

掩码表征迁移策略下的锂电池变工况健康状态预测

王一航, 陈旭, 沈萌, 赵春晖[†]

(浙江大学 控制科学与工程学院, 浙江 杭州 310027)

摘要: 锂电池健康状态(SOH)预测可以对电池老化程度进行评估。由于电池工作状况的差异, 锂电池训练数据(源域)和在线应用数据(目标域)具有不同的分布, 而迁移学习是解决上述问题的有效方法。然而, 一方面, 传统迁移学习方法需要大量源域数据标签, 而SOH测量困难, 难以提供充足标签; 另一方面, 这些方法无法充分利用已有的专家知识。基于此, 本文创新性地提出了一种掩码表征迁移策略(MFTS), 实现了源域无标签场景下的变工况锂电池SOH预测。首先, 设计了一种掩码自监督框架, 其可以在无标签的情况下实现自动特征提取来表征源域数据。其次, 提出了一种专家知识模块, 引导所提特征逼近专家特征, 从而实现了专家知识的融入。最后, 提出了一种双学习率的方法对特征提取和SOH预测网络进行同步变速训练, 在迁移源域知识的同时实现了目标域SOH的准确预测。基于NASA的公开数据集, 所提出的MFTS模型在6组实验上的预测误差均不大于4.08%。

关键词: 锂离子电池; 健康状态; 掩码表征迁移策略; 变工况迁移

引用格式: 王一航, 陈旭, 沈萌, 等. 掩码表征迁移策略下的锂电池变工况健康状态预测. 控制理论与应用, 2024, 41(8): 1377 – 1385

DOI: 10.7641/CTA.2023.30025

A masked feature transfer strategy for lithium battery state of health prediction under variable working conditions

WANG Yi-hang, CHEN Xu, SHEN Meng, ZHAO Chun-hui[†]

(College of Control Science and Engineering, Zhejiang University, Hangzhou Zhejiang 310027, China)

Abstract: Lithium battery state of health (SOH) prediction can evaluate battery aging. Due to differences in battery working conditions, lithium battery training data (source domain) and online application data (target domain) have different distributions, and transfer learning is an effective method to solve the above problems. However, on the one hand, traditional transfer learning methods require a large number of source domain data labels, and the SOH measurement is difficult to provide sufficient labels. On the other hand, these methods cannot make full use of existing expert knowledge. To solve the above problems, this paper innovatively proposes a masked feature transfer strategy (MFTS), which realizes the SOH prediction of the lithium battery under variable working conditions with unlabeled source domain data. First, a masked self-supervised framework is designed, which can automatically extract robust representations in source domain data without labels. Secondly, an expert knowledge module is proposed to guide the extracted features to approach the expert features, thus realizing the integration of expert knowledge. Finally, a double learning rate method is proposed to perform synchronous variable speed training on the feature extraction and the SOH prediction network, and achieves the accurate prediction of the target domain SOH while transferring the knowledge of the source domain. Based on the NASA's public data set, the prediction error of the proposed MFTS model in the six sets of experiments is all less than or equal to 4.08%.

Key words: Lithium battery; state of health; masked feature transfer strategy; variable working conditions transfer

Citation: WANG Yihang, CHEN Xu, SHEN Meng, et al. A masked feature transfer strategy for lithium battery state of health prediction under variable working conditions. *Control Theory & Applications*, 2024, 41(8): 1377 – 1385

1 引言

近年来, 锂离子电池因其低自放电率、高电压、长寿命周期、高能量密度以及高可靠性等优点被广泛使用^[1], 与此同时, 其带来的安全问题不容小觑^[2]。作为

保障安全性的重要手段之一, 锂电池的健康状态(state of health, SOH)管理受到越来越多的关注。SOH作为一种评估电池健康的指标, 反映了电池实际容量与标称容量的衰减比率, 由式(1)表示:

收稿日期: 2023-01-17; 录用日期: 2023-10-26.

[†]通信作者. E-mail: chhzhao@zju.edu.cn; Tel.: +86 571-87951879.

本文责任编辑: 崔巍.

国家自然科学基金杰出青年基金项目(62125306), NSFC-浙江两化融合联合基金项目(U1709211)资助.

Supported by the National Natural Science Foundation of China (62125306) and the NSFC-Zhejiang Joint Fund for the Integration of Industrialization and Informatization (U1709211).

$$\text{SOH} = \frac{C_{\text{act}}}{C_{\text{anorm}}}, \quad (1)$$

其中 C_{aact} 和 C_{anorm} 分别代表电池的实际最大容量和标称容量^[3]. 一个全新电池的SOH值为100%, 随着电池的不断使用, SOH会逐渐下降. 当SOH降至80%以下时, 认为电池的寿命终止, 需要更换电池^[4]. 因此, 为了时刻掌握电池的健康程度, 对SOH进行预测十分重要. 由于电池的标称容量是确定的, 故对SOH的预测可以转化为对实际最大容量的预测. 预测方法主要可以分为两类, 包括机理分析法^[5-7]和数据驱动法^[8-9].

机理分析法使用微分方程来描述电池的老化过程, 或者利用专家知识提取和电池老化相关的特征, 从而对SOH进行估计. Weng等^[5]借助电化学模型和恒定电流-恒定电压充电方法, 使用变换函数和非线性最小二乘法对SOH进行预测. Li等^[6]使用单粒子模型(single particle model, SPM)对SOH进行预测, 该模型将阳极和阴极分别视为具有与电极相同的表面积的一个颗粒. Li等^[7]将传感器信号转换为增量容量(incremental capacity, IC)曲线, 并从曲线中提取了表征电池老化信息的特征用于SOH预测. 尽管机理分析法已经可以成功的对SOH进行预测, 但是对于复杂系统来说, 仍然很难获取足够的先验知识.

