



融合双模式超声成像与深度视觉的电池缺陷程度辨识方法

武予然¹, 李泽星¹, 王鹏博¹, 申梦圆¹, 牛靖凯², 妙珊²

(¹郑州电力高等专科学校, 河南 郑州 450000; ²郑州大学电气与信息工程学院, 河南 郑州 450001)

摘要: 为解决电池生产、运输及服役全周期的内外部缺陷检测难题, 提升缺陷评估的定量化精度与工程实用性, 本文提出一种融合双模式超声成像与深度视觉的电池缺陷程度辨识方法。首先, 基于超声透射扫描与反射扫描双模式成像技术, 结合多工况缺陷电池制备与数据增强方法, 以 36 块样本电池为对象, 构建覆盖气泡、磕碰、划痕、附着物、浸润度等典型缺陷的结构化图像数据库。其次, 设计基于深度学习与计算机视觉的电池缺陷辨识模型, 提出集成残差学习与注意力门控机制的 Attention Residual U-Net 缺陷分割网络, 通过残差块缓解梯度消失问题, 借助注意力门控强化缺陷区域特征, 实现对电池微小、不规则缺陷的精准分割。通过残差块缓解梯度消失问题, 借助注意力门控强化缺陷区域特征, 实现对电池微小、不规则缺陷的精准分割。最后, 基于 Attention Residual U-Net 输出的缺陷掩膜, 提取区域尺度、连通域聚集状态、线性连续性及空间分布等视觉信息, 采用 K-means 聚类确定各类缺陷的基础分级阈值, 并结合层次分析法 (AHP) 与故障模式及影响分析 (FMEA) 完成风险修正与权重分配, 将综合得分离散化为优质、良好、合格、风险四个质量等级, 实现缺陷程度的量化辨识与分级预警。经所构建包含 2500 余张缺陷图像数据库的实例验证, 该方法 mIoU 为 0.8783、Dice 系数为 0.9328, 可精准辨识电池内外部缺陷并量化状态等级, 为电池质量管控提供高效可靠的技术支撑。

关键词: 电池; 缺陷辨识; 超声检测; Attention Residual U-Net; 分级预警

doi: 10.19799/j.cnki.2095-4239.2026.0156

中图分类号: TM 92

文献标志码: A

文章编号: 2095-4239 (XXXX) XX-1-12

Method for Identifying the Degree of Battery Defects by Fusing Dual-Mode Ultrasonic Imaging and Deep Vision

WU Yuran¹, LI Zexing¹, WANG Pengbo¹, SHEN Mengyuan¹, NIU Jingkai², MIAO Shan²

(¹Zhengzhou Electric Power College, Zhengzhou 450000, Henan, China; ²School of Electrical and Information Engineering, Zhengzhou University, Zhengzhou 450001, Henan, China)

Abstract: To address the challenges of internal and external defect detection throughout the full life cycle of batteries including production, transportation and service, and to improve the quantitative accuracy and engineering practicability of defect evaluation, this paper proposes a battery defect degree identification method integrating dual-mode ultrasonic imaging and deep vision. Firstly, based on the dual-mode imaging technology of ultrasonic transmission scanning and reflection scanning, combined with the preparation of defective batteries under multiple working conditions and data augmentation methods, a structured image database

收稿日期: 2026-02-12; 修改稿日期: 2026-04-21。

基金项目: 国网河南省电力公司科技项目资助 (5217S0260005)。

第一作者: 武予然 (1981—), 女, 讲师, 研究方向为锂电池预警技术, E-mail: wuyuran@zpec.edu.cn; 通信作者: 妙珊 (1989—), 讲师, 研究方向为储能电池管理与控制, E-mail: miaos@zzu.edu.cn

引用本文: 武予然, 李泽星, 王鹏博, 等. 融合双模式超声成像与深度视觉的电池缺陷程度辨识方法[J]. 储能科学与技术, XXXX, XX(X): 1-12.

