

采用迁移学习的小样本锂电池荷电状态估算方法

李龙^{1,2}, 燕旭朦³, 张钰声¹, 冯雅琳¹, 胡红利², 段羽洁², 崔晨辉²

(1. 国网陕西省电力有限公司电力科学研究院, 西安, 710199;

2. 西安交通大学电气工程学院, 710049, 西安; 3. 国网西安高新供电公司, 710076, 西安)

摘要: 针对锂电池荷电状态(SOC)估算面临的大型数据集获取困难和训练速度慢的问题, 结合深度学习和迁移学习提出一种小样本锂电池荷电状态估算方法。基于卷积-长短期记忆网络(CNN-LSTM)构建深度神经网络结构。在源域上采用 K 折交叉验证对 NASA 数据集进行划分, 选取 SOC 估计性能最优的网络, 利用目标域内具有多种工况和温度条件的 Panasonic 小样本数据进行迁移学习。为了提升方法的整体性能, 分析了网络超参数对 SOC 估计结果的影响。实验结果表明: 在相同的迭代次数下, 该方法在不同的工况下可以较准确地实现小样本电池 SOC 估计, 相较于非小样本迁移学习处理方法的均方根误差降低了 47.29%。

关键词: 电池荷电状态; 迁移学习; 小样本训练; K 折交叉验证

中图分类号: TM912 **文献标志码:** A

DOI: 10.7652/xjtuxb202311014 **文章编号:** 0253-987X(2023)11-0142-09

Lithium Battery State of Charge Estimation Method Based on Transfer Learning

LI Long^{1,2}, YAN Xumeng³, ZHANG Yusheng¹, FENG Yalin¹, HU Hongli²,

DUAN Yujie², CUI Chenhui²

(1. State Grid Shaanxi Electric Power Research Institute, Xi'an 710199, China; 2. School of Electrical Engineering,

Xi'an Jiaotong University, Xi'an 710049, China; 3. State Grid Xi'an High-Tech Power Supply Company,

Xi'an 710076, China)

Abstract: Aiming at the difficulty of obtaining large data sets and the slow training speed of lithium battery state of charge estimation, a small sample lithium battery state of charge estimation method is proposed by combining deep learning and transfer learning. A deep neural network is constructed based on the convolution-long and short term memory network (CNN-LSTM). In the source domain, K -fold cross-validation is used to divide the NASA data set, select the network with the best SOC estimation performance, and then transfer learning is carried out to Panasonic small data with different temperatures and working conditions in the target domain. In order to improve the overall performance, the influence of network hyperparameters on SOC estimation results is discussed. Compared to non-few-shot transfer learning, the error of this method is reduced by 47.29% under the same epoch.

Keywords: battery state of charge; transfer learning; insufficient samples training; K -fold cross validation

锂电池因其较高的储能密度、功率容限和较低的成本受到了人们的广泛关注,目前已广泛应用于消费电子、动力系统与大规模储能系统中^[1]。电池荷电状态(state of charge, SOC)是锂电池循环过程中的重要参数,表征了电池在充放电循环中的剩余容量^[2]。SOC的准确估计至关重要,其对电动汽车的可靠行驶、储能系统的状态估计与决策都有重要的意义^[3]。

SOC 值随着充放电循环变化,并且受到温度、电池老化等情况的影响^[4],无法直接用传感器测量。目前,常用的 SOC 估算方法有基于电化学模型的方法、安时积分法、开路电压法、卡尔曼滤波族法、数据驱动法等。电化学模型法研究锂离子电池内部电化学反应动力学,从运行机理方面描述电池的充放电状态^[5-7]。电化学模型状态估计准确,但是计算量大且应用过程复杂。安时积分法直接对充放电循环曲线进行积分,得到电池的 SOC 值,但该方法存在初始 SOC 不确定、电流传感器温度漂移等问题,随着电池循环,测量的累积误差会不断增大。开路电压法需要将电池开路静置^[3,8],不能对 SOC 进行在线估算。卡尔曼滤波族法^[7,9-13]依赖于建立的电路等效模型的准确性,对真实世界中多样的电池类型与工况的自适应性较弱。针对上述方法存在的问题,研究人员做出了一定的改进。文献[8]利用实验和数学模型修正锂离子电池端电压,使开路电压法得以应用于在线 SOC 估算。文献[5]构建了一种能反映电池退化的降阶电化学模型,结合双非线性滤波器实现电池 SOC 和健康状态(state of health, SOH)的估计。文献[14]提出了一种变阶 RC 模型的多模模型,更好地反映锂离子电池的动态非线性特性。随着机器学习的发展,基于数据驱动的方法展现了卓越的性能,机器学习能够挖掘在电池充放电循环实验中获得的历史数据,从运行数据中获取启发性知识与特征。传统的机器学习方法^[15],例如贝叶斯和支持向量机等已经被用于电池 SOC 的估计任务中,这些方法直接学习可观测量与 SOC 之间的映射关系。深度学习能够捕捉全局特征与上下文信息,自动提取深层次的数据特征,在图像识别、序列信息处理等任务中较传统方法性能更佳^[16]。文献[17]基于一种循环神经网络对电池的剩余使用寿命进行预测,在一定电流密度下,预测结果误差较小。文献[18]利用长短期记忆神经网络(long short-term memory, LSTM)的长时记忆特性,将阶段 SOH 均值引入 SOC 的估算中实现联合估算,提高了 SOC 的估计精度。