数据驱动法可以自动建立传感器测量值和待预测值的映射关系, 不用建立复杂的微分方程等模型, 也无需深入了解内部的复杂机理. 因此, 数据驱动的方法在学术界和工业界都受到了广泛的关注^[10-11]. 近年来, 随着计算速度和数据量的不断提升, 深度学习方法在健康管理领域被广泛应用^[12-13]. 例如, 刘小峰等^[14]通过降噪自编码器提取特征, 再构建健康指数进行航空发动机健康管理. 彭开香等^[15]利用深度置信网络结合隐马尔可夫模型进行健康指标构建. 在电池健康状态预测领域, 王一航等^[16]通过二维支持域直推式建模来预测少量循环下的锂电池SOH. Li等^[17]对电池充电曲线进行了特征提取, 并使用随机森林方法进行SOH预测. Shen等^[18]使用充电周期中的电压、电流等传感器信号训练卷积神经网络(convolutional neural network, CNN)模型来对SOH进行在线估计. Li等^[19]提出了一种变体长短期记忆网络(long short term memory, LSTM)模型来同时对SOH和剩余寿命(remaining useful life, RUL)进行预测. 然而, 上述这些SOH估计方法均假设训练和测试数据来自于相同的工况, 具有相似分布. 事实上, 训练数据和测试数据可能是在不同的工况下采集的. 在不同工况下, 环境温度、充放电的电流和电压都会有所差异, 从而导致充放电数据分布具有显著差异, 在本文中将这种训练和测试工况不相同的问题称为变工况问题. 在变工况问题中, 在一种工况下训练的SOH估计模型往往会在另一种

工况下失效. 因此, 在变工况条件下进行SOH预测是一个具有挑战性的问题.

迁移学习方法是解决变工况问题的一种有效手段^[20-21]. 在迁移学习中, 训练工况下的数据称为源域数据, 而测试工况下的数据称为目标域数据. 迁移学习的核心思想就是研究如何将源域的知识迁移至目标域, 以建立一个在目标域上性能优良的模型, 从而解决由于变工况带来的模型不匹配问题^[22]. 近期, 一些迁移学习方法例如域自适应神经网络(domain adaptive neural network, DANN)^[23]、相关性对齐(correlation alignment, CORAL)^[24]和深度适配网络(deep adaptation network, DAN)^[25]被相继提出, 并且已经被广泛用于不同工业问题. 例如, 在故障诊断方面, Chai等^[26]提出了一种故障原型适配网络用于工业智能故障诊断, 并利用多源域细化的对抗性适应策略解决域不一致和类别不一致下故障诊断问题^[27]. 同时, 迁移学习也逐渐用于解决变工况条件下的锂电池SOH预测问题. 例如, Tan等^[28]通过评估任务之间的相关性, 以微调或者重建全连接层的方式实现源域到目标域的知识迁移. Ye等^[29]提出了一种深度域对抗网络(deep domain adversarial network, DDAN), 通过对抗学习的方式使得源域和目标域的特征对齐, 最后, 使用少量目标域数据进行微调, 实现了变工况条件下SOH的预测. 尽管上述方法已经取得了不错的结果, 但其仍然会面临以下两方面挑战:

1) 现有的迁移学习问题均考虑源域存在大量的有标签充放电数据. 实际上, 在锂电池的使用过程(即充放电循环)中, 其对应的传感器信号例如电压、电流和温度都是可以很容易直接测得的, 但是对应每次充放电循环的SOH标签数据则只能通过繁琐且冗长的测试在实验室中得出. 因此, 如果希望收集大量的标签, 其耗费的人力和时间成本都是巨大的. 因此, 针对源域无标签的迁移学习问题研究更加具有挑战 and 现实意义. 本文将这种源域无标签的变工况问题称为无监督变工况问题;

2) 针对锂电池的SOH预测问题, 已有很多利用专家知识提取特征进行分析的研究, 如增量容量曲线等. 但是已有的迁移学习方法仅考虑数据层面的模型训练, 而并未利用专家知识中蕴含的丰富信息. 事实上, 专家知识的引入可能会为网络提供很多正向的引导和帮助, 因此如何在训练中利用专家知识是迫切需要研究的问题.

针对上述挑战, 本文提出了一种掩码表征迁移策略(masked feature transfer strategy, MFTS)来解决无监督变工况场景下的锂电池SOH预测问题. 首先, 针对源域数据无标签问题, 设计了一种掩码重构的数据增强自监督手段, 该方法可以在不使用标签的前提下

实现自动特征提取来表征源域数据. 其次, 提出了一个专家知识引导的特征逼近策略, 引导模型特征逼近专家特征, 从而将专家知识引入迁移学习方法中. 最后, 采用一种双学习率的端到端微调方法, 实现了源域知识到目标域的迁移. 本文的贡献点总结如下:

1) 提出了一种掩码表征迁移策略来解决变工况场景中源域数据无标签情况下的锂电池SOH预测问题. 所设计的掩码自监督框架可以从无标签的源域数据中自动抽取特征来表征原始信息, 首次解决了无监督变工况场景下的锂电池SOH预测问题;

2) 提出了一种专家知识引导策略为模型添加了先验知识. 通过已有的专家知识引导模型特征层和专家特征进行近似, 实现了数据信息与专家知识的有效融合.

本文剩余部分结构如下: 第2节首先介绍了一些常用的深度神经网络架构和增量容量曲线方法; 第3节介绍了所提用于无监督变工况场景下锂电池SOH预测的MFTS策略; 第4节通过实验证明了所提方法的有效性; 第5节进行了总结与讨论.

2 预备知识

本节首先介绍了一些深度神经网络(deep neural networks, DNN)^[30]架构, 包括CNN^[31]和门控循环单元(gate recurrent unit, GRU)^[32], 之后介绍了增量容量曲线方法^[33].

2.1 卷积神经网络

CNN是一种具有局部连接、参数共享等特点的深度神经网络, 其由卷积层、池化层和全连接层组成^[34]. 在卷积层中, 输入与可学习的权重进行卷积, 结果经过非线性激活函数例如线性整流函数(rectified linear unit, ReLU)以计算新的特征图. 具体而言, 第 l 层的输出特征图可以计算为

$$\mathbf{x}_j^l = \text{ReLU}\left(\sum_{i=1}^p \mathbf{x}_i^{l-1} * \mathbf{k}_{ij}^l + b_j^l\right), \quad j = 1, 2, \dots, q, \quad (2)$$

其中: \mathbf{x}_j^l 和 \mathbf{x}_i^{l-1} 是第 j 张输出和第 i 张的输入特征图; \mathbf{k}_{ij}^l 是卷积核, b_j^l 是对应的偏置, p 和 q 是输入和输出的特征图的数量, $*$ 表示卷积操作. 在本文中用粗体表示向量, 而常规斜体表示标量.

在卷积层之后, 池化层通过计算特征图中局部的最大值并将相似的局部单元合并为一个元素来对特征图进行下采样, 可以表示为

$$\mathbf{x}_{r,j}^l = \max\{\mathbf{x}_{r',j}^{l-1}\}, \quad \forall r' \in \mathcal{R}_r, \quad (3)$$

其中: $\mathbf{x}_{r,j}^l$ 表示第 l 层第 j 个滤波器的第 r 个点, \mathcal{R}_r 是第 r 个点周围的局部单元. 与卷积相对应的还有反卷积, 其是一种特殊的正向卷积. 先按照一定的比例通过补0来扩大输入特征图的尺寸, 接着旋转卷积核, 进行正向卷积, 其计算方式和正向卷积相同.