Citation: WU Yuran, LI Zexing, WANG Pengbo, et al. Method for Identifying the Degree of Battery Defects by Fusing Dual-Mode Ultrasonic Imaging and Deep Vision[J]. Energy Storage Science and Technology, XXXX, XX(X): 1-12.

covering typical defects such as air bubbles, mechanical indentation, scratches, surface attachments, and electrolyte infiltration uniformity was constructed based on 36 sample batteries. Secondly, a battery defect identification model based on deep learning and computer vision is designed, and an Attention Residual U-Net defect segmentation network integrating residual learning and attention gate mechanism is proposed. The residual block is adopted to alleviate the gradient vanishing problem, and the attention gate is utilized to enhance the features of defect regions, so as to achieve accurate segmentation of tiny and irregular defects in batteries. Finally, to realize quantitative identification and graded early warning of defect severity, the defect thresholds, score mapping rules, and weight allocation are quantified based on K-means clustering, Analytic Hierarchy Process (AHP), and Failure Mode and Effects Analysis (FMEA). Specifically, K-means clustering and normal distribution fitting are used to determine the natural thresholds of defect pixel areas; AHP is applied to quantify the impact weights of different defects; FMEA is adopted to analyze the failure modes, severity, and occurrence probability of each defect, and the score mapping rules are formulated to map defect parameters to quantitative scores. The comprehensive score is then discretized into four quality levels: Excellent, Good, Qualified, and Risk, realizing hierarchical early warning of battery states. Verified by the constructed database containing more than 2500 defect images, the proposed method achieves a mIoU of 0.8783 and a Dice coefficient of 0.9328. It can accurately identify internal and external battery defects and quantify state grades, providing efficient and reliable technical support for battery quality control.

Keywords: Battery; defect identification; ultrasonic detection; Attention Residual U-Net; graded warning

在全球能源结构向清洁化、低碳化转型的大背景下, 电池凭借其卓越的热稳定性、长循环寿命以及高性价比, 已成为新能源汽车动力系统和大规模储能电站的核心能源部件^[1]。但在生产环节中, 由于材料波动、设备精度不足或操作失误, 电池容易产生气泡、磕碰、电解液浸润不均等缺陷。这些问题不仅加速电池容量的衰减、缩短使用寿命, 还可能引发短路、热失控等严重安全隐患。因此, 精确高效的缺陷检测技术对于保障电池质量和安全至关重要^[2]。

当前, 传统的检测手段由于技术原理和设备限制, 难以全面满足电池的检测需求: 目视检查仅能识别表面缺陷, 如划痕、污渍等, 无法探测电池内部缺陷; X射线检测虽能探测内部缺陷, 但设备昂贵、操作环境要求严格^[3]; 红外热成像通过温差反映内部异常, 但对微小缺陷的定位精度不足且易受环境干扰^[4]; 电化学阻抗谱需要复杂的电极连接与校准, 且不适用于快速批量检测^[5]。总体而言, 这些传统方法的定位精度有限, 检测效率低, 难以满

足大规模生产对快速筛查与深度评估的需求^[6]。

随着新能源产业对电池质量要求的持续提升, 锂电池无损检测技术凭借非侵入、高精度、可实时监测的核心优势, 已成为电池质量评估、性能监测及故障诊断领域的研究热点^[7]。靳欣等^[8]采用超声检测仪追踪混合固液电解质锂离子电池全寿命周期内电解液的含量变化与分布特征, 结合热失控产气分析, 验证了电解液衰减规律及向固态转化的猜想, 为超声技术在电池电解液状态监测中的应用提供关键实验支撑。Ouyang^[9]等系统阐述超声技术基于声阻抗、飞行时间等参数, 在锂电池 SOC/SOH 估计、内部产气、异物识别、锂析出检测及热失控预警中的应用原理、技术路径与优化方案, 深入剖析结构适配性不足等技术瓶颈。朱建功等^[10]将超声检测纳入锂电池失效分析体系, 依托其非侵入特性实现电解液浸润状态与内部结构缺陷的精准监测, 为多维度传感网络构建提供技术参考。李龙飞^[11]则通过提取超声信号特征实现极片异常快速识别, 为制造缺陷早期筛查提供有效辅助, 完善了缺陷电池故

障诊断体系。Daniel Williams^[12]通过 100 次充电循环中电池 SOH 退化与超声信号 (TOF) 的强相关性, 证实超声波可有效监测锂离子电池退化速度。

现有研究已证实超声检测在电池缺陷识别中优势显著, 其与图像识别技术的融合更是成为无损检测领域研究热点, 相关研究通过改进深度学习架构实现了电池微小异物的超声图像智能识别^[13], 也依托光纤超声成像技术完成了电池内部缺陷的可视化监测^[14], 验证了技术融合的可行性。但现有超声图像处理方法仍难以解决缺陷精准量化问题, 成为工程化应用核心瓶颈: 传统计算机视觉方法对超声图像的散斑噪声、灰度不均鲁棒性差, 无法精准提取不规则缺陷轮廓; 常规 CNN 易因梯度消失丢失微小缺陷细节, 在“小缺陷、大背景”场景下漏检率高^[15]。同时, 现有研究多聚焦单一缺陷的定性检测, 尚未建立兼顾缺陷类型、形态特征与风险等级的量化评估体系。