为保证模型准确性,深度学习依赖于大数据集的训练,这一点在使用深度学习方法的 SOC 估计研究中得以体现^[19-21],但该方式的缺点却往往较少提及。首先,大型数据集的获取是一个长期和高成本的过程。例如,电池数据集有各种实验工况,如恒压恒流充放电工况、美国城市道路循环工况(UDDS)、联邦城市运行工况(FUDS)等,在进行 SOC 估计时,研究者往往获得带有噪声的小样本数据,这就使得深度学习训练得到的网络的适应性与泛化性能较差^[3,6]。针对上述问题,本文设计出一种深度学习与迁移学习结合的方法,通过深度学习自动提取深层次特征的能力以及迁移学习获取不同领域知识的特性,实现对小样本数据的 SOC 估计,具有更快的训练速度和更好的泛化性能。

1 SOC 估计方法

1.1 SOC 估计方法总览

本文所提出的 SOC 估计方法如图 1 所示。首先需要对网络进行配置,包括网络结构以及网络参数的设置;然后通过 K 折交叉验证对源数据集进行划分处理。使用配置好的网络进行 K 次训练,选择估计性能最优的网络保留其网络结构及参数。使用目标数据集进行迁移学习再训练。此外,对训练好的网络进行测试,得到误差结果。最后将提出的方法与未进行迁移学习的方法进行性能比较。




图 1 基于迁移学习的锂电池 SOC 估计方法总览
Fig.1 Overview of lithium battery SOC estimation method based on transfer learning

1.2 CNN 结构

受到人眼观察事物方式的启发,二维卷积神经网络在图像处理的任务中展现了卓越的性能。对于SOC估计任务而言,电池组的传感器数据通常是一维时间序列,例如电压、电流、温度随时间的变化,CNN可以从传感器数据中识别出简单的特征,并组合抽象为更深层次的模式,因此一维CNN适用于多传感器融合与信号处理的任務中^[19]。

一维CNN与二维CNN的区别在于卷积核的大小与卷积核滑动的方式。对卷积层的输入而言,设其为一维序列 $\mathbf{X}$ 。 $\mathbf{M}_{n-1}$ 代表网络的第 n 层的输入, $\mathbf{M}_n$ 表示第 n 层向下一层传递的值,由此,卷积层的行为可以描述如下式

$$\mathbf{M}_n = f(\mathbf{M}_{n-1} * \mathbf{W}_n + \mathbf{b}_n) \quad (1)$$

式中: $\mathbf{W}_n$ 为第 n 层卷积核的权值向量; $*$ 代表卷积操作; $\mathbf{b}_n$ 为偏移向量,通过激活函数 $f(\cdot)$ 映射出该层的输出 $\mathbf{M}_n$;池化层对输入 $\mathbf{M}_{n-1}$ 进行特征降维,并在一定程度上保持特征的尺度不变性。池化层的产生可以描述如下式