卷积和反卷积神经网络将不同传感器信号视作不同通道的特征图, 通过卷积池化等操作来提取传感器信号间的相关性, 同时也可以提取曲线中的局部信息例如陡增、凹陷等, 这对判断电池的充放电状态从而推断电池的SOH有很大的帮助.

2.2 门控循环单元

GRU是循环神经网络(recurrent neural network, RNN)的一种变体, 其可以捕捉长期依赖关系, 并解决传统RNN出现的梯度消失和梯度爆炸问题.

GRU采用更新门和重置门来解决训练过程中梯度消失的问题, 每个时间步 t 的计算方式如下所示:

$$z_t = \sigma(\mathbf{W}_z[\mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (4)$$

$$r_t = \sigma(\mathbf{W}_r[\mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (5)$$

$$\tilde{\mathbf{h}}_t = \tanh(\mathbf{W}[\mathbf{r}_t \odot \mathbf{h}_{t-1}, \mathbf{x}_t]), \quad (6)$$

$$\mathbf{h}_t = (1 - z_t) \odot \mathbf{h}_{t-1} + z_t \odot \tilde{\mathbf{h}}_t, \quad (7)$$

其中: z_t 和 r_t 分别是更新门和重置门, σ 是sigmoid激活函数, \tanh 是双曲正切激活函数, $\mathbf{W}_z, \mathbf{W}_r, \mathbf{W}$ 是权重矩阵, \odot 代表Hadamard积(按元素乘积), \mathbf{h}_t 是时间步 t 的隐藏状态.

双向门控循环单元(bi-direction GRU, BiGRU)不仅能够利用历史信息, 也可以利用未来信息. 其由两个独立的GRU组成, 一个用于前向训练, 一个用于后向训练, 最终结果由两个输出拼接而成, 即

$$\mathbf{o}_t = [\vec{\mathbf{h}}_t, \overleftarrow{\mathbf{h}}_t], \quad (8)$$

其中: $\vec{\mathbf{h}}_t$ 和 $\overleftarrow{\mathbf{h}}_t$ 分别代表前向和后向所产生的特征, \mathbf{o}_t 为BiGRU的输出.

GRU和BiGRU可以自动提取锂电池SOH预测所需要的信息, 即传感器的时序相关性. 通过更新门和重置门提取充放电曲线中的长期变化情况, 从而推断电池的老化状态, 最终实现对电池SOH的预测.

2.3 增量容量(IC)曲线

增量容量是在足够小的时间间隔内将电池当前时刻容量的变化与电池端电压的变化进行微分计算得出的. IC曲线提供了一种非破坏性的电池老化表征手段, 曲线中的每个峰值和位置都代表了锂电池特定的电化学信息, 例如相平衡的位置^[35]. IC曲线的纵坐标是 $\frac{dQ}{dV}$, 横坐标是电压值, 可由下式计算:

$$\frac{dQ}{dV} = \frac{dI \cdot t}{dV} = \frac{I \cdot dt}{dV}. \quad (9)$$

图1展示了电池每间隔20个充放电循环绘制一次的IC曲线, 从曲线中不难看出, IC曲线的峰值和峰位置随着循环次数的增加呈现规律的变化趋势, 例如波峰的位置向左下角偏移(如图中箭头所示). 因此, IC曲线提供了表征电池老化的专家知识, 可以通过对IC曲线提取特征来实现对电池SOH值的推断.




图1 每20个循环绘制一次的IC曲线
Fig. 1 IC curves drawn every 20 cycles

3 掩码表征迁移策略

在本节中首先介绍了本文的问题设定,之后详细介绍了MFTS的具体结构和训练方法.

3.1 无监督变工况问题设定

对于锂电池的一次充放电循环,可直接测量得到电压、电流和温度等传感器信号.由于每一次循环得到的信号长度不尽相同,本文中利用降采样的方式将每次充放电循环的信号处理至一样的长度,便于后续运算.在电池的SOH预测中,和SOH较为相关的特征是各传感器的趋势,而不是细节部分.因此,虽然经过降采样处理,但由于电池充放电过程中的整体趋势比较简单,降采样仍然可以保留原始数据的趋势,从而也不会使模型性能产生大的波动.降采样的长度用 L 表示. X 代表降采样后的数据空间, Y 代表标签空间.正如引言中提到,文中将训练工况下的数据称之为源域数据,测试工况下的数据称为目标域数据.在无监

督变工况场景中,源域数据集合仅有充放电数据而没有对应的SOH标签,目标域数据集合仅有少量的有标签数据,其对应的标签可以获得但是数量稀少. $\mathcal{D}_S = \{(\mathbf{x}_i^S)\}_{i=1}^n$ 和 $\mathcal{D}_T = \{(\mathbf{x}_j^T, y_j)\}_{j=1}^m$ 分别表示源域和目标域的数据集合.其中: $\mathbf{x}_i^S \in X_S \in \mathbb{R}^{K \times L}$ 和 $\mathbf{x}_j^T \in X_T \in \mathbb{R}^{K \times L}$ 是由单次充放电循环中的 K 个传感器的测量信号组合而成, $y_j \in Y_T$ 代表对应的SOH值. n 和 m 分别代表源域和目标域样本个数,通常情况下 $n \gg m$. \mathcal{D}_S 和 \mathcal{D}_T 分别是联合分布 $P(X_S, Y_S)$ 和 $Q(X_T, Y_T)$ 中采样得到,并且 $P \neq Q$.本文期望利用从 \mathcal{D}_S 中学到的知识辅助 \mathcal{D}_T 构造预测模型,使得模型可以准确预测 \mathcal{D}_T 中的样本.

3.2 MFTS总体结构

MFTS的总体结构示意图如图2所示,模型整体由掩码近似网络(masked approximation neural network, MANN)、专家知识模块(expert knowledge module, EKM)和特征迁移模块(feature translate module, FTM)3部分组成.首先,将源域的无标签充放电数据进行掩码,然后输入MANN的编码器和解码器进行重构,最终期望输出纯净的重构数据.输出的数据和真实的加噪前的数据进行近似,使得特征可以很好地表征原始信号的信息.同时,MANN提取的特征会输入EKM中,要求网络提取的特征经过降维后逼近专家特征,从而引导模型学习到专家知识中蕴含的丰富信息.这两部分训练完成后,在MANN特征层后连接FTM模块,并利用目标域数据进行微调,最终实现SOH预测任务.接下来会对MFTS的各个部分进行详细阐述.

