	0.31	0.48	3.33

从图表中可以看出，由 0.1Hz 的稀疏特征数据还原得到的稀疏还原数据在 SOC 估计任务中的平均 MAE 为 0.42%，平均 RMSE 为 0.60%，最大误差为 4.45%，表现优于 0.1Hz 稀疏特征数据。进而稀疏还原数据在 SOC 估计中的有效性以及稀疏数据还原方法应用于云端平台的潜力得到证明。

5.4 本章小结

本小节基于 MAE 理论和 ExtraMAE 模型，建立了用于动力锂电池特征数据还原的 ExtraMAE 模型。从松下电池数据的数据还原结果来看，稀疏还原数据能够较好地拟合特征本身的变化趋势，达到较高精度。基于稀疏还原数据的 SOC 估计验证表明，稀疏还原数据起到弥补缺失数据信息和增强数据的作用。松下电池测试集中基于 0.2Hz 稀疏数据所得稀疏还原数据的 SOC 估计结果平均 MAE 达到 0.45%，平均 RMSE 达到 0.58%，最大误差为 3.49%，精度显著优于基于稀疏数据和基于稠密数据的 SOC 估计精度；基于 0.1Hz 稀疏数据所还原数据的 SOC 估计结果同样达到了较高精度。进而，稀疏数据还原模型的有效性得到验证，其在云端平台应用的潜力亦得到证明。

结 论

车载动力电池状态估计在电动汽车的应用中具有重要意义，而传统的电池状态估计方法或是建模复杂，或是不能满足全生命周期动态工况下的精度要求，或是受到数据缺失的影响。本文针对上述三个问题分别开展动力电池的 SOC 估计研究、SOC 与 SOH 联合估计研究、稀疏特征数据还原研究。

在动力电池的 SOC 估计研究中，本文基于 Ada-GRU 模型和 CNN-GRU 模型，提出了一种 Fb-Ada-CNN-GRU-KF 方法。该方法可以同时考虑到输入数据的空间信息和时间信息，并充分利用不同数据之间的分布差异。另外，误差反馈机制的引入使得模型的系统性误差降低，KF 后处理器使得模型可以在线输出稳定的预测值。松下电池公开数据集验证实验中，模型多温度下 MAE 和 RMSE 均值分别为 0.78% 和 0.82%，所提出模型的鲁棒性和准确性得到验证；另外，相对于 CNN-GRU 和 Ada-GRU 模型，所提出模型各个改进模块的有效性也通过预测效果对比得到证明。为了为全生命周期的 SOC 和 SOH 联合估计模型做铺垫，同时减小计算量，该部分研究还利用实验室电池数据训练 Ada-CNN-GRU-KF 模型用于全生命周期的 SOC 估计，多老化点的 MAE 平均值达到 0.98%，RMSE 平均值达 1.41%，精度达到预期效果。

在动力电池的 SOC 与 SOH 联合估计研究中，本文首先提出了 Ada-CNN-GRU-Ave 用于估算动态驾驶工况下锂离子电池的 SOH。由于 SOH 是一个变化缓慢的变量，在生成输入数据时采用双时间尺度策略，以平衡模型的精度和计算量；将输出 SOH 值从先验输出中平均为单个放电周期的一个值，从而增强模型的稳定性。实验室数据 BJS DST 工况下的测试中，特征 SOC 和 ADC 的添加可以使 CNN-GRU 模型在 15 秒内收敛，且 SOH 估计值的 MAE 和 RMSE 分别从 0.67% 和 1.4% 降低到 0.14% 和 0.37%，表明 SOC 和 ADC 作为新特征输入对 SOH 的估计精度和速度提升的有效性；另外，Ada-CNN-GRU-Ave 模型估计所得 SOH 的 MAE 和 RMSE 分别为 0.02% 和 0.03%，其优越性得到对比验证，为 SOC 与 SOH 的联合估计打下基础。在得到 SOC 估计模型与 SOH 估计模型后，为对 SOC 与 SOH 联合估计的效果进行验证，同时解决联合估计验证中电池老化试验相邻老化点 SOH 过于离散的问题，为模型设置 SOH 偏差初值，得到偏差 SOC 值，模拟极限条件下 SOC 与 SOH 累计误差。实验表明，利用偏差 SOH 值得到的偏差 SOC 值，能够基本表征 SOC 的实际趋势，进而实现 SOH 快速收敛到准确范围内，用于当前老化点 SOC 与 SOH