$$\mathbf{M}_n = \text{Pooling}(\mathbf{M}_{n-1}) \quad (2)$$

式中: $\text{Pooling}(\mathbf{M}_{n-1})$ 通常使用平均池化或者最大池化,在本文中,采用平均池化可减少传感器噪声对性能的影响。

1.3 LSTM 结构

LSTM是循环神经网络(recurrent neural network, RNN)的一种,均可用于解决时序问题,但是RNN存在梯度爆炸或梯度消失问题,因此不具备长期记忆功能^[17]。为了解决这一问题,LSTM引入了门控单元^[22],包括输入门、遗忘门和输出门,使用门结构实现信息一定程度的保留,达到选择性遗忘的目的,既实现了长期记忆功能,也不至于占据大量内存^[19]。每个LSTM单元如图2所示,有3个输入为:细胞状态 $\mathbf{C}_{t-1}$ 、隐层状态 $\mathbf{h}_{t-1}$ 和 t 时刻的输入向量 $\mathbf{x}_t$;有两个输出为:细胞状态 $\mathbf{C}_t$ 和隐层状态 $\mathbf{h}_t$,同时 $\mathbf{h}_t$ 作为 t 时刻的输出。 $\mathbf{C}_{t-1}$ 会参与 t 时刻输出 $\mathbf{h}_t$ 的计算, t 时刻的隐层状态 $\mathbf{h}_{t-1}$ 与输入 $\mathbf{x}_t$ 也会对 $\mathbf{C}_t$ 进行适当修改,传到下一时刻。具体的计算公式如下

$$\mathbf{f}_t = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (3)$$

$$\mathbf{i}_t = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (4)$$

$$\tilde{\mathbf{C}}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c) \quad (5)$$

$$\mathbf{C}_t = \mathbf{f}_t \mathbf{C}_{t-1} + \mathbf{i}_t \tilde{\mathbf{C}}_t \quad (6)$$

$$\mathbf{o}_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (7)$$

$$\mathbf{h}_t = \mathbf{o}_t \tanh(\mathbf{C}_t) \quad (8)$$

其中: σ 与 $\tanh$ 均是激活函数, $[\mathbf{h}_{t-1}, \mathbf{x}_t]$ 代表将 $\mathbf{h}_{t-1}$

和 $\mathbf{x}_t$ 两个向量连接起来; $\mathbf{f}_t$ 为 t 时刻遗忘门的状态; $\mathbf{W}_f$ 为遗忘门的权重向量; $\mathbf{b}_f$ 为遗忘门的偏置向量; $\mathbf{i}_t$ 为 t 时刻输入门的状态; $\mathbf{W}_i$ 为输入门的权重向量; $\mathbf{b}_i$ 为输入门的偏置向量; $\tilde{\mathbf{C}}_t$ 为细胞的中间状态; $\mathbf{W}_c$ 为中间状态的权重向量; $\mathbf{b}_c$ 为中间状态的偏置向量; $\mathbf{o}_t$ 为 t 时刻输出门的状态; $\mathbf{W}_o$ 为输出门的权重向量; $\mathbf{b}_o$ 为输出门的偏置向量; $\mathbf{C}_t$ 为细胞状态的输出; $\mathbf{h}_t$ 为LSTM单元的总输出。




图2 LSTM 神经元结构

Fig. 2 LSTM neuron structure

1.4 迁移学习

研究者们采用一种方式在现实世界中使用机器学习模型:即在训练集验证了构建模型的可行性后,使用收集到的新数据重构网络以保证模型的准确性,因为收集到的新样本可能与训练数据特征并不完全相似。

与传统机器学习相比深度学习性能更卓越,但是也面临着上述问题。更进一步地,深度学习训练阶段依赖于大型数据集,使用小样本容易导致模型训练不充分或者直接过拟合。实验数据通常是在实验室对电池进行循环充放电等实验中采集得到的,需要付出大量的人力物力资源。现实采集到的电池运行数据具有小样本特征,存在非平稳放电、受噪声干扰等问题。目前急需解决的是目标数据与源数据特征分布不完全相同的问题和小样本训练导致性能退化的问题。

迁移学习通俗来讲就是学习知识之间的相似性,利用旧知识来完成新任务的方法^[23]。迁移学习涉及领域和任务两个概念。领域 D 定义为由 d 维特征空间 R 和边缘概率分布 $P(x)$ 组成, $D = \{X, P(x)\}$,任务 $T = \{Y, f(x)\}$,其中 Y 代表标签空间, $f(x)$ 代表回归模型。迁移学习可定义为:给定源任务 D_s 和 T_s ,新的目标任务中,在 $D_s \neq D_T$ 或 $T_s \neq T_T$ 条件下学习源域与目标域知识的相似性^[24],提高目标域回归模型 $f_T(x)$ 的泛化性能^[25]。

不同的锂电池虽然型号与运行环境不同,但是其工作原理类似,其电参数和温度所反映的电池信息特征分布具有一定的相似性,本文针对上文提到的两点问题,构建一种结合深度学习与迁移学习的电池 SOC 估计方法,自动提取迁移学习源域与目标域相似的特征分布,有效增强目标域与小样本学习的模型适应能力。

