

DOI:10.19651/j.cnki.emt.2312789

基于红外视频识别的锂电池健康状态快速检测^{*}

汪志成 王哲 王泽旺 赵杰 束登峰

(东华理工大学机械与电子工程学院 南昌 330013)

摘要: 针对退役动力电池梯次利用过程中对电池健康状态快速检测的需求,本文以软包磷酸铁锂电池为研究对象,提出基于红外热成像的锂电池健康状态快速检测方法。通过改变电池充电和放电电流倍率,研究不同老化程度的电池在放电过程中的温度变化情况,采集放电过程中的红外热成像视频,建立电池健康状态与红外热成像特征的对应关系,以此作为电池健康状态检测的健康因子;构建基于SlowFast-LSTM深度学习网络模型的改进型视频识别算法,对于电池健康状态0~40%、40%~50%、50%~60%、60%~70%、70%~80%、80%~100%这6种类别的识别率达到80.78%,单次电池检测时间3 min,实现电池健康状态的快速检测。

关键词: 磷酸铁锂电池;电池健康状态;视频识别;红外热成像;SlowFast

中图分类号: TP274.5; TH89 文献标识码: A 国家标准学科分类代码: 510.40

Rapid detection of lithium battery health status based on infrared video recognition

Wang Zhicheng Wang Zhe Wang Zewang Zhao Jie Shu Dengfeng

(School of Mechanical and Electronic Engineering, East China University of Technology, Nanchang 330013, China)

Abstract: To meet the demand for rapid detection of battery health status in the process of retired power battery recycling, this paper takes soft pack lithium iron phosphate batteries as the research object and proposes a rapid detection method of lithium battery health status based on infrared thermal imaging. By changing the battery charging and discharging current multipliers, the temperature changes of batteries with different aging degrees during the discharge process are studied, and the infrared thermographic video during the discharge process is collected to establish the correspondence between the battery health state and the infrared thermographic features, which is used as the health factor for battery health state detection; an improved video recognition algorithm based on SlowFast-LSTM deep learning network model is constructed for battery health state detection. The improved video recognition algorithm achieves an average recognition rate of 80.78% for the six categories of battery health state 0~40%, 40%~50%, 50%~60%, 60%~70%, 70%~80% and 80%~100%, and a single battery detection time of 3 minutes, which enables fast detection of battery health state.

Keywords: lithium iron phosphate battery; battery state of health; video recognition; infrared thermography; SlowFast

0 引言

新能源汽车产业蓬勃发展,2022年我国新能源汽车销量为688.7万辆,其中磷酸铁锂电池占总销量的58.4%,在全球市场中,2022年全球软包动力电池市场份额为34.49%。动力电池反复使用后会从汽车上退役,预计2025年我国退役动力电池累计将达到 78×10^7 kg。因此准确快速的电池健康状态检测对于退役新能源汽车动力电池

的梯次利用具有重大意义。目前电池健康状态(state of health, SOH)检测主要有基于模型和基于数据驱动的方法^[1-2]。基于模型的检测方法主要包括电化学模型、等效电路模型和热学模型等,Zhou等^[3]改进单粒子模型,将电阻和正极中锂离子固相扩散时间作为SOH检测指标,误差在5%以内;Li等^[4]考虑固体电解质膜(solid electrolyte interphase, SEI)的形成,使用单颗粒模型,将SEI膜的增长转化为电池循环次数的函数;Sabatier等^[5]对伪二维电化

收稿日期:2023-02-11

*基金项目:江西省科技合作专项重点项目(20212BDH80008)、国家自然科学基金(12165001)、科技部常规性科技援外项目(KY201702002)、江西省重点研发计划项目(20181BBE58006)资助

学模型(P2D)进行简化,实现电池 SOH 与荷电状态(state of charge, SOC)的估计,但模型计算复杂度较高,难以在实际工程中应用; Hu 等^[6]使用分数阶等效电路模型实现电池 SOH 的估计,但该方法对数据的质量要求过高; 在研究电池热学模型中, Ma 等^[7]采用离散的 Arrhenius 模型描述电池容量的退化情况,研究了电池温度与 SEI 增厚对电池 SOH 的影响; Tang 等^[8]基于电化学-热耦合模型研究不同容量电池在充放电过程中产热的主要原因与变化; 黄奐奇^[9]基于伪二维电化学-热耦合模型在时域和频域上分别对模型进行研究,实现电池健康状态的估计,误差小于 1.52%。

基于数据驱动法是随着大数据和计算能力的提高而提出,该方法不需要对电池内部的工作机理进行研究,只需要采集电池工作过程中的一些参数如:电压、电流、温度、内阻以及容量等数据,以此为基础通过向量机、神经网络、高斯过程回归、支持向量回归^[10]、深度学习等数据挖掘算法完成参数与退化状态之间的关系映射,实现电池健康状态估计。Zhang 等^[11]将电池的部分增量容量与神经网络进行融合,实现电池在恒流工作状态下的 SOH 估计; 宋丹丹等^[12]通过提取电池表面温度、电流、电压等特征与电池内部老化机理相关联,使用机器学习的方法实现电池健康状态在线估计。

