

基于迁移学习的 在线铅酸蓄电池容量预测方法研究

Research on Online Lead-acid Battery Capacity Prediction Method Based on Transfer Learning

李国庆¹,杨泽昆¹,竹梦圆¹,周明千²(1. 中讯邮电咨询设计院有限公司,北京 100048;2. 中讯邮电咨询设计院有限公司郑州分公司,河南 郑州 450007)

Li Guoqing¹,Yang Zekun¹,Zhu Mengyuan¹,Zhou Mingqian²(1. China Information Technology Designing Consulting Institute Co.,Ltd., Beijing 100048, China; 2. China Information Technology Designing & Consulting Institute Co., Ltd. Zhengzhou Branch, Zhengzhou 450007, China)

摘要:

为了提高基站、机房等场景下蓄电池组的使用寿命,针对蓄电池组长期处于浮充状态无法实时监测测量电池容量的问题,利用迁移学习的思想,将实验室中蓄电池组充放电数据与现网中蓄电池组的在线浮充数据建立起联系,从而预测现网中蓄电池组中各个电池的容量。最后通过实验验证了该方法的有效性,使实时监测在线蓄电池容量变为可能。

关键词:

蓄电池;容量预测;迁移学习

doi:10.12045/j.issn.1007-3043.2023.07.012

文章编号:1007-3043(2023)07-0065-05

中图分类号:TN86

文献标识码:A

开放科学(资源服务)标识码(OSID):



Abstract:

In order to improve the service life of battery packs in scenarios such as base stations and computer rooms, and aiming at the problem that the battery pack cannot be monitored and measured in real time when the battery pack is in a floating charge state for a long time, the idea of transfer learning is used to establish a relationship between the charging and discharging data of battery packs in the laboratory and the online floating charging data of battery packs in the current network, so as to predict the capacity of each battery in the battery pack in the current network. Finally, the effectiveness of this method was verified through experiments, which makes it possible to monitor the online battery capacity in real time.

Keywords:

Battery; Capacity prediction; Transfer learning

引用格式:李国庆,杨泽昆,竹梦圆,等. 基于迁移学习的在线铅酸蓄电池容量预测方法研究[J]. 邮电设计技术,2023(7):65-69.

1 概述

作为基站的“生命之源”,蓄电池对于维持通信系统正常运转起着关键作用,每个基站都有作为后备电源的蓄电池,用于储备电能、应对电网异常等特殊情况,因此加强对蓄电池的维护和管理^[1],改善其使用状况,从而有效地延长蓄电池的使用寿命,具有重要的意义。此外,蓄电池的有效管理也可以降低其环境污染和碳排放,最终实现我国能源结构转型,确保碳达峰、碳中和目标的实现,保障国家能源安全^[2]。

为了提高蓄电池组的使用寿命,本文主要针对蓄电池管理过程中涉及到的在线蓄电池容量预测方法进行探讨说明。

2 蓄电池容量预测算法

目前,国内外普遍采用荷电状态(State of Charge, SOC)来表示蓄电池的剩余容量。SOC是直接反映蓄电池的可持续供电能力和健康状况的一个重要参数^[3]。由于阀控式密封铅酸(VRLA)蓄电池的SOC不仅与其本身的材料有关,而且类型各不相同,实际用途和使用环境也存在差异,导致影响SOC的因素过多,因此预测SOC的方法也是各种各样。根据电池

收稿日期:2023-06-14

SOC 预测模型的选择, 电池 SOC 预测算法大致可以分为 3 类: 物理建模方法、基于等效电路模型的 SOC 预测算法和基于神经网络的 SOC 预测算法^[4]。

2.1 物理建模方法

物理建模方法主要有放电试验法^[5]、安时计量法^[6]、开路电压法^[7]、内阻法^[8]等。

a) 放电试验法是公认最可靠的 SOC 预测方法。它是将电池以一定的放电倍率恒流持续放电, 直至电池端电压达到放电截止电压的实验方法, 通过放电电流与时间的乘积就能得到蓄电池的容量。这个方法主要用于实验室计算电池组充电效率、检验 SOC 估算精度或者用于蓄电池的检修, 适用于所有电池。但是, 该方法有 2 个明显的缺点: 需要严格的测试条件, 要求恒流、精确测量等, 这需要大量时间和人力; 电池正在进行的工作不得不中断, 无法实时在线预测。

b) 安时计量法是 SOC 预测最常用的方法, 实质是认为流进电池的电量与流出电池的电量有一定的比例关系, 而不考虑电池内部的结构和外部的电气特性, 因此这种方法适用于各种电池。但是这个方法在应用中存在很多问题。