1.5 重采样

在迁移学习过程中,研究者时常遇到目标域与源域样本空间不同的问题,可分为输入维度不同与输入序列属性不同。本文的 SOC 预测方法中,对于输入维度不同的问题,采取电池端电压、电流与温度 3 个实际锂电池应用中普遍存在的物理量作为输入。对于输入序列属性不同的问题,本文关注系统采样率差异导致的机器学习在实际应用中适应性差的问题。对于采样率差异的问题,本文采取对目标域样本空间进行重采样的方式。对于目标域采样率较低的情况,采取插值后升采样的方式;对于目标域采样率较高的情形,采用先滤波后抽取的方法进行降采样。

2 实验过程

2.1 数据预处理

本实验中源数据采用 NASA 锂电池数据集,目标数据采用 Panasonic 锂电池实验数据集,本文将 SOC 值记作 S_{oc} 。源数据包含了 6 组共 22 块锂电池的放电循环,每个放电循环的 S_{oc} 均从 100% 开始放电,总计 2 016 个样本。该锂电池额定容量均为 2 A·h,该电池数据集有 4 种工作温度条件,包括 4℃、24℃、43℃、混合温度;每组电池的放电方式均不相同,有 2 A、4 A 恒流放电、方波放电、分段恒流放电等放电方式,每个放电循环持续时间取决于放电方式,持续 10~70 min。由于该数据集的多样性以及样本量充足,所以具备作为迁移学习中源数据的条件。目标数据是 Phillip Kollmeyer 博士实验所得 Panasonic 18650PF 电池数据集,该数据集是额定容量为 2.9 A·h 的全新 Panasonic 18650PF 电池在 5 种不同温度下进行的多工况测试得到,温度范围为 -20℃~25℃,测试驱动循环共 9 种,包括 US06、HWFET、UDDS、LA92、NN 以及由这 5 种驱动循环随机组合的混合驱动循环,其中 NN 驱动循环由 US06 和 LA92 驱动循环组合而成。目标数据集样本数较少,共有 46 个放电循环,选取 UDDS、LA92、NN 工况下获得的实验数据作为测试数据,其余数据为训

练数据。

由于源数据集放电循环采样率为 0.1 Hz,而目标数据集放电循环采样率为 10 Hz,因此为了统一源域与目标域的样本空间,将目标数据集放电循环进行了降采样,即每 100 个数据点取平均值,步长为 100。该方法既可以使目标数据用于迁移学习,也可以对高频噪声进行滤除。

本文选用放电电压、放电电流、电池温度作为模型的输入特征,电池的 S_{oc} 作为模型的目标输出,由于 NASA 数据未直接给出相应时刻的 S_{oc} ,本文采用安时积分法计算得出的 S_{oc} 作为目标输出。为消除各变量之间的量值大小差异的影响,本文对所有输入输出数据进行了最大-最小的标准化处理,表达式如下

$$\tilde{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{9}$$

式中: x 为标准化处理前的输入; $\tilde{x}$ 为标准化处理后的输入; $x_{\max}$ 是某一输入变量 x 的最大值,和 $x_{\min}$ 是某一输入变量 x 的最小值,处理后的数据均在 $[0, 1]$ 范围内。

2.2 预训练

2.2.1 K 折交叉验证

K 折交叉验证如图 3 所示,在预训练中,源数据集被随机分为 K 个相互排斥的数据子集,将这种数据子集称作折叠,然后进行 K 次模型训练,每次训练中,保留一个数据折叠作为测试数据,其余 K - 1 个折叠作为训练数据,K 次训练均保留不同的折叠。K 次模型训练结束后,选取测试集估计误差最小的模型,保留其网络结构和参数进行迁移学习。





图 3 K 折交叉验证
Fig. 3 K-fold cross validation

2.2.2 CNN-LSTM 网络模型

论文所构建的网络为 CNN-LSTM 神经网络,模型包括两层卷积层、两层池化层、一层 LSTM 层和两层全连接层,输入为时间序列数据,每层卷积层后连接平均池化层进行特征降维,而后通过卷积层