综上所述,现有的方法均无法实现电池健康状态的快速检测,基于模型法需要研究复杂的内部工作机理,检测效率低,耗时长,通用性较差^[13]; 基于数据驱动法需要采集大量的历史数据来保证结果的准确性,仍需要采集电池循环周期内的充放电数据,耗时也相对较长。本文结合红外热成像,根据不同健康程度电池工作时产热不同,使用深度学习视频识别算法来实现 SOH 的快速检测。该方法能够与锂电池内部的退化机理联系起来,不需要建立复杂的内部退化模型,既方便测量又能确保其精度和速度,有利于推动退役动力锂电池梯次利用技术的发展。

1 锂电池健康状态快速检测方法原理

1.1 锂电池工作原理

锂离子电池是可反复充放电的二次电池其工作原理如图 1 所示。

本研究使用磷酸铁锂电池为实验对象,其电极充放电总反应:



表 1 所选电池基本参数

电池规格	标称容量	额定电压	内阻	放电截止电压	充电截止电压	工作温度
10 mm×90 mm×140 mm	10 Ah	3.2 V	≤3 mΩ	2.50 V	3.65 V	-10 °C~45 °C

使用高倍率 2C 电流对电池进行放电至截止电压 2.5 V,采集不同电池放电截止时与初始时刻的温度差,分析不同老化电池的温度特性,电池的温差曲线如图 3

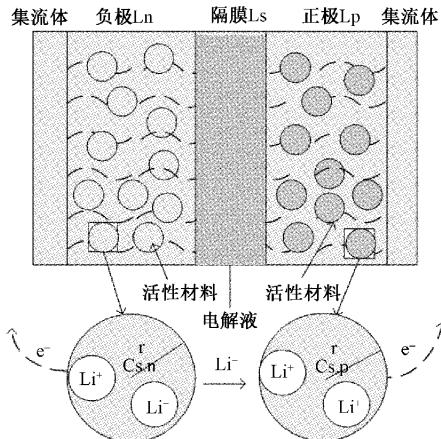
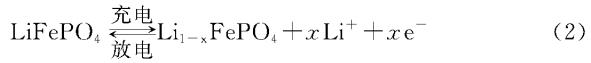


图 1 锂离子电池工作原理

阳极反应:



阴极反应:



1.2 锂电池老化特性研究

SOH 是衡量锂电池在不同工作阶段相对于新电池的健康状况^[14],通常用多次循环的电池容量与电池额定容量的比值来表示,计算公式如下:

$$SOH = \frac{C_t}{C_0} \times 100\% \quad (4)$$

其中, C_t 表示为第 t 个循环次数对应的电池实际容量, C_0 表达电池的额定容量。

电池 SOH 反映了当前时刻电池的最大实际容量与额定容量之间的比率。以此为依据可将退役动力锂电池 SOH 划分为 4 个梯度进行梯次利用^[15], 分别可用在动力汽车(SOH 为 80%~100%)、储能装置(SOH 为 60%~80%)、数码产品(40%~60%)、回收利用(低于 40%)。本文以 10 Ah 磷酸铁锂软包电池作为研究对象,电池的基本参数如表 1 所示,选取不同容量的 50 组电池研究,在恒温条件下(20 °C),对这些电池进行循环充放电测试,测量电池的内阻、开路电压、SOH、温差等参数,并对不同老化程度的电池进行分析,电池样本 SOH 分布如图 2 所示,部分数据(电池 C1~C8)如表 2 所示。

所示。

随着电池老化程度的加深,其内部的副反应增加,不可逆热也增加,SOH 越低的电池在放电截止时刻的温度

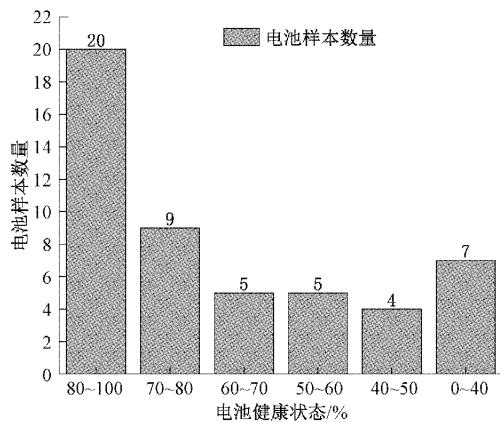


图 2 不同 SOH 电池数量分布

表 2 部分电池测试数据

电池编号	开路电压/V	容量/Ah	SOH/%	内阻/mΩ	能量/Wh	温差/℃
C1	3.435	9.482	94.82	10.0	32.24	16.68
C2	3.436	9.051	90.51	11.0	31.02	16.50
C3	3.421	8.732	87.32	12.0	29.99	17.92
C4	3.413	7.648	76.48	15.0	26.35	21.10
C5	3.305	6.369	63.69	9.90	18.60	20.32
C6	3.341	5.732	57.32	18.4	14.85	25.44
C7	3.305	4.563	45.63	24.9	12.17	23.36
C8	3.307	3.190	31.90	57.3	10.59	23.38