的联合估计。联合估计模型中，SOH 估计值的 MAE 与 RMSE 均为 0.07%，SOC 估计结果的 MAE 为 0.99%，RMSE 为 1.44%，联合估计模型的泛化性和准确性得到了很好的验证。

在动力电池的稀疏特征数据还原研究中，本文基于 MAE 理论和 ExtraMAE 模型，建立了用于动力锂电池特征数据还原的 ExtraMAE 模型。模型将 0.2Hz 和 0.1Hz 的松下电池数据还到 1Hz。从 0.2Hz 数据还原结果来看，还原电压、还原电流和还原温度的平均 MAE 分别控制在 0.022V、0.725A 和 0.012°C 以内，稀疏还原数据能够较好地拟合特征本身的变化趋势。基于稀疏还原数据，本文又对三种不同的数据在 SOC 估计任务中的表现做了对比验证。从估计结果看，稀疏还原数据既能够弥补缺失数据信息，又起到减小数据冗余做数据增强的作用，在松下电池测试集中的 SOC 估计精度显著优于基于稀疏数据和稠密数据的 SOC 估计精度，平均 MAE 值在 0.60% 以内。进而，稀疏数据还原模型的有效性得到验证，其在云端平台应用的潜力亦得到证明。

相关创新点总结如下：

(1) 利用改进的深度迁移学习模型，考虑多训练集中不同工况的分布差异、特征数据的空间特征信息，实现电池状态估计泛化性和精度的提升。将 KF 算法与深度迁移学习模型相结合，实现 SOC 估计的平稳输出。

(2) 以双时间尺度特征输入，实现低成本 SOH 估计模型的训练与测试。结合 SOC 估计模型与 SOH 估计模型，实现全生命周期动态工况下高精度的 SOC 与 SOH 联合估计。

(3) 对于云端平台特征数据稀疏的问题，利用 ExtraMAE 模型实现了稀疏特征数据还原，还原数据的精度以及在 SOC 估计中的有效性得到证明。

本文推进过程中，有以下不足之处有待后续深入研究：

(1) 深度迁移学习模型的参数由多组不同模型参数加权得到，参数量大，模型的训练较为消耗空间与计算力，未来应进一步对模型结构进行优化。

(2) 模型包含众多超参数，需要人为手动调整，未来应寻求优化算法实现超参数的自动寻优。

参考文献

- [1] 胡敏, 王恒, 陈琪. 电动汽车锂离子动力电池发展现状及趋势[J]. 新能源汽车, 2020, 12(4): 22-25.
- [2] Jossen A, Späth V, Döring H, Et Al. Reliable battery operation - a challenge for the battery management system[J]. Journal of Power Sources, 1999, 84(2): 283-286.
- [3] 张瑛. 基于数据驱动的退役动力电池快速分选及健康状态估计[D]. 山东大学, 2021.
- [4] Tran M K, Panchal S, Khang T D, et al. Concept review of a cloud-based smart battery management system for lithium-ion batteries: Feasibility, logistics, and functionality[J]. Batteries, 2022, 8(2):19.
- [5] Li S, He H, Wei Z, Et Al. Edge computing for vehicle battery management: Cloud-based online state estimation[J]. Journal of Energy Storage, 2022, 55(PB): 105502.
- [6] 秦潇涵. 基于循环神经网络的锂电池SOC估计[D]. 杭州电子科技大学, 2020.
- [7] How D N T, Hannan M A, Hossain Lipu M S, et al. State of charge estimation for lithium-ion batteries using model-based and data-driven methods: A review[J]. IEEE Access, 2019, 7: 136116-136136.
- [8] Kim J, Seo G S, Chun C, et al. OCV hysteresis effect-based SOC estimation in extended Kalman filter algorithm for a LiFePO₄/C cell[J]. 2012 IEEE International Electric Vehicle Conference, IEVC 2012, 2012.
- [9] Ali M U, Zafar A, Nengroo S H, et al. Towards a smarter battery management system for electric vehicle applications: A critical review of lithium-ion battery state of charge estimation[J].Energies, 2019, 12(3): 446.
- [10] Barai A, Widanage W D, Marco J, et al. A study of the open circuit voltage characterization technique and hysteresis assessment of lithium-ion cells[J]. Journal of Power Sources, 2015, 295: 99-107.
- [11] Hannan M A, Lipu M S H, Hussain A, et al. A review of lithium-ion battery state of charge estimation and management system in electric