(a) 需要标定 SOC 初始值。

(b) 需要精确计算充放电效率。

(c) 需准确测量电流, 若电流测量不准, 将造成 SOC 计算误差, 随着时间的增加, 电池 SOC 的累积误差会越来越大。

(d) 电流传感器的精度会受到温度漂移和其他随机干扰的影响, 所以在高温状态和电流波动剧烈的情况下误差较大。

c) 开路电压法是根据电池的容量与开路电压有一定的线性关系而建立起来的, 通过测量开路电压就能够直接得到电池容量的大小。它虽然可以不依赖蓄电池尺寸、大小和放电速度, 但是对电池要求比较高, 需要电池静止很长时间, 达到电压稳定才能测量, 也意味着不能实现在线测量。而且随着电池老化, 开路电压变化不明显, 因此也就无法准确预测剩余电量。

d) 内阻法是利用电池内阻与 SOC 之间的单调关系, 在知道电池内阻的条件下估计电池的 SOC 值。但是蓄电池的内阻一般在毫欧量级, 容易受温度和循环时间等因素的影响, 所以内阻与 SOC 的对应关系很难复现, 而且蓄电池内阻测量装置价格昂贵, 体积庞大, 该方法不适合大规模推广。

2.2 基于等效电路模型的 SOC 预测算法

基于等效电路模型的 SOC 预测算法是基于电池模型建立系统状态空间表达式, 将电池 SOC 作为状态变量之一, 然后通过滤波器或观测器估计电池 SOC^[9]。其主要思想是利用等效电路模型使用电阻、电容和恒定电压源等电路元件组成一个电路网络来模拟电池的动态特性, 然后将测量的电流、电压、温度和其他变量与电池 SOC 联系起来。将这些可测的因素作为模型的输入, 得到模型输出的端电压预测值与端电压实际采样值之间的误差。然后用误差乘以增益反馈的估计值来调整状态量, 从而使状态量的估计值与真实值一致。最后, 通过观测器或滤波器得到当前电池 SOC 值, 如图 1 所示。由于等效电路模型的准确性直接影响到基于状态空间电池模型的 SOC 预测的准确性, 所以如何设计一个有效的等效电路模型对于该类方法是非常重要的。

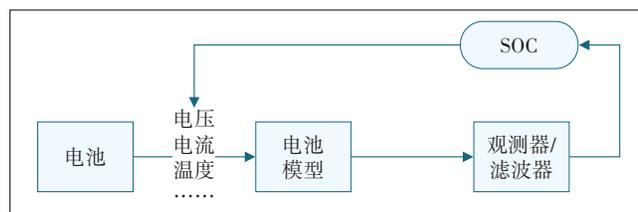


图 1 基于等效电路模型的 SOC 预测算法

2.3 基于神经网络的 SOC 预测算法

由于蓄电池 SOC 预测受很多因素影响, 对其充放电过程建立准确的数学模型难度比较大, 而神经网络可以自动从样本中提取更多抽象的、富有表现力的特征, 在一定程度上可以反应电池 SOC 与这些特征的线性与非线性关系。而这些算法将电池视为一个未知系统, 将可在线测量的电池电流、电压、温度等作为模型的输入, 将电池 SOC 作为模型的输出, 最后通过一些人工智能算法训练一个特征映射模型, 从而建立起输入和输出之间的复杂关系, 如图 2 所示^[10]。从而将蓄电池 SOC 预测问题转化为时间序列问题。