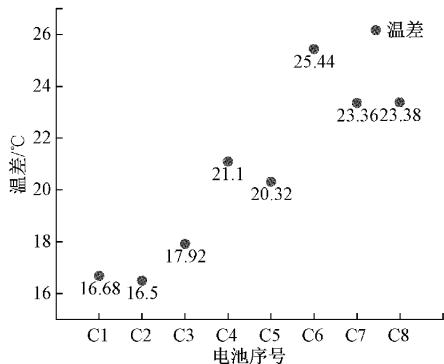


图 3 不同电池放电截止时刻温差

差 ΔT 相对较高^[16], 这种现象为下文研究提供了有力的依据。

1.3 实验装置及流程

根据上文描述的锂电池特性, 本文使用海康威视专业热成像仪 TPH16 来拍摄不同电池工作过程中温度的变化, 测温精度为 $\pm 2\%$, 使用视频方式从空间和时序特征上分析不同电池的温度变化趋势。将电池放入恒温箱中, 初始温度设为 20°C , 使用电池分容测试仪灼智电池测试仪 (EBC-X) 对电池进行循环充放电测试、内阻测试等性能测试。实验装置设计图如图 4 所示, 实验平台如图 5 所示。

具体实验流程如图 6 所示。

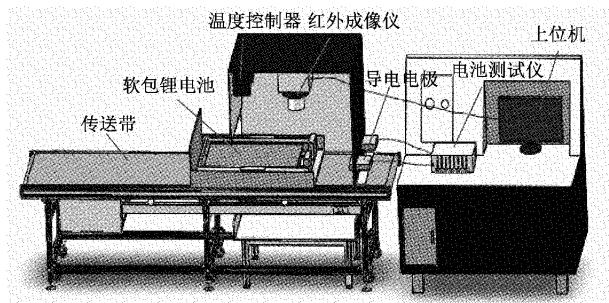


图 4 实验装置图

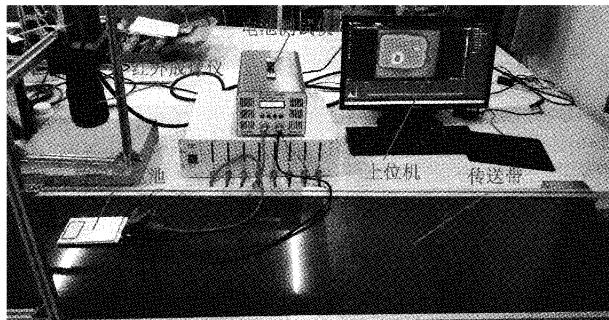


图 5 实验平台实物图



图 6 实验总体流程

- 1) 将实验电池置于恒温箱中, 设置恒定温度 20°C , 保持电池与实验环境初始温度一致;
- 2) 使用电池测试仪对 50 组电池分别进行测试, 得到电池当前容量、循环性能等信息;
- 3) 根据式(4)计算电池的 SOH 值, 并根据 SOH 不同进行分类, 分为 $0\sim 40\%$ 、 $40\%\sim 50\%$ 、 $50\%\sim 60\%$ 、 $60\%\sim 70\%$ 、 $70\%\sim 80\%$ 、 $80\%\sim 100\%$ 6 种类别;
- 4) 对各类别电池使用 2C 电流进行放电, 使用红外成

像仪拍摄 3 min 的红外视频,然后将电池静置 1 h 待电池温度恢复到初始温度时重复进行上述步骤,直到电池放电至截止电压。

5) 对采集的视频进行预处理,包括数据增强,关键帧提取等操作,并将处理好的数据进行打标签,将测得的数据根据 7 : 3 的比例分为训练集与测试集,送入深度学习网络进行学习得到分类结果,实验结束。

2 锂电池热特性研究与分析

2.1 锂电池热模型

电池工作时热量产生主要来自电化学反应和质量传输产生的能量损耗^[17],包括可逆热和不可逆热^[18]。其中可逆热主要由电化学反应所产生,而不可逆热主要是欧姆热、极化热等^[19]。电池热传递的方式主要包括:热传导、热对流、热辐射。本文的实验环境位于相对密闭的恒温环境中,热辐射与热对流的值相对较小,因此主要考虑电池热传导。

根据能量守恒定律可得方程如式(5)所示。

$$\rho C_p \frac{\partial T}{\partial t} = \lambda_x \frac{\partial^2 T}{\partial x^2} + \lambda_y \frac{\partial^2 T}{\partial y^2} + \lambda_z \frac{\partial^2 T}{\partial z^2} + Q \quad (5)$$

式中: ρ 是电池密度, C_p 是电池比热容, $\lambda_x, \lambda_y, \lambda_z$ 分别为电池各向异性导热系数, T 为温度, t 为时间, Q 为总生热速率, 电池总产热又包括可逆热与不可逆热两部分,具体公式如式(6)所示。

$$Q = \frac{\int_0^{L_n+L_{sep}+L_p} (Q_p + Q_r + Q_i) dx}{L_n + L_{sep} + L_p} \quad (6)$$