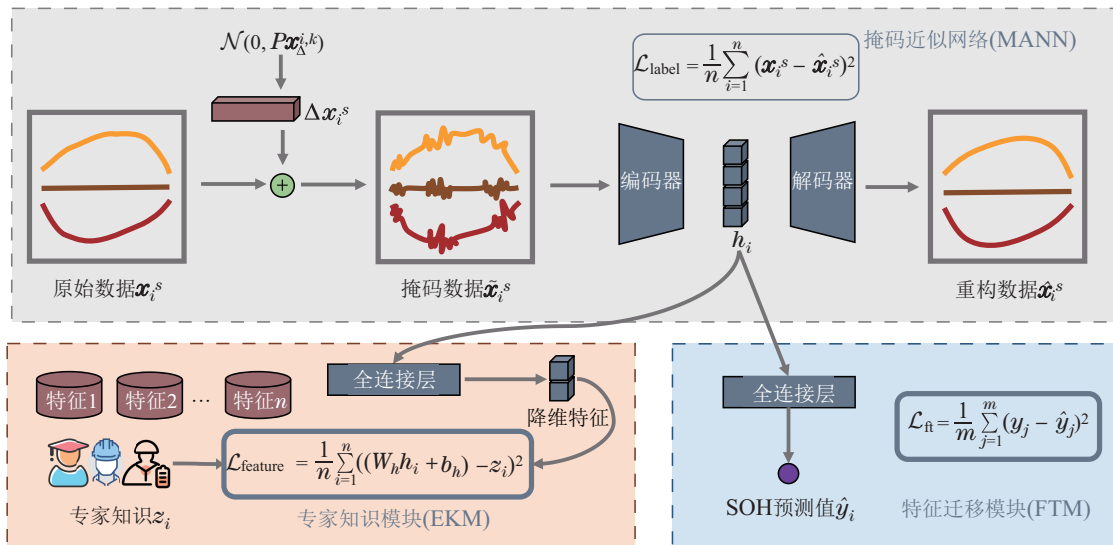


图2 MFTS总体结构示意图
Fig. 2 The overall structure of MFTS

3.3 掩码近似网络

在MANN中,首先,对输入的源域数据施加噪声.这里加噪是一种通用的手段,并没有统一的噪声规范.

大部分的研究都选择使用高斯白噪声进行加噪处理,因为高斯白噪声可以更好地模拟真实噪声.如果把真实噪声看成非常多不同概率分布的随机变量的加合,

并且每一个随机变量都是独立的, 根据中心极限定理, 那么它们的总和就会随着噪音源数量的上升, 趋近于一个高斯分布. 以第*i*次充放电循环的源域数据 \mathbf{x}_i^S 为例, 添加的噪声用 $\Delta\mathbf{x}_i^S$ 表示, 掩码后的数据用 $\tilde{\mathbf{x}}_i^S$ 表示. 然后, 将掩码后的数据输入编码器中获得特征 \mathbf{h}_i , 原始数据中的信息均蕴含在此特征中. 特征再经过解码器后重构出干净的信号, 重构信号用 $\hat{\mathbf{x}}_i^S$ 表示. 这里要求 $\hat{\mathbf{x}}_i^S$ 同 \mathbf{x}_i^S 进行逼近. 由于不同循环施加的噪声具有随机性, 在训练之前将噪声加入到数据中, 希望模型可以在有噪声的环境中依然能够完成下游任务, 从而迫使其学习到对输入中的微小变化具有鲁棒性和泛化能力的特征表示. 接下来会详细介绍加噪过程, 然后介绍MANN的编码器和解码器模块.

具体而言, 对于加噪模块, 有

$$\mathbf{x}_i^{S,k} + \Delta\mathbf{x}_i^{S,k} = \tilde{\mathbf{x}}_i^{S,k}, \quad k = 1, 2, \dots, K, \quad (10)$$

其中: 上标*k*表示第*k*个传感器信号; $\mathbf{x}_i^{S,k} \in \mathbb{R}^L$. 噪声的信噪比用 N_{snr} 表示, 其计量单位为dB, 可由下式计算:

$$N_{\text{snr}} = 10 \lg \frac{P_s}{P_\Delta}, \quad (11)$$

其中 P_s 和 P_Δ 分别代表信号和噪声的功率. 对于第*i*次充放电循环第*k*个传感器中信号的功率, 可以计算为

$$P_s^{i,k} = \frac{1}{L} \sum_{t=1}^L (x_{i,t}^{S,k})^2, \quad (12)$$

其中 $x_{i,t}^{S,k}$ 代表第*i*次充放电循环第*k*个传感器中第*t*个时刻采样点的值, 由此可以计算得到噪声的功率

$$P_\Delta^{i,k} = \frac{P_s^{i,k}}{10^{\frac{N_{\text{snr}}}{10}}} = \frac{1}{L} \sum_{t=1}^L (x_{i,t}^{S,k})^2. \quad (13)$$

对于高斯白噪声, 其均值为0, 方差和功率相等, 故可以计算出 $\Delta\mathbf{x}_i^{S,k}$ 的分布为

$$\Delta\mathbf{x}_i^{S,k} \sim \mathcal{N}(0, P_\Delta^{i,k}), \quad (14)$$

其中: \mathcal{N} 表示正态分布, 0和 $P_\Delta^{i,k}$ 分别表示均值和方差.

掩码过程中的掩码比例可调, 用 λ 表示, $\lambda \in [0, 1]$, 0代表全部不掩码, 1代表全部掩码. 此外, 由于曲线的连续性, 单点掩码的值可以从前一刻的值和后一刻的值平均得到, 这样就丧失了提取表征信息的能力, 为了提高掩码的连续性, 在掩码时设置了一个超参数 N_{len} , 其代表随机掩码片段的最小长度. 换言之, 总共 $L \cdot \lambda$ 的掩码片段会被随机分成若干个小块进行掩码, 每个小块的长度都大于等于 N_{len} , 从而掩蔽更多的信息. 值得注意的是, 对于每一次充放电循环, 掩码的位置都是随机的, 两次不同循环间的掩码位置不完全相同, 增加了模型重构的难度.