以深度学习算法为例, 介绍一些常见的网络。一个典型的 CNN 结构由 1 个输入层、1 个卷积层、1 个池

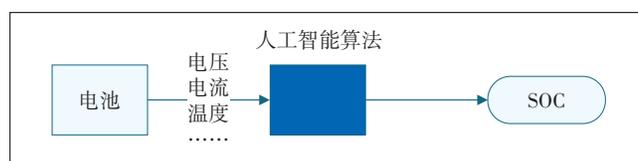


图 2 基于神经网络的的 SOC 预测算法

化层、1个全连接层和1个输出层组成,如图3所示。经过多次过滤操作,CNN可以通过逐层卷积和池化操作提取数据特征。但是,CNN网络各层的神经元之间没有相互联系,一个输入对应一个输出的结构不能解决时间序列问题。RNN由输入层X、隐藏层Y和输出层H组成,与CNN网络不同的是,RNN保留了历史信息的delayer^[11],如图4所示。RNN被广泛用于解决时间序列数据问题。然而,RNN有梯度爆炸和梯度消失的问题,所以它只能处理较短时间序列问题。它在实际应用中受到很大限制。门控循环单元(GRU)和长短时记忆(LSTM)网络的研究可以有效改善RNN的隐藏节点,为解决时间序列预测问题提供新的方向。作为RNN网络模型的一个变种,LSTM网络模型通过引入单元状态,可以很好地弥补RNN的缺陷,它更适用于处理和预测时间序列中相对较长的间隔和延迟。将LSTM和CNN结合起来,可以充分利用输入数据的特征,同时存储历史输入信息,具有更准确和稳定的预测效果^[12]。GRU是LSTM的一个变种,用于克服RNN的短期依赖性问题。当初始SOC值不确定时,它具有很强的鲁棒性,并能很好地适应环境温度的变化^[13]。这类电池SOC预测方法通常要建立离线数据库,并且获取大量样本,否则很容易过度拟合并陷入局部最优解,目前很难在工程中大规模应用。

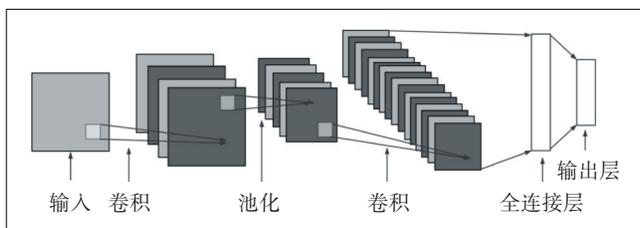


图3 CNN网络结构

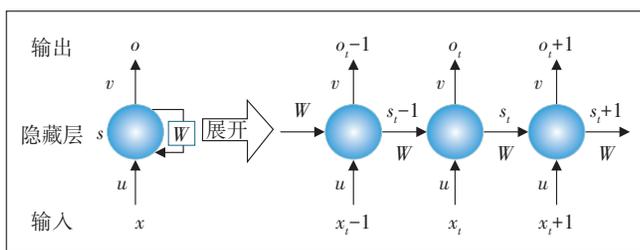


图4 RNN结构

3 在线铅酸蓄电池容量预测

当前基站内的蓄电池容量难以预测,究其原因不仅是蓄电池本身的问题,而且还有数据难以获取的因

素,因为基站或机房一般只有维护性放电,蓄电池本身的容量无法获取,所以如何能够根据已有数据预测在线蓄电池容量也是十分复杂的问题。

3.1 迁移学习

迁移学习(Transfer Learning)是属于深度学习的一个子研究领域,该研究领域的目标在于利用数据、任务或模型之间的相似性,将在旧领域学习过的知识,迁移应用于新领域中^[14]。迁移学习侧重于跨领域的知识迁移,受人跨领域迁移知识能力的启发,旨在利用相关领域(称为源域)的知识来提高目标域的模型性能或减少目标领域所需的训练数据数量。然而知识转移并不总是会给新的任务带来积极的影响。如果领域之间没有共同点,知识转移可能是不成功的。而域适应(Domain Adaptation, DA)是迁移学习的一个子方向^[15],它的源任务和目标任务一样,但源域和目标域的数据分布不一样,并且源域有大量的标记样本,目标域则没有(或很少)标记样本的迁移学习方法。与迁移学习相比,域适应还需要保证源域目标域的标签空间和特征空间都相同且条件概率分布相同。

3.2 基于迁移学习的在线铅酸蓄电池容量预测方法

为尽可能减少源域和目标域的数据分布差异,选取了实验室的高温浮充环境和基站环境作为源域和目标域,其中基站电池数据采集的是2个蓄电池组,共48个单体的信息(放电时电压达到截止电压的仅有17个),单体蓄电池额定容量为1 000 Ah,额定电压为2 V,放电方式为3 h恒流放电。实验室电池数据是采集了1个电池组,2个单体的信息,其他条件与基站相同,选取其中9次循环的数据。