式中: L_n, L_{sep}, L_p 分别表示电池负极、隔膜、正极的厚度, Q_p 是电池内部发生极化现象产生的不可逆热, Q_r 是电池正负极发生电化学反应所产生的可逆熵热, Q_i 是在电子传导过程中和离子传输过程中所产生的不可逆欧姆热。

而对于不同 SOH 的电池,SOH 值越低的电池老化程度越深,电池内部的离子活性降低,电解质分解,电极表面 SEI 膜变厚以及内阻变大,这些性能因子的改变会导致电池内部的极化热与欧姆热的值上升,因此 SOH 越低的电池,温度上升的值越高,红外成像变化越明显。

2.2 锂电池热特性分析

对不同 SOH 电池放电时的温度进行采集,为避免外界干扰,测量多个位置温度平均值。如图 7 所示采集电池两极、中心、最远端 5 个位置 P_1, P_2, P_3, P_4, P_5 的温度,算出每一时刻的平均温度 \bar{P} 。

公式如下:

$$\bar{P} = \frac{\sum_{i=1}^n P_i}{n}, n = 5 \quad (7)$$

对不同 SOH 电池 C1~C8 分别采集放电过程中 \bar{P} 的值,并绘制折线图观察其区别,如图 8 所示。同时采集电池 C1~C8 恒流放电下的温度平均变化率 ΔT ,公式如式(8)所示。

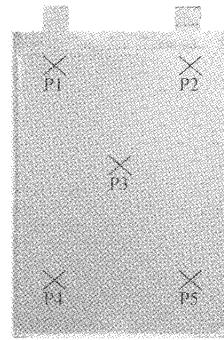


图 7 电池表面温度提取

$$\overline{\Delta T}(k) = \frac{\overline{P}_{end}(k) - \overline{P}_{start}(k)}{t(k)}, k = 1, 2, \dots, m \quad (8)$$

其中, k 表示当前电池的编号, m 为样本量, \overline{P}_{end} , \overline{P}_{start} 表示恒流放电结束时、开始时的温度值, $t(k)$ 表示放电的时间。计算出 C1~C8 的温度平均变化率并将其绘制成曲线图如图 9 所示。

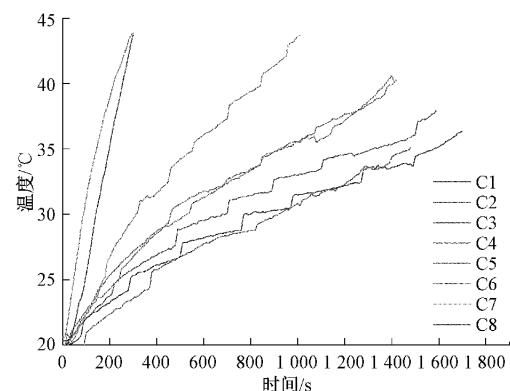


图 8 电池表面平均温度

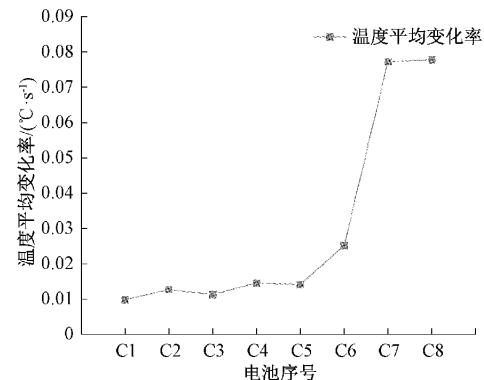


图 9 电池温度平均变化率

为进一步了解不同 SOH 电池放电过程温度的变化情况,本文采用有限差分法来求取电池温度变化率 ΔT ,具体公式如下:

$$\Delta T(t) = \frac{\overline{P}(t+L) - \overline{P}(t)}{L} \quad (9)$$

式中: L 为采样间隔, t 表示任意放电时刻。由于要捕捉电池放电时温度细微的变化,因此 L 的取值不能过大;同样 L 值也不能过小,因为较小的值会容易受到噪声的影响。因此本文根据温度的变化情况取采样间隔 $L=40$,并绘制电池C1~C8温度变化率的曲线图,如图10所示。

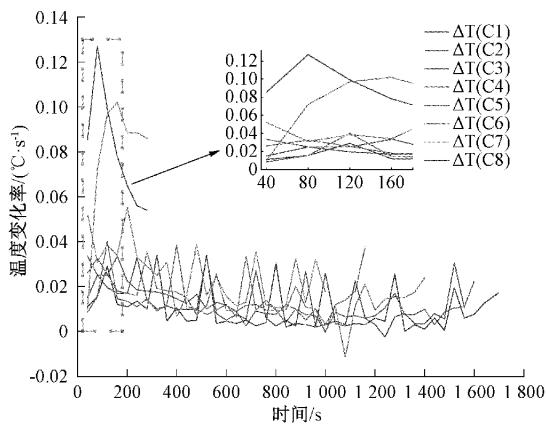


图10 电池温度变化率

由图10可知电池放电时表面温度会随时间不断上

升,且SOH越低的电池温度上升的速度越快,温升值越高,温度平均变化率的值也越大。同时对于电池温度变化率,整体趋势为先减小后增大,然后达到峰值,并且随着电池SOH降低,温度变化率的峰值会向左移,值也逐渐增大。在前3 min的局部温度变化率曲线中,可以看出电池温度变化率会随着SOH的降低而逐渐增大,电池C8峰值达到最大值。根据这些实验分析可以得知,温度会随着电池SOH的变化而以某种规律进行改变,且普遍符合这一现象,因此本文通过红外视频的方式从时序特征上来研究不同电池工作过程中温度变化的趋势。