在缺陷检测与评估的技术研究领域, 国内外学者也开展了大量相关探索。Zhang 等^[16]提出 DyAD 锂电池故障检测框架, 在海量数据上实现 88.6% 的 AUROC 值, 可降低故障检测成本 33%-50%; Kong 等^[17]构建锂电池微内部短路 (ISCr) 模型, 提出电化学阻抗谱 (EIS) 诊断方法, 实现毫秒级故障检测; Jiang 等^[18]提出 VMD-孤立森林故障诊断方法, 可提前 480s 检测电池故障, 且误报率低; Lu 等^[19]设计集成深度神经网络 (DNNs) 框架, 在跨制造商电池样本的状态评估中展现出优异的误差控制效果; Yao 等^[20]提出 CNN-WNN-WLSTM 混合模型, 在 NASA 电池数据集上的收敛速度与估计精度均优于单一模型; 张有兵等^[21]提出基于热电联合模型与深度学习的锂离子电池温度估计方法, 通过自适应遗忘因子递推最小二乘法进行参数辨识, 结合自适应权重物理信息神经网络融合物理约束与数据驱动优势, 为电池管理系统提供精准温度支撑。尽管现有研究取得了一定进展, 但在复杂缺陷的精准分割、多类型缺陷的量化评估及全流程自动化检测等方面仍存在提升空间, 亟需构建一套兼顾检测精度与工程实用性的协同检测及量化评估体系。

基于上述研究背景与核心问题, 本文紧扣电池内外部缺陷检测与评估需求, 提出一种融合双模式超声成像与深度视觉的缺陷程度辨识方法。首先, 依托超声透射扫描与反射扫描双模式成像技术, 建

立覆盖全场景缺陷的结构化图像数据库, 为缺陷程度辨识夯实数据基础; 其次, 构建基于深度学习与计算机视觉的电池缺陷辨识模型, 设计高精度 Attention Residual U-Net 分割网络, 实现微小、不规则缺陷的精准提取, 为后续缺陷区域尺度、形态及分布特征量化提供可靠边界依据; 最后, 融合 K-means 聚类、层次分析法 (AHP) 以及失效模式与影响分析 (FMEA) 方法, 建立综合评估体系, 实现电池不同类型、程度缺陷的量化辨识与分级预警。经实例验证, 所提方法具备有效性与可行性, 可为电池质量自动化、量化检测及分级管控提供技术支撑。

1 超声波扫描图像数据库构建

1.1 超声成像基本原理

超声无损检测利用超声波在声阻抗存在差异的介质界面处产生反射与折射的特性, 通过测量入射波与接收波的传播时间, 计算反射点与入射点的距离, 进而实现缺陷精准定位。检测时, 激励电源驱动导波探头发射超声波, 超声波在被检构件内传播, 途经气泡、磕碰等缺陷时, 因声阻抗突变产生反射信号; 导波探头接收信号后, 检测系统依据反射波的幅值、飞行时间等参数处理分析, 生成直观呈现构件内部结构与缺陷状况的检测图像。

该技术主要包含两类扫描模式 (扫描方式如图 1 (a) 所示): 其一为超声透射扫描, 采用“一发一收”双探头对穿式布局, 发射探头的超声波穿透被测电池后, 由接收探头接收并转换为电信号, 经处理生成图 1 (b) 所示的二维内部结构图像, 常用于电池一致性检测, 可识别分析电解液浸润情况、内部气泡等结构特征, 实现电池结构一致性评价; 其二为超声反射扫描, 采用单探头“自发自收”模式, 超声波传播过程中遇到声阻抗差异显著的界面时产生反射回波, 经探头接收、压电晶体转换及信号处理后, 生成图 1 (c) 所示的浅表面缺陷图像, 系统可依据回波特征参数定位缺陷, 该方法适用于电池厚度方向检测, 能捕捉微小结构异常与缺陷信号, 对磕碰、划痕等局部损伤具有高检测灵敏度。通过超声透射-反射融合扫描模式, 可实现内外部缺陷检测的优势互补, 全面覆盖电池全维度缺陷特征。