对于编码器, 其由并行的BiGRU和CNN组成. 这里使用BiGRU而不是使用GRU的原因是每次输入网

络的都是一个循环的全部片段, 希望网络能够从两个方向提取到更多的时间特征. 用 F_B 表示BiGRU函数, F_{CNN} 表示CNN函数, 则有

$$\mathbf{h}_i = [F_B(\tilde{\mathbf{x}}_i^S), F_{\text{CNN}}(\tilde{\mathbf{x}}_i^S)], \quad (15)$$

其中 $[\cdot, \cdot]$ 代表向量拼接操作.

对于解码器, 其由并行的GRU、反卷积层和全连接层组成. 这里加入全连接层是受残差神经网络的启发, 避免网络过于复杂使其过拟合. 最终的输出三者相加, 得到干净的重构数据 $\hat{\mathbf{x}}_i^S$, 用 F_G , F_D 和 F_C 分别表示GRU, 反卷积层和全连接层函数, 则有

$$\hat{\mathbf{x}}_i^S = F_G(\mathbf{h}_i) + F_D(\mathbf{h}_i) + F_C(\mathbf{h}_i). \quad (16)$$

重构数据 $\hat{\mathbf{x}}_i^S$ 和真实的纯净数据 \mathbf{x}_i^S 进行近似, 损失函数 $\mathcal{L}_{\text{label}}$ 称为重构损失, 即

$$\mathcal{L}_{\text{label}} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i^S - \hat{\mathbf{x}}_i^S)^2, \quad (17)$$

其中*n*代表源域样本的个数.

3.4 专家知识模块

EKM将专家知识引入模型. 正如之前介绍的那样, 专家知识的引入可以帮助模型学习到专家知识中蕴含的丰富信息. 同时, 利用专家知识提取的特征应该是一些表征电池老化信息的健康特征, 并且与SOH密切相关. 例如IC曲线的特征、恒流充电时长、恒压充电时长等等. 本文中选择使用IC曲线的健康特征作为专家知识对模型进行指导. 电池的老化信息可以在IC曲线的波峰和波谷中体现出来, 正如图2中所示, IC曲线具有两个波峰和一个波谷, 波峰和波谷对应了锂离子嵌入和脱嵌过程中石墨正负极的相变过程, 即专家知识. 对于绝大多数的锂电池, 其每个充放电循环都存在这样的波峰和波谷, 这种知识是通用可泛化的. 但是值得注意的是, 对于不同的充放电循环, 波峰和波谷的数值可能会有所不同, 这是个体差异性的体现. 在通用的专家知识的引导下, 为每个不同的循环计算出它独有的专家特征, 以此来克服专家知识的个体差异.

由于IC曲线涉及到微分计算, 曲线中包含非常多的噪声信号, 噪声会影响对特征的提取, 所以, 如何去除噪声就变得尤为关键. 本文中使用了高斯滤波(Gaussian smoothing, GS)滤波器进行滤波, 其可以表示为

$$G(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{\left(\frac{-x-\mu}{2\sigma^2}\right)^2}, \quad (18)$$

其中: μ 是均值, σ 是标准差. 使用GS滤波器滤波之后, 从曲线上提取了6个和SOH变化密切相关的特征点, 分别是两个波峰和一个波谷的电压值和 $\frac{dQ}{dV}$ 值. 利用专家知识提取的特征用 \mathbf{z}_i 表示.

使得 \mathbf{h}_i 经过一层线性层的降维后和 \mathbf{z}_i 进行逼近, 从而通过 \mathbf{h}_i 实现对 \mathbf{z}_i 的预测, 进而指导模型提取出和

z_i 相关的可解释性更强的特征. 损失函数称为专家特征损失

$$\mathcal{L}_{\text{feature}} = \frac{1}{n} \sum_{i=1}^n ((\mathbf{W}_h \mathbf{h}_i + \mathbf{b}_h) - z_i)^2, \quad (19)$$

其中 \mathbf{W}_h 和 \mathbf{b}_h 代表线性层的权重和偏置.

需要注意的是, MANN和EKM模块是使用源域数据同步训练的, 其整体损失函数为

$$\mathcal{L} = \mathcal{L}_{\text{feature}} + \alpha \mathcal{L}_{\text{label}}, \quad (20)$$

其中 α 为重构损失的权重, 当 $\alpha < 1$ 时, 网络更注重提取的隐层特征和专家知识的近似, 而当 $\alpha > 1$ 时, 网络更注重重构数据和真实纯净数据的近似.

3.5 特征迁移模块及双学习率训练策略

当MANN和EKM两部分使用源域数据训练完成后, 在特征 \mathbf{h}_i 后添加FTM模块用于SOH预测, 其由全连接层组成, 即

$$\hat{y}_j = \text{ReLU}(\mathbf{W}_y \mathbf{h}_i + \mathbf{b}_y), \quad (21)$$

其中: ReLU代表ReLU激活函数, \mathbf{W}_y 和 \mathbf{b}_y 代表全连接层的权重和偏置, \hat{y}_j 表示网络预测的目标域第 j 个样本的SOH值.

使用目标域的少量有标签数据 \mathcal{D}_T 对整体网络进行微调. 微调过程是将网络输出和目标域标签进行近似, 其损失函数可以表示为

$$\mathcal{L}_{\text{ft}} = \frac{1}{m} \sum_{j=1}^m (y_j - \hat{y}_j)^2, \quad (22)$$

其中: m 代表目标域的样本个数, y_j 代表目标域第 j 个样本对应的SOH标签.

Kumar等^[36]从理论证明了当源域和目标域的数据分布差异较大并且预训练的特征提取器比较优秀时, 在目标域数据上使用固定特征提取器仅调整全连接层(linear probing, LP)的方式训练的误差要远小于使用整体微调(fine tuning, FT)的方式训练的误差, 同时, 如果能够先进行LP训练一个优秀的全连接层, 再进行FT的效果要比二者单独都要更优. 基于此, 本文采用了一种巧妙的双学习率训练策略, 为了实现端到端的训练, 在训练时对全连接层赋予更大的学习率, 而对前面的特征提取器(MANN中的编码器)则采用小学习率缓慢更新的方式进行同步整体微调. 用 η_{enc} 表示特征提取器的学习率, η_{fc} 表示全连接层的学习率, 则有

$$\theta_{\text{enc}} = \theta_{\text{enc}} - \eta_{\text{enc}} \frac{\partial}{\partial \theta_{\text{enc}}} \mathcal{L}_{\text{ft}}(\theta_{\text{enc}}), \quad (23)$$

$$\theta_{\text{fc}} = \theta_{\text{fc}} - \eta_{\text{fc}} \frac{\partial}{\partial \theta_{\text{fc}}} \mathcal{L}_{\text{ft}}(\theta_{\text{fc}}), \quad (24)$$

其中 θ_{enc} 和 θ_{fc} 分别代表特征提取器和全连接层的参数. 由于 θ_{fc} 未经过训练, 全部是初始化参数, 因此需要赋予更大的学习率确保收敛, 而 θ_{enc} 已经训练较为完

备, 因此需要使用较小的学习率以保证特征提取器不会进行较大的改变, 并且确保不会错过局部的极小值. 一般情况下, η_{fc} 为之前训练MANN+EKM模块学习率的3-5倍, 而 η_{enc} 一般为 η_{fc} 的十分之一甚至更小.