3 锂电池健康状态快速检测算法研究

3.1 红外视频样本库构建

采集红外视频来分析电池充放电过程中温度的变化情况,不仅可以从图像的变化来区分温度的变化,还可以描述电池温度变化的时序特征,从电池生热及热扩散的角度进行分析。对不同SOH的电池使用2C电流进行放电,使用红外成像仪拍摄放电前3 min的红外视频,部分电池C1~C8放电3 min对应的红外图如11所示。

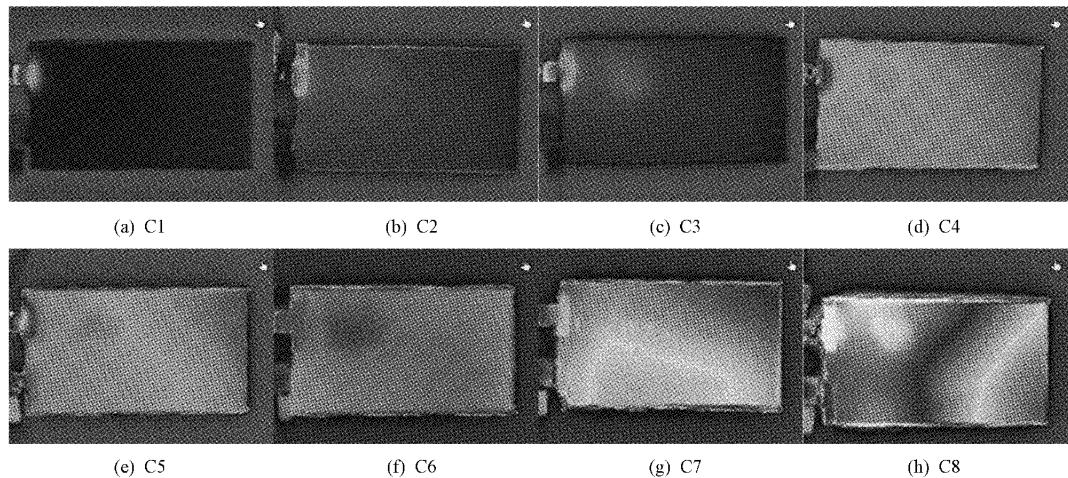


图11 不同电池放电3 min红外图

采集的红外视频为每秒25帧,每个电池拍摄3 min视频共4 500帧,共50组电池,并根据电池SOH的不同分为6类,即SOH分别为:0%~40%、40%~50%、50%~60%、60%~70%、70%~80%、80%~100%,构建实验样本库。由于红外视频图像相较于可见光照片存在分辨率低、低对比度、低信噪比等问题,因此本文对实验样本库进行图像增强的预处理操作,来增强红外视频的识别精度,之后将处理好的样本送入深度学习网络进行学习,来达到视频识别的目的。

目前视频识别的架构多用来处理小于5 s的视频,本实验使用的视频时长为3 min,需要提高网络模型在视频时序上联系上下文的能力,以实现长视频的识别。因此本文使用基于SlowFast-LSTM网络模型对电池红外视频进

行分类,具体模型结构如图12所示。

3.2 基于SlowFast-LSTM网络的SOH快速检测算法构建

1)SlowFast网络

通常人类视网膜神经细胞主要分为两类,其中约80%的细胞(P-cells)以低频运作,可以识别细节信息;而大约20%的细胞(M-cells)则以高频运作,对时间的变化敏感。根据这一特性提出一种SlowFast架构^[20],使用两个分支分别对时间和空间维度进行处理分析。其中Slow分支在低帧率下运行,使用较大的步长 τ 来采集视频中, τ 设置为16,视频每秒帧数为30,每秒大约可以采集2帧,即 $T=2$,通道数为C;Fast分支在高帧率下运行,来捕获时间序列的信息,同时使用较少的通道数来使模型轻量化,视频帧数采集的步