挖掘数据间的关系,再利用 LSTM 的记忆功能对数据进行选择性记忆得到关键特征,最后用全连接层

进行特征关联,得出对应的 S_{OC} 。具体网络结构如图 4 所示。具体网络结构配置参数见表 1。



橙色—卷积层;灰色—池化层;绿色—LSTM 层;浅蓝色—全连接层。

图 4 CNN-LSTM 神经网络模型

Fig. 4 CNN-LSTM neural network model

表 1 CNN-LSTM 神经网络结构配置参数
Table 1 CNN-LSTM neural network structure parameters

网络层	滤波器大小	滤波器数	步长	权重数	偏置数
序列输入	3				
卷积层 1	3	32	1	$3 \times 3 \times 32$	1×32
平均池化层 1	3	32	1		
卷积层 2	3	64	1	$3 \times 32 \times 64$	1×64
平均池化层 2	3	64	1		
LSTM		64		$256 \times 64 \times 2$	256×1
全连接层 1	256			256×64	256×1
全连接层 2	128			128×256	128×1
输出层	1			1×128	1×1

表 1 为训练模型所采取的网络结构,输入层为序列输入,具有 3 个通道,紧接着为两个卷积与平均池化层,然后是两个全连接层,最后是一个输出层,网络中的激活函数除输出层外均使用 Leaky-Relu 函数,输出层采用 Relu 函数。超参数的选取见表 2,由于预训练和再训练的训练样本数差距较大,因此迭代样本数选取不同。由于再训练是建立在预训练的基础上,各学习参数不需要较大变动,因此再训练的初始学习率设置得更小,学习率下降周期更长,


且迁移学习从预训练中已经学到部分数据特征,进一步缩减再训练的迭代轮次,减少训练时间。

表 2 超参数的选取
Table 2 Hyperparameter selection


参数	预训练	再训练
迭代样本数	128	6
初始学习率	0.010	0.001
学习率下降因子	0.85	0.60
学习率下降周期	25	90
L_2 正则化参数	0.01	0.01
迭代轮数	1 000	500

2.2.3 训练结果

将 CNN-LSTM 神经网络利用源数据集预训练后,随机选取了测试集中 $0\text{ }^{\circ}\text{C}$ 下 US06 工况样本进行 SOC 估计。图 5(b)中均方根误差 E_{RMSE} 为 2.86% ,估计误差峰值的绝对值即为最大误差 E_{MAX} ,其值为 6.36% 。结果说明预训练后的 CNN-LSTM 神经网络能够实现电池 S_{OC} 的准确估计。



(a) S_{OC} 观测曲线和估计曲线对比



(b) S_{OC} 估计误差曲线

图 5 预训练后的 CNN-LSTM 神经网络 S_{OC} 估计结果
Fig. 5 Pre-trained CNN-LSTM neural network model test case S_{OC} prediction curve under US06 condition at 0 °C

2.3 迁移学习

图 6 是选取表 2 中再训练的超参数进行迁移学习后的估计结果,该结果是测试集中 0 °C 下 LA92 工况的估计结果。其 E_{RMSE} 为 1.37%, E_{MAX} 为 4.99%,估计曲线基本贴合观测曲线,估计效果较优。图 7(a)展示的是均方根误差 E_{RMSE} 、平均绝对误差 E_{MA} 、 E_{MAX} 随温度变化的柱状图,可以看出迁移学习后的网络对于低温的 S_{OC} 估计效果更好;图 7 (b)是测试集误差 E_{RMSE} 、 E_{MA} 、 E_{MAX} 对应不同工况的柱状图,表明迁移学习后的网络对不同工况测试样本的适应性强。






图 6 迁移学习 0 °C 下 LA92 工况的 S_{OC} 估计曲线
Fig. 6 Transfer learning S_{OC} prediction curve under LA92 condition at 0 °C



(a) 不同温度条件



(b) 不同测试样本工况


图 7 不同温度及工况条件下的测试样本估计误差
Fig. 7 Prediction errors of test samples under different conditions and different temperature

3 迁移学习前后的 CNN-LSTM 网络性能比较


3.1 未进行迁移学习的 CNN-LSTM 网络

未进行迁移学习的方法分为直接用预训练好的模型估计和用网络模型直接训练两种。直接用预训练好的模型对 Panasonic 电池测试数据集进行测试,估计效果较差,因为训练数据和测试数据跨越了电池型号,所以只能学习到放电时 S_{OC} 衰减的趋势,估计准确度非常差,其 E_{RMSE} 为 30.5%, E_{MAX} 为 42.65%。用预训练的网络模型直接对目标数据集进行训练可以达到较好的效果,其 E_{RMSE} 为 3.92%, E_{MAX} 为 14.33%。相对于用网络模型直接训练而言,在效果相近的情况下迁移学习训练次数更少。