实验所用超声波检测技术的核心参数如下: 检




图1 双模式超声扫描原理 (a) 超声扫描设备工作方式示意图 (b) 超声透射扫描结果 (c) 超声反射扫描结果
Fig 1 Principle of Dual-mode Ultrasound Scanning (a) Schematic diagram of the working mode of the ultrasound scanning equipment (b) Result of ultrasound transmission scanning (c) Result of ultrasound reflection scanning

测范围 300 mm×250 mm，适配最大厚度≤30mm 的电芯；成像分辨率为 0.1 mm - 1 mm，检测分辨率达 0.5 mm，可满足电池高精度成像检测需求。双模式超声扫描结果分别为电池内部结构分析与表层缺陷评估提供了有力支撑。

1.2 缺陷电池制备与数据采集

如图2所示，所搭建实验平台的超声检测专用夹具可容纳厚度不超过 30 mm 的电池样品，为全面覆盖电池生产、运输及服役全周期的典型缺陷形态，本文选取 24 Ah 方壳磷酸铁锂电池（长度×厚度×高度：100×20×140 mm）作为实验基础样本，并基于该样本设计十类缺陷电池模型。

1.2.1 内部缺陷样本制备

内部缺陷直接影响电池的电化学性能与结构稳定性，其形成与电池生产、运输、服役全周期的电化学应力、环境应力及异常工况密切相关。为全面复刻真实场景下的缺陷类型，本文通过模拟常温循环、高温循环老化、低温循环老化、常温微短路故障、低温析锂故障、电池内部产气等不同工况下的电池损伤机制，制备了 22 块电池涵盖以上 6 类典型

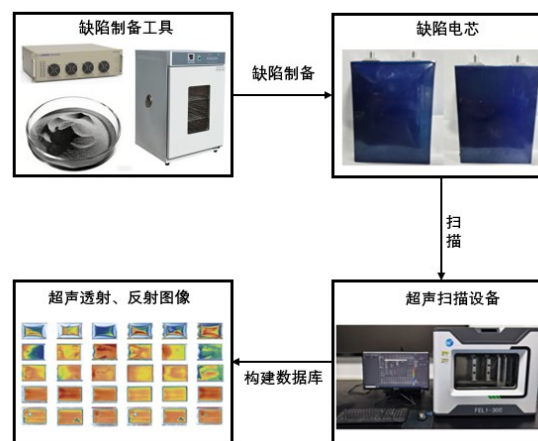


图2 基于双模式超声成像的缺陷图像数据库构建
Fig 2 Construction of the defect image database based on dual-mode ultrasound imaging

内部缺陷样本，如表 1 所示。

上述工况从“常规服役-极端环境-故障异常”三个维度，全面覆盖了电池全生命周期内内部缺陷的核心形成机制：既包含常温循环对应的“自然老化类缺陷”，也涵盖高低温环境诱发的“环境应激

表 1 电池内部缺陷样本制备

Table 1 Preparation of Sample for Internal Defects of Batteries

工况模拟	内部缺陷样本制备
常温循环测试	将电池置于常温（25℃）环境中，以 0.5C 在硅油介质中开展充放电循环实验，模拟电池在常规运行工况下的性能衰减过程
高温循环老化测试	将电池置于 50℃ 高温环境，以 1C 倍率开展循环老化实验，加速电池活性物质衰退、电解液分解等热致老化进程
低温循环老化测试	将电池置于 -5℃ 低温环境，以 1C 倍率开展循环老化实验，模拟电池在低温工况下的容量衰减规律与界面阻抗增长特性
常温微短路故障模拟	开启电池阀口并放入铁粉，随后在 25℃ 环境下以 1C 倍率进行充放电循环，模拟电池内部因异物入侵引发的局部放电现象
低温析锂故障模拟	打开电池阀口并放入 0.5g 铁粉，在 -2.5℃ 低温环境下开展充放电循环，通过低温工况与异物刺激的复合作用诱导电池内部析锂故障
电池内部产气模拟	通过对电池施加过充及过放循环的极端工况，主动诱导电池内部发生电解液分解、SEI 膜破裂等化学反应模拟电池在过充过放故障场景下的内部产气现象