4 实验与分析

本节首先介绍了实验所用的数据集, 然后分别进行了迁移学习方法对比实验、损失函数权重实验以及可视化展示及消融实验.

4.1 数据集及评价标准

本节利用NASA爱达荷州国家实验室的开源数据^[37]对MFTS的有效性进行验证, 数据集中的电池为市售18650锂电池, 一组电池在不同的环境温度下循环进行充电、放电和阻抗测试, 涉及到的传感器变量有3个, 分别为电流、电压和温度.

在本文中, 选择了3种不同的工况来验证本方法的有效性. 对于工况1, 此组电池均在室温24°C条件下循环进行充电、放电和阻抗测试, 电池分别包含168, 168, 168和132个充放电循环. 在充电过程中, 电池首先在恒流(constant current, CC)模式下以1.5 A电流进行充电, 直至电压上升至4.2 V; 然后, 进入恒压(constant voltage, CV)模式进行充电直至充电电流下降至20 mA. 放电过程包含CC模式, 以2 A恒定电流的方式进行放电, 直至电压分别下降至2.7 V, 2.5 V, 2.2 V和2.5 V, 其单次充放电循环的电压、电流和温度曲线如图3所示. 工况2实验在43°C条件下进行, 并且放电过程以4 A恒定电流的方式进行放电, 直至电压分别下降至2.0 V, 2.2 V, 2.5 V和2.7 V. 工况3实验温度为4°C, 且放电电流为1 A, 需要注意的是, 工况3电池中的某些循环SOH值异常低, 但其对实验并无影响. 表1给出了所选电池数据的详细说明.




图3 工况1单次充放电循环的电压、电流和温度曲线

Fig. 3 Voltage, current and temperature curves of a single charge-discharge cycle in working condition one

图4展示了4个电池的老化曲线, 从图中可以看出, 电池的退化能力随着循环次数呈现不稳定的下降趋

势, 并且曲线中有一些尖峰, 这种现象称为锂电池的容量再生现象, 使得电池SOH的预测变得更加困难.

表 1 不同工况电池的详细说明

Table 1 Detailed description of batteries under different working conditions

工况	电池编号	温度/ °C	充电 电流/A	放电 电流/A
1	No.5, No.6, No.7, No.18	24	1.5	2
2	No.29, No.30, No.31, No.32	43	1.5	4
3	No.46, No.47, No.48	4	1.5	1

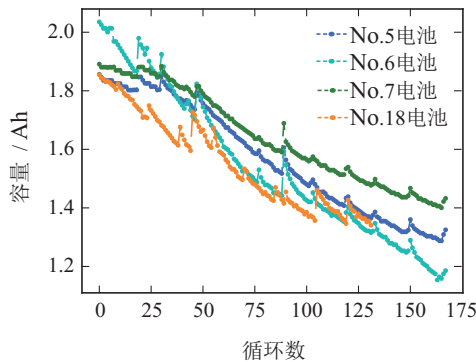


图 4 工况1的电池老化曲线

Fig. 4 Battery aging curves of working condition one

本文对于3个工况分别做了6组实验, 每组实验选取其中的一个工况作为源域, 另一个工况作为目标域, 选取目标域中的一个电池作为微调数据, 其余电池作为验证数据, 其中C1, C2和C3分别代表工况1, 2, 3. →符号代表从前一个工况迁移至后一个工况, 例如C1→

C2代表从工况1迁移至工况2.

实验评价标准选用均方根误差(root mean square error, RMSE)和平均绝对误差(mean absolute error, MAE). RMSE可以衡量观测值同真值之间的偏差, 而MAE能更好地反映预测值误差的实际情况, 二者可以用下式表示:

$$RMSE = \sqrt{\frac{1}{M} \sum_{i=1}^M (y_i - \hat{y}_i)^2}, \quad (25)$$

$$MAE = \frac{1}{M} \sum_{i=1}^M |y_i - \hat{y}_i|, \quad (26)$$

其中: y_i 代表真实值, \hat{y}_i 代表预测值, M 代表总预测样本数.

4.2 迁移学习方法对比

为了便于理解, 表2展示了本文所提方法MFTS的模型具体结构.

由于本方法首先使用源域数据训练MANN和E-KM模块, 再连接FTM模块使用目标域数据进行训练, 因此当利用目标域数据训练时MANN的解码器(表中加括号的网络层)将被去除. 此外, 本文使用的批次数量为64, 每个充放电循环均降采样至100个采样点长度, 共电压、电流和温度3个传感器, 故模型的输入为64*100*3, 最终输出64*1的SOH值预测向量. 不同方法下SOH的预测精度如表3所示, 选取了DAN, DaNN和深度域混淆(deep domain confusion, DDC)3种迁移学习方法作为对比. 并且另外选择了不进行迁移, 直接进行建模的方法同时作为对照. 为保证公平, 几种方法的特征提取器均相同, 最优结果加粗表示.

表 2 MFTS网络结构表

Table 2 MFTS network structure table

网络层	输出形状	网络结构
掩码数据	(64, 100, 3)	—
编码器-GRU	(64, 100, 200)	Dropout=0.2, 3层
编码器-GRU-全连接层	(64, 100)	节点200*100
编码器-CNN-卷积层	(64, 16, 8, 8)	卷积核3*3, 步长为1
编码器-CNN-池化层	(64, 16, 6, 6)	池化核3*3, 步长为1
编码器-CNN-卷积层	(64, 32, 4, 4)	卷积核3*3, 步长为1
编码器-CNN-池化层	(64, 32, 2, 2)	池化核3*3, 步长为1
特征层	(64, 25)	节点228*25
(EKM-全连接层)	(64, 6)	节点25*6
(解码器-GRU)	(64, 25, 300)	Dropout=0.2, 3层
(解码器-反卷积层)	(64, 3, 10, 10)	卷积核6*6, 步长为1
(解码器-全连接层)	(64, 300)	节点25*300
FTM-全连接层	(64, 1)	节点25*1

批次数=64, 迭代轮数=1000, 优化器=Adam, 学习率= 0.0001

从表3中可以看出, 在6次实验中, MFTS的预测精度RMSE最优为2.62%, 最差为4.08%, 均值为3.54%, MAE最优为2.04%, 最差为3.51%, 均值为2.94%. 其

预测结果优于其余的所有算法(最优均值为5.11%和3.96%), 并且相比较直接建模的方法精度提高一倍, 充分证明了本方法的有效性. 图5展示了不同方法在

C1→C3实验中在No.47电池上的预测效果,从图中可以看出,MFTS的预测值(紫色)和真实的SOH值(蓝色)最相近,其预测结果明显优于其余的对比算法.同时可以发现,直接建模的方式预测效果不佳,这是由于在变工况的场景下,源域和目标域的数据分布差异较大,在不进行迁移的情况下将二者合并建模会导致模型的误差增大.