- vehicle applications: Challenges and recommendations[J]. *Renewable and Sustainable Energy Reviews*, 2017, 78: 834-854.
- [12] He H, Zhang X, Xiong R, et al. Online model-based estimation of state-of-charge and open-circuit voltage of lithium-ion batteries in electric vehicles[J]. *Energy*, 2012, 39(1): 310-318.
- [13] Tian J, Xiong R, Shen W, et al. State-of-charge estimation of LiFePO₄ batteries in electric vehicles: A deep-learning enabled approach[J]. *Applied Energy*, 2021, 291(5): 116812.
- [14] Plett G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs - Part 1. Background[J]. *Journal of Power Sources*, 2004, 134(2): 252-261.
- [15] 苗壮. 动力锂离子电池动态特性研究及SOC估算[D]. 哈尔滨工业大学, 2017.
- [16] Chen Z, Fu Y, Mi C C. State of charge estimation of lithium-ion batteries in electric drive vehicles using extended Kalman filtering[J]. *IEEE Transactions on Vehicular Technology*, 2013, 62(3): 1020-1030.
- [17] Vidal C, Malysz P, Kollmeyer P, et al. Machine learning applied to electrified vehicle battery state of charge and state of health estimation: State-of-the-art[J]. *IEEE Access*, 2020, 8: 52796-52814.
- [18] Vapnik V, Golowich S E, Smola A. Support vector method for function approximation, regression estimation, and signal processing[J]. *Advances in Neural Information Processing Systems*, 1997, 9: 281-287.
- [19] 李智鹏. 磷酸铁锂电池荷电状态估算方法研究[D]. 浙江大学, 2013.
- [20] Hossain Lipu M S, Hannan M A, Hussain A, et al. Data-driven state of charge estimation of lithium-ion batteries: Algorithms, implementation factors, limitations and future trends[J]. *Journal of Cleaner Production*, 2020, 277: 124110.
- [21] He W, Williard N, Chen C, et al. State of charge estimation for Li-ion batteries using neural network modeling and unscented Kalman filter-based error cancellation[J]. *International Journal of Electrical Power & Energy Systems*, 2014, 62: 783-791.
- [22] Zaremba W, Sutskever I, Vinyals O. Recurrent neural network regularization[J]. *ArXiv*, 2014: 1-8.