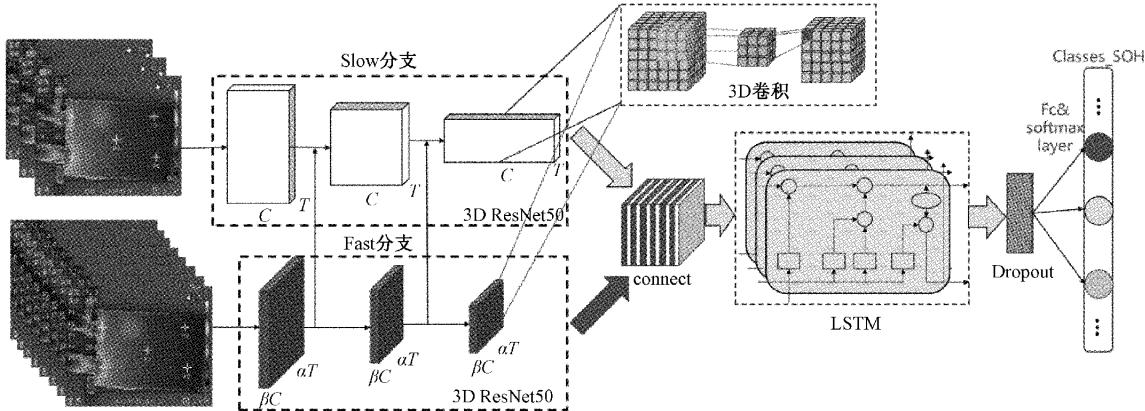


图 12 基于 3DResNet 的 SlowFast-LSTM 网络结构

长较小为 τ/α , 其中 α 设置为 8, 那么对帧率为 30 的视频来说, 1 秒可以采集大约 15 帧, $\alpha T = 15$, Fast 分支使用较小的通道数 (βC), 其中 $\beta = 1/8$ 。整体网络结构如图 13 所示。

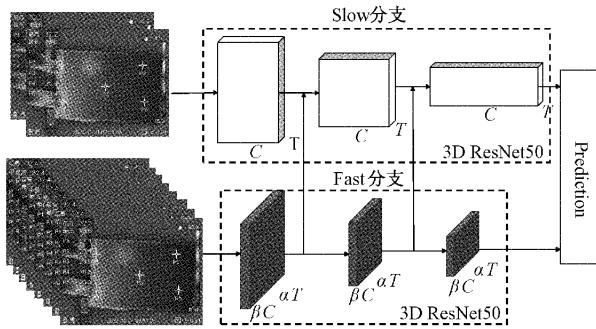


图 13 SlowFast 基本网络结构

其中 Slow 分支和 Fast 分支使用的主干网络均为 3 D ResNet50 模型, 在每个分支的末端执行全局平均池化, 然后将两个分支的特征进行横向连接进行类别预测。

2) 长短期记忆网络(LSTM)

LSTM 通常用来有效的传递和表达长时间序列中的信息并不会导致之前长时间的信息遗忘, 该网络是由循环神经网络(RNN)衍生而来。

LSTM 内部结构如图 14 所示, 共分为遗忘门、记忆门和输出门 3 部分^[21], 其中 x_t 代表第 t 个序列输入值; C 表示记忆单元(cell), 是网络的核心, 控制信息的传递; f 表示遗忘门决定将前一时刻的记忆单元 C_{t-1} 保存多少至当前 C_t ; o 代表输出门决定将 C_t 传递多少至当前输出 h_t ; h_{t-1} 表示在 $t-1$ 时刻的隐层状态。

上述过程具体公式如下:

$$f_t = \sigma(\mathbf{W}_f \cdot [x_t, h_{t-1}] + b_f) \quad (10)$$

$$i_t = \sigma(\mathbf{W}_i \cdot [x_t, h_{t-1}] + b_i) \quad (11)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c \cdot [x_t, h_{t-1}] + b_c) \quad (12)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (13)$$

$$o_t = \sigma(\mathbf{W}_o \cdot [x_t, h_{t-1}] + b_o) \quad (14)$$

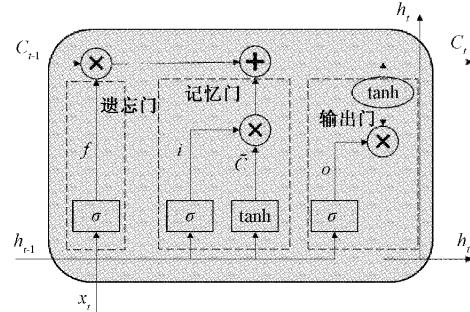


图 14 LSTM 内部结构

$$h_t = o_t \tanh(C_t) \quad (15)$$

上式分别表示遗忘门、记忆门和输出门的公式, 其中

\mathbf{W}_f 为遗忘门的权重矩阵, \mathbf{W}_i 和 \mathbf{W}_o 分别为记忆门 i_t 、 \tilde{C}_t 的权重矩阵, \mathbf{W}_o 指代输出门的权重矩阵; b_f, b_i, b_o, b_o 分别指代遗忘门、记忆门与输出门的偏置项; σ 为 sigmoid 激活函数; \tanh 指代双曲正切激活函数, 可以将输出值归一化到 $[-1, 1]$; 最终得到 t 时刻 h_t 值为最终输出结果。

LSTM 通过门函数, 控制历史信息的传递, 具备一定的时间序列处理与预测能力。理论上其步长越长, 挖掘出的信息量越多。然而在步长超出一定长度时, 仍旧会出现远距离记忆丢失及梯度消失。本文通过使用 SlowFast 网络, 提取视频空间与时间序列特征, 将 Slow 分支与 Fast 分支进行连接后输入 LSTM, 尽可能保留更长时间的记忆信息, 提高长视频识别的准确度, 取得良好结果。