类缺陷”，还囊括微短路、析锂、产气对应的“故障致命类缺陷”；从损伤本质来看，已覆盖“电化学老化（活性物质/SEI膜变化）、结构破坏（极片/隔膜损伤）、化学失效（电解液分解/产气）、异物诱导（微短路/析锂）”四大类内部缺陷的核心诱因，能够基本复刻电池可能出现的各类内部缺陷，为后续检测技术验证提供全面、真实的样本支撑。

1.2.2 浅表面缺陷样本制备

浅表面缺陷虽不直接影响电池初始电化学性能，但会破坏壳体防护完整性，加速外部环境对电池内部的侵蚀^[22]。本文通过受控机械作用、异物涂抹附着等方式制备了14块电池涵盖以上4类典型表层缺陷样本，如表2所示。

为了构建兼具完备性与有效性的图像数据集，本文以36块样本电池为对象，通过10种缺陷工况模拟、1200余圈循环测试，制备内部、浅表面缺陷电池。将制作好的缺陷电池固定于超声检测设备的专用夹具内，并完全浸没在硅油中。随后对检测参数进行精准调试，同时设定适配的探测深度和扫描分辨率，通过透射扫描与反射扫描的双模式成像技术，获取电池内部结构及表面状态的高精度超声图像。最后，以原始扫描图像为基础，结合数据增强技术扩充样本多样性，构建包含2500余张结构化图像的专用数据库。为保证模型评估的严谨性并实现物理层面的数据隔离，本文按照7:2:1的比例将数据集划分为训练集、验证集与测试集。同时，在36块样本电池中选取4块完全独立的全新物理电池进行典型缺陷制备，并单独作为测试集，确保测试集与训练集、验证集在物理样本上完全独立，为后续缺陷分割算法训练与验证提供充足、全面的数据源支撑。

2 电池缺陷辨识模型构建

2.1 基于深度学习的缺陷分割网络

针对超声图像中散斑噪声强、伪影干扰多、局

部灰度不均以及微小缺陷回波易淹没于背景的问题，本文研究了一种基于深度学习的缺陷分割方法。提出了集成残差学习与注意力门控机制的Attention Residual U-Net缺陷分割网络，在经典U-Net编码器-解码器对称结构基础上，通过在特征提取模块引入残差块缓解梯度消失问题、在跳跃连接层嵌入注意力门控单元强化缺陷区域特征，实现强散斑、多伪影及灰度不均干扰下电池微小不规则缺陷的精准鲁棒分割^[23]。

2.2 辨识模型架构

本文所构建的辨识模型在编码器端采用了深度残差学习机制，由三个连续的残差块构成特征提取的主干。残差块通过跳跃连接实现了特征的累加，其数学表达形式如下：

$$y = f(x, \{W_i\}) + W_s x \quad (1)$$

其中 x 和 y 分别代表该层的输入与输出向量， $f(x, \{W_i\})$ 表示经过两层卷积及激活函数处理后的残差映射，而 W_s 是为了匹配输入输出通道维度而设置的 1×1 卷积投影矩阵。

特征图通道数随采样深度依次由3演进至64、

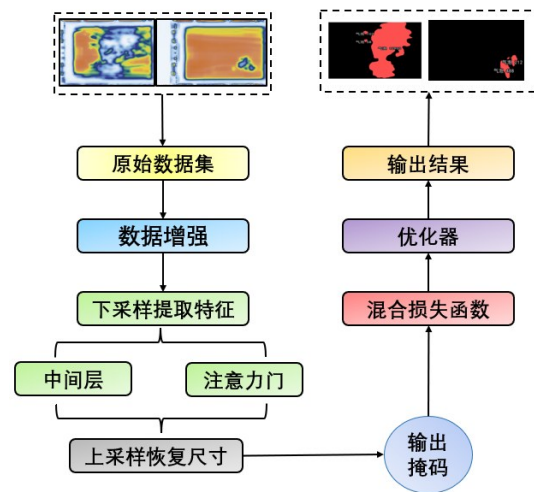


图3 模型整体架构图

Fig 3 Overall Architecture Diagram of the Model

表2 电池浅表面部缺陷样本制备

Table 2 Preparation of Battery Surface Defect Samples with Minor Surface Impairments

工况模拟	浅表面部缺陷样本制备
机械磕碰损伤测试	通过跌落、撞击、挤压等受控机械应力作用于电池，有针对性地造成电池壳体变形与内部结构物理损伤
表面划痕损伤测试	通过轻微摩擦、刮擦等受控方式在电池壳体表面制造不同深度与长度的划痕
表面附着物模拟	选取电池生产及应用场景中常见的污染物，通过定量涂抹、自然附着等方式固定于电池表面，模拟实际生产过程中可能出现的表面附着物缺陷
极耳脱落	沿极耳与极片连接界面施加可控横向剥离力，制备部分或完全脱落缺陷并修复外壳，完成极耳脱落缺陷样本制备。