- [23] Chemali E, Kollmeyer P J, Preindl M, et al. Long short-term memory networks for accurate state-of-charge estimation of li-ion batteries[J]. IEEE Transactions on Industrial Electronics, 2018, 65(8): 6730-6739.
- [24] Song X, Yang F, Wang D, Et Al. Combined CNN-LSTM network for state-of-charge estimation of lithium-ion batteries[J]. IEEE Access, 2019, 7: 88894-88902.
- [25] 段英杰. 锂离子电池寿命测试与健康状态估计[D]. 浙江大学, 2021.
- [26] Meddings N, Heinrich M, Overney F, et al. Application of electrochemical impedance spectroscopy to commercial Li-ion cells: A review[J]. Journal of Power Sources, 2020, 480.
- [27] 徐鑫珉, 王练, 史慧玲. 基于电化学阻抗谱的电池老化寿命研究[J]. 电源技术, 2015(3).
- [28] 郭涵刚. 锂离子电池健康状态估计及剩余寿命预测研究[D]. 吉林大学, 2022.
- [29] 刘栋. 锂离子电池健康状态及剩余使用寿命研究[D]. 湖南大学, 2020.
- [30] 张君鸣. 基于神经网络方法的锂离子电池状态估计研究[D]. 山东大学, 2021.
- [31] Eddahech A, Briat O, Vinassa J M. Determination of lithium-ion battery state-of-health based on constant-voltage charge phase[J]. Journal of Power Sources, 2014, 258: 218-227.
- [32] Jiang Y, Jiang J, Zhang C, et al. State of health estimation of second-life LiFePO₄ batteries for energy storage applications[J]. Journal of Cleaner Production, 2018, 205: 754-762.
- [33] Weng C, Feng X, Sun J, et al. State-of-health monitoring of lithium-ion battery modules and packs via incremental capacity peak tracking[J]. Applied Energy, 2016, 180: 360-368.
- [34] Liu Q, Kang Y, Qu S, Et Al. An online SOH estimation method based on the fusion of improved ICA and LSTM[J]. 2020 IEEE/IAS Industrial and Commercial Power System Asia, 2020: 1163-1167.
- [35] Li K, Zhou P, Lu Y, et al. Battery life estimation based on cloud data for electric vehicles[J]. Journal of Power Sources, 2020, 468: 228192.
- [36] Xu C, Li L, Xu Y, et al. A vehicle-cloud collaborative method for multi-type fault diagnosis of lithium-ion batteries[J]. eTransportation, 2022,

- 12: 100172.
- [37] Zhou Y, Gu H, Su T, et al. Remaining useful life prediction with probability distribution for lithium-ion batteries based on edge and cloud collaborative computation[J]. *Journal of Energy Storage*, 2021, 44: 103342.
- [38] Lu Y, Li K, Han X, et al. A method of cell-to-cell variation evaluation for battery packs in electric vehicles with charging cloud data[J]. *eTransportation*, 2020, 6: 100077.
- [39] 程万伟. 时间序列缺失值插补方法研究[D]. 湖南大学, 2018.
- [40] Little R J A, Rubin D B. *Statistical analysis with missing data* [M]. John Wiley & Sons, 2019, 793.
- [41] Van Buuren S. *Flexible imputation of missing data*[M]. CRC press, 2018.
- [42] Lokupitiya R S, Lokupitiya E, Paustian K. Comparison of missing value imputation methods for crop yield data[J]. *Environmetrics: The official journal of the International Environmetrics Society*, 2006, 17(4): 339-349.
- [43] Schafer J L, Graham J W. Missing data: Our view of the state of the art.[J]. *Psychological methods*, 2002, 7(2): 147.
- [44] 徐鸿艳;孙云山;秦琦琳;朱明涛; 缺失数据插补方法性能比较分析[J]. *软件工程*, 2021, 24(11): 11-14+10.
- [45] 郝雨微. 基于深度学习的医疗时序数据补值模型研究[D]. 吉林大学, 2019.
- [46] Ma L, Zhang T. Deep learning-based battery state of charge estimation: Enhancing estimation performance with unlabelled training samples[J]. *Journal of Energy Chemistry*, 2023, 80: 48-57.
- [47] Zhang M, Zhang H, Yuan D, et al. Learning-based sparse data reconstruction for compressed data aggregation in IoT networks[J]. *IEEE Internet of Things Journal*, 2021, 8(14): 11732-11742.
- [48] 安靖宇. 基于循环神经网络结构的动力电池SOC算法研究[D]. 吉林大学, 2021.
- [49] Kollmeyer P. Panasonic 18650PF li-ion battery data[J]. *Mendeley Data*, 2018, 1.
- [50] Bengio Y, Haffner P. Gradient-based learning applied to document

- recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324..
- [51] 韩林洁. 基于CNN和GRU的滚动轴承退化状态评估及剩余寿命预测[D]. 北京机械工业自动化研究所, 2020.
- [52] Chung J. Gated recurrent neural networks[C]. *International conference on machine learning*, 2015, 2067-2075.
- [53] Zha M, Wong S, Liu M, et al. Time series generation with masked autoencoder[J]. *ArXiv*, 2022.