3.3 实验结果

本文实验在 Ubuntu16.04 系统下进行, 硬件平台包括: GPU (NVIDIA Tesla V100), CPU (Intel Xeon Platinum 8358) 以及 128 G 内存, 程序基于 Python 语言下的 Pytorch 平台进行相关实验。使用 mmaction2 工具对采集的红外数据进行抽帧操作, 每秒抽取一帧对其进行标注; 选取 70% 红外视频作为训练集, 30% 作为测试集, 由于没有与所提出的结构兼容的相关预训练模型, 网络训练是从头开始执行^[22]。采用小批量和批归一化 (batch

normalization, BN)^[23]方法提高训练的收敛速度,将网络的输入批大小(batch)设为12,设定初始学习率为0.01,epoch=100(在第30/60/80个epoch学习率依次衰减为原来的1/10);在训练过程中,对时域从全长视频中随机抽取一个片段($T \times \tau$ 帧),Slow分支和Fast分支的输入分别为 T 帧和 αT 帧;对空间域采用角点裁剪和水平翻转两种方法进行数据增强,以增加训练样本的多样性,最后将每个裁剪区域的大小调整为 224×224 进行训练,记录网络模型在epoch=[0,100]区间中的识别准确率如图15所示,可以得到在SlowFast-LSTM网络模型的识别准确率达80.78%。

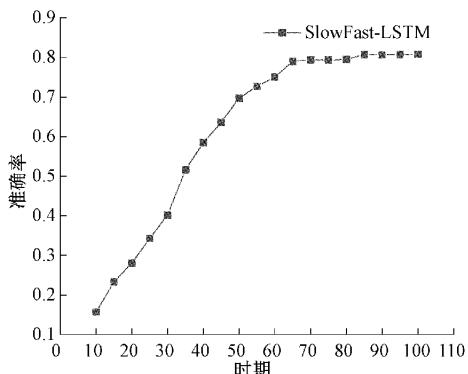


图15 SlowFast-LSTM网络模型识别准确率

3.4 不同检测方法对比验证

为了使电池检测效率更高,设计了电池健康状态快速检测系统。使用PyQT框架设计了用户可视化操作界面,如图16所示,可实现红外视频的实时采集与加载,并将视频处理算法内置于系统中,实现电池健康状态的在线检测。



图16 电池SOH检测系统界面

另外选取10个电池样本进行测试,分别使用传统电池健康状态检测方法与本文方法进行对比,同时记录两种方法的检测时间,结果如表3所示。

根据表3结果,10个电池样本测试SOH识别率达到90%,电池视频数据采样时间为3 min,系统检测平均时长平均检测时间为108.2 s,整体测试时间在5 min之内,而

表3 电池SOH检测系统的性能评估

编号	实际值	检测值	是否	传统检测	本文检测
			正确	时间/h	时间/s
N51	98.12%	80%~100%	是	2.89	109.35
N52	91.23%	80%~100%	是	2.75	107.69
N53	82.65%	80%~100%	是	2.58	109.32
N54	77.43%	70%~80%	是	2.31	106.72
N55	67.35%	60%~70%	是	2.69	109.34
N56	59.68%	50%~60%	是	2.71	108.56
N57	48.72%	40%~50%	是	3.28	107.64
N58	41.15%	0%~40%	否	2.03	107.35
N59	29.31%	0%~40%	是	2.45	108.36
N60	19.13%	0%~40%	是	1.44	108.08

传统方法测试电池健康状态需要几个小时的时间。对于数据驱动方法而言,该方法通常是采集电池工作过程中的各种运行参数,对采集的大量数据进行机器学习实现电池SOH检测,因此多用于新能源汽车电池SOH在线检测。在退役电池梯次利用中,由于退役电池的容量、批次、内部化学性质等均存在较大差异,需要大量的电池运行参数,限制了梯次利用产业的发展。通过本文方法可以实现电池健康状态的快速检测,与其他检测方法相比,本文方法不用对电池进行完整的充放电研究,仅需采集电池放电前3 min的红外视频,对视频进行识别即可得到电池的健康状态,节省大量时间成本,对提高目前电池梯次利用的效率具有一定意义。

4 结 论

退役动力电池健康状态快速检测在锂电池梯次利用中意义重大。本文提出一种基于红外热成像的锂电池健康状态快速检测方法,分析了锂电池老化特性,研究不同老化电池充放电过程中温度变化情况,发现电池温度变化呈现规律变化,与电池SOH具有很强的相关性,并以此作为研究对象将不同电池的温度变化与红外热成像建立联系,通过分析不同电池所对应的红外视频变化的不同来实现电池健康状态的快速检测;使用改进的SlowFast网络模型建立在更长视频中时序上的关系,从而达到检测的目的。实验结果表明:在SlowFast-LSTM模型在自建红外视频数据库中电池健康状态(SOH)0~40%、40%~50%、50%~60%、60%~70%、70%~80%、80%~100%这6种类别的识别率达80.78%,视频数据采样时间3 min,系统检测时间不超过5 min,实现电池健康状态的快速检测。

同时仍在一些不足之处:电池样本数量不足没有类似开源的数据集用于预训练,模型识别的准确率和泛化能力有待提高。在未来的工作中将进一步优化网络模型,使用更多的骨干网络来验证本文提出方法的泛化能力;继续扩大电池样本数量、种类的视频数据,提高模型识别的准确度。