128与256。每个残差块内部核心由两层 3×3 卷积构成，并嵌入组归一化（GroupNorm）与ReLU激活函数以维持特征分布的稳定性。引入了恒等映射（Identity Mapping）路径，当输入输出维度不一致时利用 1×1 卷积进行投影匹配，使梯度能够绕过非线性变换直接传导，显著缓解了深层网络中的梯度消失风险^[24]。在编码器末端的瓶颈层，模型部署了一个512通道的高阶残差块以提取深层语义信息。解码阶段则通过双线性上采样逐级恢复分辨率，并在跳跃连接处嵌入了注意力门控模块。该模块以深层特征作为门控信号，对浅层特征进行空间维度的权重重构，通过抑制背景噪声干扰并强化缺陷区域响应，显著提升了模型对不规则边缘的定位精度，其计算过程如下：

$$\alpha = \sigma(\psi(\delta(W_g^T g + W_x^T x + b_g)) + b_\psi) \quad (2)$$

$$\hat{x} = x \cdot \alpha \quad (3)$$

其中， δ 代表ReLU激活函数， σ 代表Sigmoid函数， W_g^T ， W_x^T 和 ψ 为线性变换操作， \hat{x} 是经过空间注意力加权后的特征，它显著增强了缺陷区域的特征表示。

2.3 训练策略

在数据预处理阶段，首先针对工业缺陷图像分辨率不一致的问题，将所有原始样本统一重采样至 256×256 像素尺寸。为确保空间几何变换过程中标签逻辑的严谨性，图像分支采用双线性插值实现特征的平滑过渡，标签掩膜则严格采用最近邻插值，有效避免缺陷边缘出现非真实的中间过渡类别像素^{[25][26]}。

针对小样本场景下易出现的过拟合问题，本文实施深度离线数据增强策略：在空间维度，通过随机水平/垂直翻转、 $\pm 12^\circ$ 范围内的小角度旋转、0.85~1.15倍率的随机缩放裁剪，模拟流水线生产

中工件位置与形态的自然多样性；在光度维度，以0.7的概率进行亮度与对比度随机抖动，并叠加均值为0、标准差3~10的高斯噪声，降低模型对特定成像环境及传感器噪声的依赖，使网络聚焦于学习更具鲁棒性的缺陷本质纹理与几何特征。数据集中部分预处理后图像如图4所示。

本文采用Adam优化算法，其具备自适应学习率调整特性，初始学习率设定为 1×10^{-4} ，以兼顾训练前期的收敛速度与后期的精细寻优。针对工业检测中典型的“小样本、大背景”类别失衡问题，采用耦合交叉熵（Cross-Entropy）与Dice系数的复合损失函数。复合损失函数的定义如下：

$$y = f(x, \{W_{ij}\}) + W_s x \quad (4)$$

$$L_{Total} = L_{CE} + \lambda L_{Dice} \quad (5)$$

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N p_i y_i + \varepsilon}{\sum_{i=1}^N p_i + \sum_{i=1}^N y_i + \varepsilon} \quad (6)$$

其中， p_i 是预测概率， y_i 是真实标签， ε 是平滑因子， L_{CE} 为交叉熵损失， λ 为Dice损失的权重系数。

2.4 模型比较与验证

为了客观评估模型对电池缺陷的分割性能，本文选取了语义分割中常用的评价指标：平均交并比和Dice系数，其公式如下：

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}} \quad (7)$$

其中， k 代表总的类别数量， i 代表真实的类别， j 代表预测的类别， p_{ii} 代表真正例， p_{ji} 代表假负例。

$$Dice = \frac{2|X \cap Y|}{|X| + |Y|} \quad (8)$$

其中， X 代表真实标签的像素集合， Y 代表模型预测的像素集合。




图4 数据集中的部分图片 (a) 部分超声扫描图像 (b) 部分数据增强后图像

Fig 4 Some images from the dataset (a) Some ultrasound scan images (b) Some images after data augmentation

为了验证本文提出的 Attention Residual U-Net 算法的有效性，将其与基本 U-Net 网络在相同的电池缺陷数据集上进行了对比实验，结果分别如表 3 和表 4 所示。