如图5和图6所示,实验室数据样例包含了充电阶段和放电阶段的2个单体电池的电压变化,基站样例数据包含了2个单体电池的浮充阶段和放电阶段的电压变化,分别对比实验室条件下的充电阶段数据和基站条件下的浮充阶段数据、实验室条件下的放电阶段数据和基站条件下的放电阶段数据,可以发现实验室与基站内的电池电压变化趋势大体相同,具有一定的相似性。

因为大多数基站的现网并没有电池深度放电数据,所以无法得到电池的容量数据,希望通过实验室与现网的相似性构建迁移学习模型,源域的任务是实验室条件下铅酸蓄电池的容量预测,目标域的任务是现网条件下铅酸蓄电池的容量预测,以基站为例,通

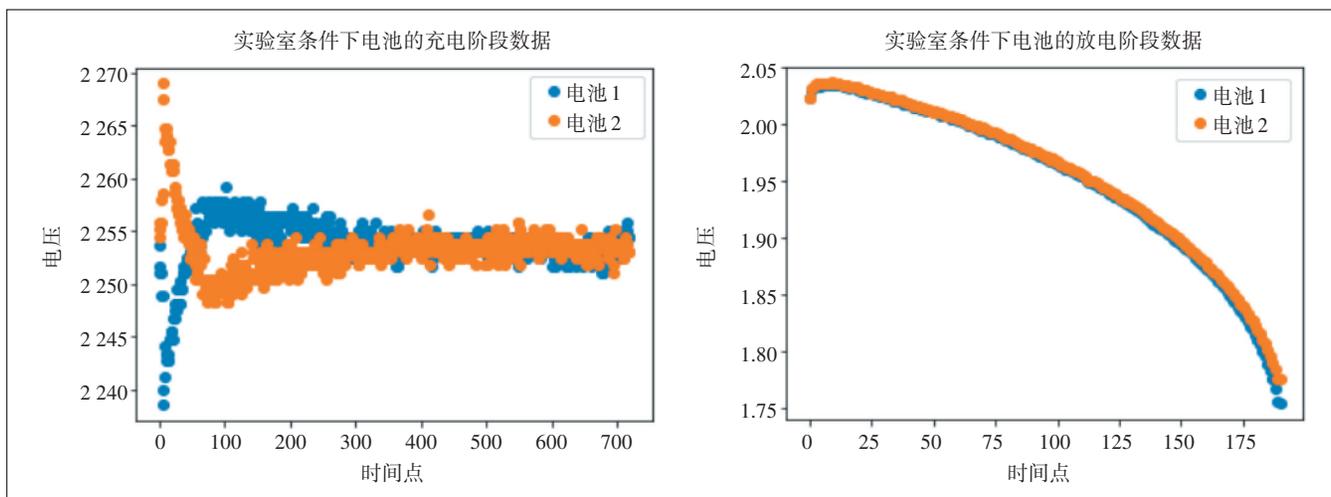


图5 实验室数据样例

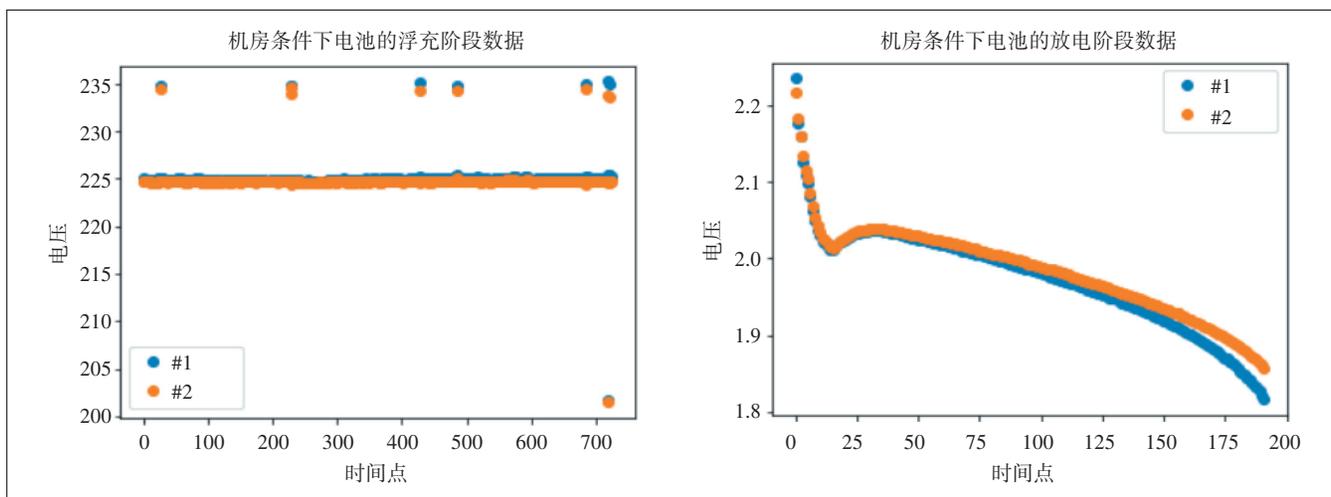


图6 基站数据样例

过源域的特征向量与目标域的特征向量的变化,将它们映射到同一个特征空间中,从而通过基于源域的标签数据能够预测目标域的标签。

为了提高源域模型在目标域的表现,在特征映射的过程中需要减小源域和目标域特征之间的差异性,并且为保证特征的可分性,将源域中差距较大的特征赋予较小的权重。这里采用最大平均偏差(The Maximum Mean Discrepancy, MMD)^[16],它是通过2个概率分布的样本测量这2个概率分布之间的差异,给定2个在 χ 上的概率分布 p 和 q ,MMD的基本定义式如下:

$$\text{MMD}[\mathcal{F}, p, q] = \sup_{f \in \mathcal{F}} \left\{ E_p[f(x)] - E_q[f(y)] \right\}$$

其中, \mathcal{F} 是函数 $f: \chi \rightarrow \mathbb{R}$ 的一个类。训练过程就是利用MMD度量源域数据分布与目标域数据分布的距离,从而逐渐较少它们之间的差异。