表3 不同方法预测SOH精度对比

Table 3 Comparison of different methods for predicting SOH accuracy

性能指标/%	迁移方向	对比方法					
		DA N ^[25]	Da NN ^[23]	DD C ^[38]	直接建模	MF TS	
RMSE	C1→C2	3.10	3.24	3.02	4.02	3.46	
	C1→C3	4.49	3.91	4.88	7.06	2.62	
	C2→C1	6.09	6.68	7.17	10.43	4.07	
	C2→C3	4.32	6.19	4.21	8.76	3.95	
	C3→C1	8.60	8.19	8.86	11.17	4.08	
	C3→C2	4.03	4.22	3.35	3.16	3.06	
	均值	5.11	5.41	5.25	7.43	3.54	
	MAE	C1→C2	2.61	2.49	2.53	3.24	3.11
		C1→C3	3.53	2.46	3.83	4.53	2.04
		C2→C1	5.22	5.82	6.26	9.05	3.45
C2→C3		3.31	5.28	3.34	7.54	3.18	
C3→C1		5.98	5.78	6.18	8.63	3.51	
C3→C2		3.08	3.24	2.85	2.71	2.37	
均值		3.96	4.18	4.17	5.95	2.94	




图5 不同方法在C1→C3实验中在No.47电池上的预测效果

Fig. 5 The prediction effect of different methods on No.47 battery in the C1→C3 experiment

5 结论

本文针对源域数据无标签情况下的锂电池变工况SOH预测问题,创新性地提出了一种掩码表征迁移策略.MFTS中的掩码近似网络通过自动特征提取来表征源域数据,克服了源域数据标签缺失带来的训练困

难问题.专家知识模块通过引导模型提取到和专家知识近似的特征,将专家知识进行融入,帮助模型学习到专家知识中蕴含的丰富信息.最后特征迁移模块利用一种双学习率策略用目标域数据进行微调,从而实现了无监督变工况场景下锂电池SOH的精准预测.通过NASA的数据进行了实验验证,MFTS对比其他的方法均有显著的性能优越性,其在6组实验上RMSE均不大于4.08%,MAE均不大于3.51%,充分证明了MFTS中各模块的有效性和重要性.

参考文献:

- [1] ZHENG Y, OUYANG M, HAN X, et al. Investigating the error sources of the online state of charge estimation methods for lithium-ion batteries in electric vehicles. *Journal of Power Sources*, 2018, 377: 161 – 188.
- [2] MANTHIRAM A. An outlook on lithium ion battery technology. *ACS Central Science*, 2017, 3(10): 1063 – 1069.
- [3] CHEN Y, MIAO Q, ZHENG B, et al. Quantitative analysis of lithium-ion battery capacity prediction via adaptive bathtub-shaped function. *Energies*, 2013, 6(6): 3082 – 3096.
- [4] FARMANN A, WAAG W, MARONGIU A, et al. Critical review of on-board capacity estimation techniques for lithium-ion batteries in electric and hybrid electric vehicles. *Journal of Power Sources*, 2015, 281: 114 – 130.
- [5] WENG C, SUN J, PENG H. A unified open-circuit-voltage model of lithium-ion batteries for state-of-charge estimation and state-of-health monitoring. *Journal of Power Sources*, 2014, 258: 228 – 237.
- [6] LI J, ADEWUYI K, LOTFI N, et al. A single particle model with chemical/mechanical degradation physics for lithium ion battery state of health (SOH) estimation. *Applied Energy*, 2018, 212: 1178 – 1190.
- [7] LI Y, ABDEL-MONEM M, GOPALAKRISHNAN R, et al. A quick on-line state of health estimation method for Li-ion battery with incremental capacity curves processed by Gaussian filter. *Journal of Power Sources*, 2018, 373: 40 – 53.
- [8] CHEN X, ZHENG J, ZHAO C, et al. Full decoupling high-order dynamic mode decomposition for advanced static and dynamic synergistic fault detection and isolation. *IEEE Transactions on Automation Science and Engineering*, 2024, 21(1): 226 – 240.
- [9] ZHENG J, CHEN X, ZHAO C. Interval-aware probabilistic slow feature analysis for irregular dynamic process monitoring with missing data. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(10): 6553 – 6564.
- [10] JIN Jiangtao, XU Zifei, LI Chun, et al. Rolling bearing fault diagnosis based on deep learning and chaoticfeature fusion. *Control Theory & Applications*, 2022, 39(1): 109 – 116. (金江涛, 许子非, 李春, 等. 基于深度学习与混沌特征融合的滚动轴承故障诊断. *控制理论与应用*, 2022, 39(1): 109 – 116.)
- [11] SONG P, ZHAO C. Slow down to go better: A survey on slow feature analysis. *IEEE Transactions on Neural Networks and Learning Systems*, 2022, DOI: 10.1109/TNNLS.2022.3201621.
- [12] LI Tianmei, SI Xiaosheng, LIU Xiang, et al. Data-model interactive remaining useful life prediction technologies for stochastic degrading devices with big data. *Acta Automatica Sinica*, 2022, 48(9): 2119 – 2141. (李天梅, 司小胜, 刘翔, 等. 大数据下数模联动的随机退化设备剩余寿命预测技术. *自动化学报*, 2022, 48(9): 2119 – 2141.)
- [13] LIU Hui, LIU Zhenyu, JIA Weiqiang, et al. Current research and challenges of deep learning for equipment remaining useful life prediction. *Computer Integrated Manufacturing Systems*, 2021, 27(1): 34 –