表 3 模型比较结果

Table 3 Model Comparison Results

模型	mIoU	Dice	Accuracy
本文提出的 U-Net 模型	0.8783	0.9328	0.9568
基本 U-Net 模型	0.289	0.457	0.9360

表 4 模型验证结果

Table 4 Model Verification Results

模型	气泡	磕碰	划痕	附着物	背景
本文提出的 U-Net 模型	0.8253	0.8522	0.8064	0.963	0.9963
基本 U-Net 模型	0.4353	0.421	0.456	0.3237	0.9365

从表 3 可以看出，本文提出的 Attention Residual U-Net 在各项关键指标上均实现了更优的性能。这表明，依靠注意力机制和结合残差结构能进一步解决深层网络的退化问题，从而显著提升特征提取的鲁棒性。虽然基本 U-Net 的像素准确率达到了 93.60%，但其 mIoU 极低，这说明了由于背景占比极大，而缺陷的占比很小，U-Net 模型倾向于将所有像素预测为背景。而本文模型在保持 95.68% 准确率的同时，mDice 达到了 0.9328，说明模型实现了对前景缺陷的有效分割。

同时表 4 表明，基本 U-Net 在面对极微小或特征不明显的缺陷时识别性能很差，而 Attention Residual U-Net 证明了残差连接带来的梯度传导优势，使得网络能够学习到更精细的缺陷边界，有效缓解了小样本类别易出现的漏检问题，显著提升了

缺陷识别的完整性与可靠性。

为了更直观的对比所提出的 Attention Residual U-Net 模型与基本 U-Net 模型之间的差别，本文基于 PyQt5 框架实现电池缺陷分割的可视化分析系统，该系统针对每个独立的缺陷连通域，系统自动计算其平均预测置信度，并在区域中心标注缺陷类别与置信度，支持图像加载、结果导出，并实时显示全局平均置信度及各类缺陷的像素面积占比。

对比图 5 (b)、(c) 可见，本文提出的 Attention Residual U-Net 检测定位更精准、置信度更高，且其输出的像素级缺陷掩膜，能为后续缺陷程度量化提供稳定的区域边界，实现从缺陷检测到缺陷程度辨识的延伸。

3 基于深度视觉特征量化的缺陷程度辨识与评估

基于双模式超声扫描结构化图像数据库支撑及 Attention Residual U-Net 的精准分割结果，本文构建了面向电池缺陷程度辨识的量化评估体系。与仅依据缺陷像素面积简单评分的方式不同，本文以分割网络输出的缺陷掩膜为量化分析基础，进一步统计各类缺陷的面积占比、连通域数量、长度特征及边界连续性等核心信息。针对不同缺陷类型，选取与其失效机理适配的量化指标：气泡与附着物重点关注面积占比及区域分布特征，磕碰缺陷聚焦面积及边界不规则程度，划痕缺陷侧重长度与线性连续性，浸润异常则关注低回波区域占比及分布均匀性。在此基础上，融合 K-means、层次分析法

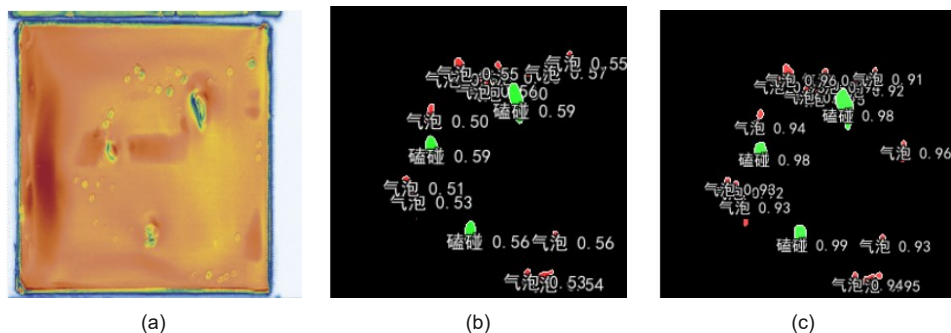


图 5 基于 U-Net 的缺陷分割与基于 Attention Residual U-Net 的缺陷分割对比 (a) 超声扫描图像 (b) 改进前置置信度 (c) 改进后置置信度

Fig 5 Comparison of defect segmentation based on U-Net and defect segmentation based on Attention Residual U-Net (a) Ultrasound scan image (b) Improved pre-confidence (c) Improved post-confidence