整个实验流程如图7所示,先将实验室充电数据和基站浮充数据通过MMD映射到同一个特征空间,然后利用映射后的实验室数据训练一个基于实验室充电阶段电压的神经网络模型,最后用这个模型预测映射后的基站浮充数据,并转换为容量,与真实容量做对比。为了验证对比迁移学习的作用,添加对照实验:在实验室数据上直接训练模型,然后在基站数据上进行预测。采用平均绝对误差(Mean Absolute Error, MAE)和平均绝对百分比误差(Mean Absolute Percentage Error, MAPE)作为评价指标,具体的公式如下:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n \left| \text{Predicted}_i - \text{Actual}_i \right|$$

$$\text{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{\text{Predicted}_i - \text{Actual}_i}{\text{Actual}_i} \right|$$

其中, n 为样本数量, Predicted_i 和 Actual_i 分别是模

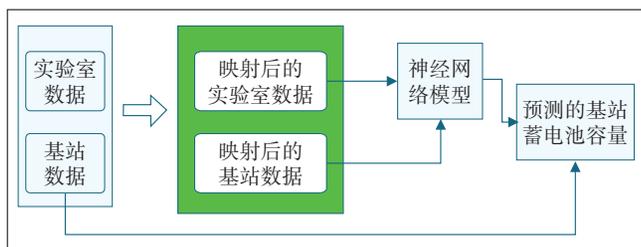


图7 基于迁移学习的在线铅酸蓄电池容量预测方法流程

型预测值和真实值,两者均是值越低,表示模型预测的更准确。

表1为在线铅酸蓄电池容量预测结果。从表1可以看出,不论是否基于迁移学习,这种方法预测出的电池容量误差均比较小,而使用迁移学习后在实验室数据上的表现更好,也证明了该方法的有效性。由于训练过程中有标签的数据都是实验室数据,模型学习到的数据分布偏向实验室数据,所以在实验室数据中的效果会更好。根据实验结果,不论是否使用迁移学习,在预测基站电池容量时,预测值通常都比真实值大,这也是因为实验室获取数据的蓄电池是比较新的,容量比较接近额定容量,而基站的蓄电池所有容量的数据都是来源于截止电压小于等于1.8V的蓄电池,这些蓄电池容量都相对较小,其他蓄电池因为放电截止电压限制的是电池组的电压,截止电压均大于1.8V,所以并没有相应的容量,导致训练数据都是较大容量的电池,而要实际预测的都是较小容量的电池,导致迁移效果并不是很好,仍需要更多的数据来验证。但总的来说,该方法可以根据实验室数据预测在线浮充阶段蓄电池的容量。