52.
(刘惠, 刘振宇, 郝维强, 等. 深度学习在装备剩余使用寿命预测技术中的研究现状与挑战. 计算机集成制造系统, 2021, 27(1): 34 – 52.)
- [14] LIU Xiaofeng, SHI Changzhen, HUANG Hongsheng, et al. Aero-engine failure threshold setting based on enhanced health index similarity. *Control Theory & Applications*, 2022, 39(5): 830 – 836.
(刘小峰, 史长振, 黄洪升, 等. 基于强化健康指数相似度量的航空发动机失效阈值设置. 控制理论与应用, 2022, 39(5): 830 – 836.)
- [15] PENG Kaixiang, PI Yanting, JIAO Ruihua, et al. Health indicator construction and remaining useful life prediction for aircraft engine. *Control Theory & Applications*, 2020, 37(4): 713 – 720.
(彭开香, 皮彦婷, 焦瑞华, 等. 航空发动机的健康指标构建与剩余寿命预测. 控制理论与应用, 2020, 37(4): 713 – 720.)
- [16] WANG Yihang, FENG Liangjun, ZHAO Chunhui. Lithium battery two-dimensional region of support transductive learning method and state of health prediction oriented to few charge-discharge cycles. *Control Theory & Applications*, 2024, DOI: 10.7641/CTA.2023.20408.
(王一航, 冯良骏, 赵春晖. 面向锂电池少量循环的二维支持域直推式健康状态预测. 控制理论与应用, 2024, DOI: 10.7641/CTA.2023.20408.)
- [17] LI Y, ZOU C, BERECIBAR M, et al. Random forest regression for online capacity estimation of lithium-ion batteries. *Applied Energy*, 2018, 232: 197 – 210.
- [18] SHEN S, SADOUGHI M, CHEN X, et al. A deep learning method for online capacity estimation of lithium-ion batteries. *Journal of Energy Storage*, 2019, 25: 100817.
- [19] LI P, ZHANG Z, XIONG Q, et al. State-of-health estimation and remaining useful life prediction for the lithium-ion battery based on a variant long short term memory neural network. *Journal of Power Sources*, 2020, 459: 228069.
- [20] CHAI Z, ZHAO C, HUANG B, et al. A deep probabilistic transfer learning framework for soft sensor modeling with missing data. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 33(12): 7598 – 7609.
- [21] CHAI Z, ZHAO C, HUANG B. Variational progressive-transfer network for soft sensing of multirate industrial processes. *IEEE Transactions on Cybernetics*, 2021, 52(12): 12882 – 12892.
- [22] CHAI Zheng, WANG Jiaye, ZHAO Chunhui, et al. Deep transfer learning methods for typical supervised tasks in industrial monitoring: State-of-the-arts, challenges, and perspectives. *Scientia Sinica Informationis*, 2023, 53(5): 821 – 840.
(柴铮, 汪嘉业, 赵春晖, 等. 面向工业监控典型监督任务的深度迁移学习方法: 现状、挑战与展望. 中国科学: 信息科学, 2023, 53(5): 821 – 840.)
- [23] GHIFARY M, KLEIJN W B, ZHANG M. Domain adaptive neural networks for object recognition. *Pacific Rim International Conference on Artificial Intelligence (PRICAI)*. Gold Coast, QLD, Australia: Springer, 2014: 898 – 904.
- [24] SUN B, SAENKO K. Deep coral: Correlation alignment for deep domain adaptation. *European Conference on Computer Vision (ECCV)*. Amsterdam, Netherlands: Springer, 2016: 443 – 450.
- [25] LONG M, CAO Y, WANG J, et al. Learning transferable features with deep adaptation networks. *International Conference on Machine Learning (ICML)*. Lille France: PMLR, 2015: 97 – 105.
- [26] CHAI Z, ZHAO C. Fault-prototypical adapted network for cross-domain industrial intelligent diagnosis. *IEEE Transactions on Automation Science and Engineering*, 2022, 19(4): 3649 – 3658.
- [27] CHAI Z, ZHAO C, HUANG B. Multisource-refined transfer network for industrial fault diagnosis under domain and category inconsistencies. *IEEE Transactions on Cybernetics*, 2022, 52(9): 9784 – 9796.
- [28] TAN Y, ZHAO G. Transfer learning with long short-term memory network for state-of-health prediction of lithium-ion batteries. *IEEE Transactions on Industrial Electronics*, 2019, 67(10): 8723 – 8731.
- [29] YE Z, YU J. State-of-health estimation for lithium-ion batteries using domain adversarial transfer learning. *IEEE Transactions on Power Electronics*, 2021, 37(3): 3528 – 3543.
- [30] LECUN Y, BENGIO Y, HINTON G. Deep learning. *Nature*, 2015, 521(7553): 436 – 444.
- [31] WAIBEL A, HANAZAWA T, HINTON G, et al. Phoneme recognition using time-delay neural networks. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 1989, 37(3): 328 – 339.
- [32] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation. *ArXiv Preprint*, 2014, arXiv: 1406.1078.
- [33] LI X, JIANG J, CHEN D, et al. A capacity model based on charging process for state of health estimation of lithium ion batteries. *Applied Energy*, 2016, 177: 537 – 543.
- [34] RAWAT W, WANG Z. Deep convolutional neural networks for image classification: A comprehensive review. *Neural Computation*, 2017, 29(9): 2352 – 2449.
- [35] LI X, JIANG J, CHEN D, et al. A capacity model based on charging process for state of health estimation of lithium ion batteries. *Applied Energy*, 2016, 177: 537 – 543.
- [36] KUMAR A, RAGHUNATHAN A, JONES R, et al. Fine-tuning can distort pretrained features and underperform out-of-distribution. *ArXiv Preprint*, 2022, arXiv: 2202.10054.
- [37] SAHA B, GOEBEL K, POLL S, et al. Prognostics methods for battery health monitoring using a Bayesian framework. *IEEE Transactions on instrumentation and measurement*, 2008, 58(2): 291 – 296.
- [38] TZENG E, HOFFMAN J, ZHANG N, et al. Deep domain confusion: Maximizing for domain invariance. *ArXiv Preprint*, 2014, arXiv: 1412.3474.

作者简介:

王一航 硕士研究生, 目前研究方向为锂离子电池少量数据的健康状态预测、迁移学习, E-mail: wangyihang@zju.edu.cn;

陈旭 博士研究生, 目前研究方向为数据驱动的工业过程监测、故障诊断, E-mail: 3160102260@zju.edu.cn;

沈萌 本科生, 目前研究方向为振动信号故障诊断、迁移学习, E-mail: 3200103582@zju.edu.cn;

赵春晖 教授, 目前研究方向为机器学习、工业大数据解析与应用, E-mail: chhzha@zju.edu.cn.