未进行迁移学习的 CNN-LSTM 网络的超参数选取表 2 中再训练的参数,其中初始学习率设置为 0.01,增强网络的学习能力,避免陷入局部极小的情况。从图 8 中可以看出,同样的超参数选取情况下,网络直接训练的估计效果不如迁移学习。



(a) 直接测试的测试样本估计误差



(b)用网络模型直接训练的测试样本估计误差

图 8 不进行迁移学习 0 °C 下 LA92 工况 S_{OC} 估计曲线

Fig. 8 S_{OC} prediction curve under LA92 condition at 0 °C without transfer learning

迁移学习、直接用模型进行训练、直接用预训练估计 3 种方法的测试结果如图 9 所示。分别对 CNN-LSTM 网络进行 10 次迁移学习和直接训练,每次训练的训练轮次 E_{poch} 设为 500,最后用 10 次训练所得的 E_{RMSE} 平均值作为上述 3 种方法的误差评价指标。此时直接训练的 $\bar{E}_{RMSE}$ 为 6.887 8%,本文提出方法的 $\bar{E}_{RMSE}$ 为 3.630 3%,在 $\bar{E}_{poch}$ 为 500 时迁移学习的 $\bar{E}_{RMSE}$ 相比直接训练的 $\bar{E}_{RMSE}$ 下降了 47.29%。




图 9 3 种方法测试集的平均误差对比

Fig. 9 Comparison of three methods test set prediction average errors

3.2 迁移学习中超参数的影响

图 10 为迁移学习与使用网络直接训练两种方法的均方根误差 $\bar{E}_{RMSE}$ 随 E_{poch} 的变化曲线,由图 10 可以看出,迁移学习 E_{poch} 为 500 时的 $\bar{E}_{RMSE}$ 低于直接训练 E_{poch} 为 5 000 时的 $\bar{E}_{RMSE}$,采用迁移学习可以较快地达到比较低的 $\bar{E}_{RMSE}$ 。训练轮次为 5 000 时两种方法均已收敛,此时直接训练的 $\bar{E}_{RMSE}$ 为 3.073 5%,迁移学习的 $\bar{E}_{RMSE}$ 为 1.533 8%,本文所提方法的 $\bar{E}_{RMSE}$ 相比直接训练的 $\bar{E}_{RMSE}$ 降低了 50.10%,与 E_{poch} 为 500 时 $\bar{E}_{RMSE}$ 的降低效果接近。





图 10 迁移学习随训练轮次的误差变化曲线


Fig. 10 Curves of transfer learning error with Epoch

图 11(a)为迁移学习测试集的 $\bar{E}_{RMSE}$ 随初始学习率的变化曲线,其中每一条曲线对应一个 L_2 正则化参数取值。随着初始学习率的增加, $\bar{E}_{RMSE}$ 总体呈增大趋势,在初始学习率为 0.003 之前涨幅最为明显,之后较为平缓;随着 L_2 正则化参数的增大, $\bar{E}_{RMSE}$ 也随之增大,在 L_2 正则化参数大于 0.03 后涨幅缓慢, L_2 正则化参数取 0.01 时 E_{RMSE} 最小。

图 11(b)为迁移学习测试集的 $\bar{E}_{RMSE}$ 随学习率降落因子的变化曲线,其中每一条曲线对应一个学习率降落周期取值。总体上讲, $\bar{E}_{RMSE}$ 曲线随着学习率降落因子的增加呈低谷趋势,低谷区间为学习率降落因子取值在 0.5~0.7 之间。学习率降落周期取 90,学习率降落因子小于 0.5 时, $\bar{E}_{RMSE}$ 随着学习率降落因子的增加而降低;学习率降落因子大于 0.5 时, $\bar{E}_{RMSE}$ 随着学习率降落因子的增加而增大。随着学习率降落周期的增长, $\bar{E}_{RMSE}$ 总体呈先增加后减小的趋势,学习率降落周期为 90 时, $\bar{E}_{RMSE}$ 曲线整体数值更小、更加稳定。



(a)估计误差随 L_2 正则化参数变化的曲线



(b)估计误差随学习率降落因子变化的曲线

图 11 估计误差随超参数的变化曲线

Fig. 11 Curves of error with hyperparameters

4 结 论

针对电池 SOC 估计面临的采集数据碎片化和小样本问题,本文借助深度学习自动提取深层次特征和迁移学习提取源领域与目标领域相似知识的能力,提出了一种基于迁移学习与深度学习的锂电池 SOC 估算方法,设计了基于 CNN-LSTM 的深度神经网络模型,并进行迁移学习。在训练轮次为 500 的情况下,经迁移学习的预测模型与直接训练的预测模型相比,均方根误差下降了 47.29%。此外,本文还研究了超参数对迁移学习结果的影响,结果表明在选取合适的超参数的情况下,所提方法比直接训练收敛更快,准确率更高。并且该方法在不同温度、跨工况条件下,能够实现小样本数据 SOC 估计的任务,相较于传统深度学习方法具有更强的适应性,更快的训练速度和泛化性能。

参考文献:

[1] PLETT G L. Extended Kalman filtering for battery management systems of LiPB-based HEV battery packs: part 2 modeling and identification [J]. Journal of Power Sources, 2004, 134(2): 262-276.