攻读硕士学位期间取得创新性成果

（一）学术论文

1. **Y Yang**, L Zhao, Q Yu*, S Liu, G Zhou, W Shen, State of charge estimation for lithium-ion batteries based on cross-domain transfer learning with feedback mechanism, Journal of Energy Storage, 2023. (IF=8.907, JCR 1 区, 二审中)

（二）专利

1. 于全庆, **杨永松**等, 基于改进深度迁移学习的锂电池荷电状态估计方法 (已受理)
2. 于全庆, **杨永松**等, 锂离子电池双时间尺度健康状态与荷电状态的联合估计的方法 (已受理)
3. 于全庆, **杨永松**等, 一种动力电池稀疏数据还原方法 (已受理)

哈尔滨工业大学学位论文原创性声明和使用权限

学位论文原创性声明

本人郑重声明：此处所提交的学位论文《基于深度学习的车用锂电池状态估计研究》，是本人在导师指导下，在哈尔滨工业大学攻读学位期间独立进行研究工作所取得的成果，且学位论文中除已标注引用文献的部分外不包含他人完成或已发表的研究成果。对本学位论文的研究工作做出重要贡献的个人和集体，均已在文中以明确方式注明。

作者签名：杨永松 日期：2023年5月22日

学位论文使用权限

学位论文是研究生在哈尔滨工业大学攻读学位期间完成的成果，知识产权归属哈尔滨工业大学。学位论文的使用权限如下：

(1) 学校可以采用影印、缩印或其他复制手段保存研究生上交的学位论文，并向国家图书馆报送学位论文；(2) 学校可以将学位论文部分或全部内容编入有关数据库进行检索和提供相应阅览服务；(3) 研究生毕业后发表与此学位论文研究成果相关的学术论文和其他成果时，应征得导师同意，且第一署名单位为哈尔滨工业大学。

保密论文在保密期内遵守有关保密规定，解密后适用于此使用权限规定。

本人知悉学位论文的使用权限，并将遵守有关规定。

作者签名：杨永松 日期：2023年5月22日

导师签名： 日期：2023年5月22日

致 谢

时光如梭，光阴似箭，我在哈尔滨工业大学两年的研究生学习生活转眼就要画上句号。回头看，可谓一路走来一路收获，值此论文完成之际，向这两年陪伴我、帮助我的人们致以敬意。

首先，感谢赵立军老师和于全庆老师在我求学之路上对我的帮助与支持。赵老师对事认真负责，待人和善可亲。在工作中，赵老师以严谨态度为学生树立了榜样；学习生活中，当我遇到困难，赵老师会及时给予我鼓励和支持，让我重拾信心继续前行。于老师对科研工作充满了热忱，用心对待每一位学生。朝夕相处的两年间，于老师孜孜不倦地带领同学们攻克科学难关，无所保留地为我们传道、授业、解惑。同时，于老师勤奋和谦虚的态度也深刻影响我，让我受用一生。

其次，感谢日日陪伴我的同窗金鑫、李建明、刘世卓、龙胜文、周广辉，师弟李维聪、聂玉威、王灿、王仁杰、杨宇，室友杜文强、李书杰、郑豪。科研上我们互相帮助鼓励，一起讨论问题，共同成长进步，生活里我们一起度过了愉快而充实的时光。

另外，感谢一些我未曾谋面却又实在影响我世界观与人生观的人文社科领域学者艾瑞克·弗洛姆、钱穆、林达、赵林、石国鹏、王受之等。读研期间我时常感到迷茫，他们以自己敏锐的洞察力和渊博的学识穿越时空为我答疑解惑，教我更好地认识世界、认识自己、看清前行的路。

特别地，感谢父母和姐姐，他们一直以来都是我生命中最坚实的后盾，没有他们的支持，我将无法取得今天的成就。

最后，感谢母校哈工大为我提供了成长学习的平台，祝福母校百年昌盛、再续辉煌，祝福学校老师们身体健康、工作顺利。