参考文献

- [1] LIN Q, WANG J, R XIONG et al. Towards a smarter battery management system: A critical review on optimal charging methods of lithium ion batteries[J]. Energy, 2019, 183: 220-234.
- [2] XIONG R, LI L, TIAN J, et al. Towards a smarter battery management system: a critical review on battery state of health monitoring methods [J]. Journal of Power Sources, 2018, 405: 18-29.
- [3] ZHOU X, HUANG J, PAN Z, et al. Impedance characterization of lithium-ion batteries aging under high-temperature cycling: Importance of electrolyte-phase diffusion[J]. Journal of Power Sources, 2019, 426(30):216-222.
- [4] 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 [J]. Applied Energy, 2018, 212: 1178-1190.
- [5] SABATIER J, MERVEILLAUT M, FRANCISCO J M, et al. Lithium-ion batteries modeling involving fractional differentiation [J]. Journal of Power Sources, 2014, 262: 36-43.
- [6] HU X, YUAN H, ZOU C F, et al. Co-Estimation of state of charge and state of health for lithium-ion batteries based on fractional-order calculus[J]. IEEE Transactions on Vehicular Technology, 2018, 67 (11): 10319-10329.
- [7] MA J, XU S, SHANG P, et al. Cycle life test optimization for different Li-ion power battery formulations using a hybrid remaining-useful-life prediction method[J]. Applied Energy, 2020, 262 (114490): 1-16.
- [8] TANG Y, WU L, WEI W, et al. Study of the thermal properties during the cyclic process of lithium ion power batteries using the electrochemical-thermal coupling model[J]. Applied Thermal Engineering, 2018, 137: 11-22.
- [9] 黄免奇. 基于电化学热耦合模型的锂离子电池老化状态估计[D]. 哈尔滨: 哈尔滨工业大学, 2021.
- [10] 付春流, 郑文芳, 陈东洋, 等. 锂电池剩余放电时间预测方法研究[J]. 电子测量技术, 2020, 43(10): 57-62.
- [11] ZHANG S, ZHAI B, GUO X, et al. Synchronous estimation of state of health and remaining useful lifetime for lithium-ion battery using the incremental capacity and artificial neural networks[J]. Journal of Energy Storage, 2019, 12: 69-78.
- [12] 宋丹丹. 基于表面温度特征的锂电池健康状态评估[D]. 西安: 西安电子科技大学, 2021.
- [13] 刘大同, 宋宇晨, 武巍, 等. 锂离子电池组健康状态估计综述[J]. 仪器仪表学报, 2020, 41(11): 1-18.
- [14] 刘大同, 周建宝, 郭力萌, 等. 锂离子电池健康评估和寿命预测综述[J]. 仪器仪表学报, 2015, 36(1): 1-16.
- [15] 刘怡, 穆苗苗, 张友琅, 等. 退役动力电池在光伏储能中应用[J]. 电源技术, 2019, 43(1): 126-128.
- [16] 石伟杰, 王海民. 基于锂离子电池热特性的 SOH 在线诊断模型研究[J]. 仪器仪表学报, 2020, 41 (8): 206-216.
- [17] 林玉珍. 车用锂离子动力电池电化学-热耦合模型及 SOC/SOH 估计方法研究[D]. 镇江: 江苏大学, 2020.
- [18] TANG Y, WU L, WEI W, et al. Study of the thermal properties during the cyclic process of lithium ion power batteries using the electrochemical-thermal coupling model[J]. Applied Thermal Engineering, 2018, 137: 11-22.
- [19] MA S, JIANG M, TAO P, et al. Temperature effect and thermal impact in lithium-ion batteries: A review[J]. Progress in Natural Science: Materials International, 2018, 28(6): 653-666.
- [20] FEICHTENHOFER C, FAN H, MALIK J, et al. SlowFast networks for video recognition [C]. 2019 IEEE/CVF International Conference on Computer Vision, 2019: 6202-6211.
- [21] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting [J]. Advances in Neural Information Processing Systems, 2015, 28.
- [22] WAN J, ESCALERA S, ANBARIAFARI G, et al. Results and analysis of chalearn lap multi-modal isolated and continuous gesture recognition, and real versus fake expressed emotions challenges [C]. Proceedings of the IEEE International Conference on Computer Vision Workshops, 2017: 3189-3197.
- [23] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. International Conference on Machine Learning, Pmlr, 2015: 448-456.

作者简介

汪志成, 博士, 副教授, 主要研究方向为新能源技术与应用。

E-mail: 277732648@qq.com

王哲(通信作者), 硕士研究生, 主要研究方向为图像处理与新能源。

E-mail: 972460328@qq.com

王泽旺, 硕士研究生, 主要研究方向为电路与系统。

E-mail: 67077387@qq.com

赵杰, 硕士研究生, 讲师, 主要研究方向为新能源工艺及装备。

E-mail: 201060045@ecut.edu.cn

束登峰, 硕士研究生, 主要研究方向为机械电子工程。

E-mail: 2468137126@qq.com