[2] 麻友良,陈全世,齐占宁. 电动汽车用电池 SOC 定义与检测方法 [J]. 清华大学学报(自然科学版), 2001, 41(11): 95-97, 105.

MA Youliang, CHEN Quanshi, QI Zhanning. Research on the SOC definition and measurement method of batteries used in EVs [J]. Journal of Tsinghua University(Science and Technology), 2001, 41(11): 95-97, 105.

[3] WANG Yujie, TIAN Jiaqiang, SUN Zhendong, et al.

A comprehensive review of battery modeling and state estimation approaches for advanced battery management systems [J]. Renewable and Sustainable Energy Reviews, 2020, 131: 110015.

[4] 鲁伟,续丹,杨晴霞,等. 锂电池分数阶建模与荷电状态研究 [J]. 西安交通大学学报, 2017, 51(7): 124-129.

LU Wei, XU Dan, YANG Qingxia, et al. Fractional model and state-of-charge of lithium battery [J]. Journal of Xi'an Jiaotong University, 2017, 51(7): 124-129.

[5] GAO Yizhao, LIU Kailong, ZHU Chong, et al. Co-estimation of state-of-charge and state-of-health for lithium-ion batteries using an enhanced electrochemical model [J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 2684-2696.

[6] 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.

[7] 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.

[8] 靳博文,潘天红,陈山. 基于稳态开路电压的锂离子电池使用程度估算 [J]. 电池, 2019, 49(6): 473-476.

JIN Bowen, PAN Tianhong, CHEN Shan. SOU estimation for li-ion battery based on steady-state open circuit voltage [J]. Battery Bimonthly, 2019, 49(6): 473-476.

[9] 丁羿茗,吕瑞强,蒋超. 基于 EKF 算法的神经网络估算锂电池 SOC [J]. 电源技术, 2021, 45(10): 1260-1263.

DING Yiming, LÜ Ruiqiang, JIANG Chao. Estimation of lithium battery SOC based on EKF neural network [J]. Chinese Journal of Power Sources, 2021, 45(10): 1260-1263.

[10] 程泽,杨磊,孙幸勉. 基于自适应平方根无迹卡尔曼滤波算法的锂离子电池 SOC 和 SOH 估计 [J]. 中国电机工程学报, 2018, 38(8): 2384-2393.

CHENG Ze, YANG Lei, SUN Xingmian. State of charge and state of health estimation of li-ion batteries based on adaptive square-root unscented Kalman filters [J]. Proceedings of the CSEE, 2018, 38(8): 2384-2393.

[11] 赵云飞,徐俊,王霄,等. 双自适应衰减卡尔曼滤波锂电池荷电状态估计 [J]. 西安交通大学学报, 2018, 52(12): 99-105.