表1 在线铅酸蓄电池容量预测结果

数据集	是否使用迁移学习	MAE	MAPE
实验室数据	否	7.533	0.010
基站数据		141.625	0.217
实验室数据	是	8.835	0.012
基站数据		97.451	0.149

4 总结

针对在线蓄电池容量预测问题,本文介绍了常见的电池容量预测方法,并提出了基于迁移学习的在线铅酸蓄电池容量预测方法,可以利用实验室的铅酸蓄电池充放电数据预测在线浮充下的铅酸蓄电池容量,为预测铅酸蓄电池容量提供了新的思路,可以时刻监测蓄电池容量,从而减轻运维人员的负担,提高蓄电

池组的使用寿命,从而为通信基站、机房等的蓄电池运维管理贡献一份力。

参考文献:

- [1] 段万普,郑路,李静. 蓄电池使用和维护[M]. 北京:化学工业出版社,2019:65-66.
- [2] 周明千,朱清峰.“双碳”目标下铅酸蓄电池健康管理研究[J]. 邮电设计技术,2022(12):57-62.
- [3] 乔波强,侯振义,王佑民. 蓄电池剩余容量预测技术现状及发展[J]. 电源世界,2012(2):21-26,35.
- [4] ZHOU W L, ZHENG Y P, PAN Z J, et al. Review on the battery model and SOC estimation method[J]. Processes, 2021, 9(9):1685.
- [5] LAIDIG M R, WURST J W. Technology implementation of stationary battery failure prediction[C]//Proceedings of 9th Annual Battery Conference on Applications and Advances. Long Beach, CA, USA: IEEE, 1994:168-172.
- [6] 龙顺游,李革臣,李中川,等. VRLA 蓄电池运行监测管理系统的研究[J]. 电源技术,2000,24(6):366-369.
- [7] 沈维祥. 基于开路电压和环境温度的铅酸蓄电池充电状态的数学模型[J]. 太阳能学报,1997(3):92-97.
- [8] 李正家. VRLA 蓄电池的寿命与在线容量判定[J]. 邮电设计技术,2001(2):38-43.
- [9] 朱瑞. 锂离子动力电池高精度建模与多状态估计方法研究[D]. 济南:山东大学,2021.
- [10] 何磊. 电动汽车锂离子电池建模及SOC估计方法研究[D]. 哈尔滨:哈尔滨工业大学,2012.
- [11] 白爽. 基于深度学习的锂离子电池寿命预测方法研究[D]. 哈尔滨:哈尔滨工业大学,2020.
- [12] YANG F F, SONG X B, XU F, et al. State-of-charge estimation of lithium-ion batteries via long short-term memory network[J]. IEEE Access, 2019, 7:53792-53799.
- [13] DUAN W X, SONG C X, PENG S L, et al. An improved gated recurrent unit network model for state-of-charge estimation of lithium-ion battery[J]. Energies, 2020, 13(23):6366.
- [14] ZHUANG F Z, QI Z Y, DUAN K Y, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2021, 109(1):43-76.
- [15] ZHOU K Y, LIU Z W, QIAO Y, et al. Domain generalization: a survey[J]. IEEE transactions on pattern analysis and machine intelligence, 2023, 45(4):4396-4415.
- [16] GHIFARY M, KLEIJN W B, ZHANG M J. Domain adaptive neural networks for object recognition[C]//PRICAI 2014: Trends in Artificial Intelligence. Cham:Springer, 2014:898-904.

作者简介:

李国庆,助理工程师,硕士,主要研究方向为自然语言处理领域,包括知识图谱,大型语言模型等;杨泽昆,助理工程师,硕士,主要从事计算机视觉相关算法工作;竹梦圆,工程师,硕士,主要从事计算机视觉、视频AI领域的算法研发工作;周明千,高级工程师,硕士,主要从事通信电源技术研究和双碳能源支撑工作。