- ZHAO Yunfei, XU Jun, WANG Xiao, et al. An estimation method for state of charge of lithium-ion batteries using dual adaptive fading extended Kalman filter [J]. Journal of Xi'an Jiaotong University, 2018, 52(12): 99-105.
- [12] 王霄, 徐俊, 曹秉刚, 等. 小波降噪卡尔曼滤波锂电池荷电状态估计 [J]. 西安交通大学学报, 2017, 51(10): 71-76.
- WANG Xiao, XU Jun, CAO Binggang, et al. A Kalman filter SOC estimation method for lithium-ion batteries based on discrete wavelet transform denoising [J]. Journal of Xi'an Jiaotong University, 2017, 51(10): 71-76.
- [13] 杨帆, 和嘉睿, 陆鸣, 等. 基于 BP-UKF 算法的锂离子电池 SOC 估计 [J]. 储能科学与技术, 2023, 12(2): 552-559.
- YANG Fan, HE Jiarui, LU Ming, et al. SOC estimation of lithium-ion batteries based on BP-UKF algorithm [J]. Energy Storage Science and Technology, 2023, 12(2): 552-559.
- [14] 李凌峰, 宫明辉, 乌江. 采用多模模型的锂离子电池荷电状态联合估计算法 [J]. 西安交通大学学报, 2021, 55(1): 78-85.
- LI Lingfeng, GONG Minghui, WU Jiang. Joint estimation algorithm for state of charge of li-ion battery with multi-mode model [J]. Journal of Xi'an Jiaotong University, 2021, 55(1): 78-85.
- [15] 陈颖, 黄凯, 丁恒, 等. 基于子种群自适应思维进化-BP 神经网络的锂离子电池 SOC 估计 [J]. 电源学报, 2022, 20(4): 92-101.
- CHEN Ying, HUANG Kai, DING Heng, et al. State-of-charge estimation of lithium-ion battery based on subpopulation adaptive mind evolutionary algorithm-bp neural network [J]. Journal of Power Supply, 2022, 20(4): 92-101.
- [16] 徐帅, 刘雨辰, 周飞. 基于 RNN 的锂离子电池 SOC 估算研究进展 [J]. 电源技术, 2021, 45(2): 263-269.
- XU Shuai, LIU Yuchen, ZHOU Fei. Research progress of SOC estimation of lithium ion batteries based on RNN [J]. Chinese Journal of Power Sources, 2021, 45(2): 263-269.
- [17] 欧明阳, 杨代军, 张存满. 基于循环神经网络的 PEMFC 寿命预测 [J]. 电池, 2020, 50(2): 123-126.
- OU Mingyang, YANG Daijun, ZHANG Cunman. Life prediction of PEMFC based on recurrent neural network [J]. Battery Bimonthly, 2020, 50(2): 123-126.
- [18] 尹春杰, 王亚男, 李鹏飞, 等. 基于 LSTM 的储能蓄电池 SOC 与 SOH 联合在线估计 [J]. 电源技术, 2022, 46(5): 541-544.
- YIN Chunjie, WANG Yanan, LI Pengfei, et al. Joint online estimation of SOC and SOH of energy storage battery pack based on LSTM [J]. Chinese Journal of Power Sources, 2022, 46(5): 541-544.
- [19] 张师涛, 蒋品群, 宋树祥, 等. 基于注意力机制和 CNN-LSTM 融合模型的锂电池 SOC 预测 [J/OL]. 电源学报[2023-05-19]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20220222.1322.005.html>.
- ZHANG Shuitao, JIANG Pinqun, SONG Shuxiang, et al. SOC prediction for lithium battery based on the fusion model of attention mechanism and CNN-LSTM [J/OL]. Journal of Power Supply[2023-05-19]. <http://kns.cnki.net/kcms/detail/12.1420.TM.20220222.1322.005.html>.
- [20] 李超然, 肖飞, 樊亚翔, 等. 基于深度学习的锂离子电池 SOC 和 SOH 联合估算 [J]. 中国电机工程学报, 2021, 41(2): 681-691, 27.
- LI Chaoran, XIAO Fei, FAN Yaxiang, et al. Joint estimation of the state of charge and the state of health based on deep learning for lithium-ion batteries [J]. Proceedings of the CSEE, 2021, 41(2): 681-691, 27.
- [21] SHEN Sheng, SADOUGH M, CHEN Xiangyi, et al. A deep learning method for online capacity estimation of lithium-ion batteries [J]. Journal of Energy Storage, 2019, 25: 100817.
- [22] 陈继斌, 李雯雯, 孙彦玺, 等. 基于卷积-双向长短期记忆网络的电池 SOC 预测 [J]. 电源技术, 2022, 46(5): 532-535.
- CHEN Jibin, LI Wenwen, SUN Yanxi, et al. Battery SOC prediction based on convolution bidirectional long term and short term memory network [J]. Chinese Journal of Power Sources, 2022, 46(5): 532-535.
- [23] SHEN Sheng, SADOUGH M, LI Meng, et al. Deep convolutional neural networks with ensemble learning and transfer learning for capacity estimation of lithium-ion batteries [J]. Applied Energy, 2020, 260: 114296.
- [24] PAN S J, YANG Qiang. A survey on transfer learning [J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345-1359.
- [25] 赵凯琳, 靳小龙, 王元卓. 小样本学习研究综述 [J]. 软件学报, 2021, 32(2): 349-369.
- ZHAO Kailin, JIN Xiaolong, WANG Yuanzhuo. Survey on few-shot learning [J]. Journal of Software, 2021, 32(2): 349-369.

(编辑 武红江)