于质量管控人员快速理解分值与风险的对应关系，降低实际应用门槛；二是能精准匹配缺陷危害的渐进特性缺陷程度从轻微到严重的演化过程呈连续变化，线性分值梯度可客观反映这种渐进式风险提升，避免非线性映射可能导致的风险误判；三是结合故障模式与影响分析（Failure Mode and Effects Analysis FMEA）结果，确保扣分幅度与风险优先级（Risk Priority Number RPN）强相关，即高风险缺陷（如磕碰、严重气泡）对应更陡峭的分值下降，低风险缺陷（如附着物）分值衰减平缓，实现“风险越高、扣分越显著”的量化逻辑。

具体地，分数映射的等级划分与扣分幅度设定，依据“风险等级-损失程度”匹配模型，通过FMEA梳理各类缺陷的故障表现与危害路径，量化严重程度与发生概率并计算RPN，据此确定各等级扣分幅度：正常等级保持100分（无缺陷满分基准），轻微风险等级扣分15-35分（缺陷存在但不影响核心功能），中度风险等级扣分35-65分（显著影响电池性能与稳定性），严重风险等级扣分65-95分（强化致命安全隐患警示），最终确保分值梯度与实际风险危害程度呈正相关，各类缺陷具体阈值划分与分数映射如表5所示。

3.2 权重分配与综合得分计算

权重分配以“风险优先级+预警时效性”为核心，经AHP量化验证匹配缺陷实际危害程度。评分体系遵循“安全风险优先、结构完整性次之、表层质量为辅”原则，附着物等非结构性表层缺陷虽影响总分，但不单独主导等级判定，仅在伴随壳体损伤、内部异常等情况时，才对风险等级进行上调。

气泡缺陷：与电解液浸润不均及内部产气直接相关，长期服役易导致极片接触不良、热场分布失衡，进而加速电池性能衰减，权重占比设定为30%；

磕碰缺陷：直接造成极片位移、隔膜破损，是诱发短路与热失控的核心风险源，安全危害程度最高，权重占比设定为40%；

划痕缺陷：破坏壳体防护完整性，加速外部水汽、杂质侵入，间接影响电池服役稳定性，且不直接引发安全事故，权重占比设定为10%；

附着物缺陷：仅影响电池表面清洁度，对内部结构与电化学反应性能无直接干扰，风险影响最为缓

和，权重占比设定为5%；

浸润度缺陷：直接影响电解液传导效率与极片反应均匀性，显著缩短电池循环寿命，对核心性能影响关键，权重占比设定为15%。

经AHP构建判断矩阵并通过一致性检验（CR < 0.1），上述权重分配逻辑严密，符合“安全优先、性能为辅”的电池质量评估需求。缺陷量化评估综合得分（ D_x ）通过加权求和得到，公式如下：

$$D_x = 30\% \times D_{1x} + 40\% \times D_{2x} + 10\% \times D_{3x} + 5\% \times D_{4x} + 15\% \times D_{5x} \quad (9)$$

其中， D_x 为缺陷量化评估综合得分， D_{1x} 为气泡缺陷得分， D_{2x} 为磕碰缺陷得分， D_{3x} 为划痕缺陷得分， D_{4x} 为附着物缺陷得分， D_{5x} 为浸润度得分。

综合得分满分为100分，按得分区间划分为四个电池质量等级，其中90分及以上为优质等级，缺陷风险极低且各项性能指标优异，可直接投入使用；80-89分为良好等级，存在极轻微缺陷但不影响电池核心性能与安全，建议常规巡检；60-79分为合格等级，存在轻微缺陷且可能影响长期服役稳定性，需定期专项监测；低于60分为风险等级，存在严重缺陷且易引发性能衰减或安全隐患，需检修维修或直接淘汰。

3.3 缺陷辨识量化评估

为使评估结果更直观量化，将原可视化系统中的预测置信度替换为缺陷像素面积，通过精准量化各类缺陷的物理规模，直接反映其对电池结构与性能的实际影响程度，为电池综合得分的计算与质量等级的精准辨识提供更客观、可追溯的核心依据。

如图6（a）、（b）所示，为同一块电池的超声透射图像、超声反射图像及经Attention Residual U-Net分割算法提取的缺陷结果。结合分割结果与区域形态分析可量化获取：电池内部气泡区域尺度为700 px，且主要呈局部聚集分布，但尚未形成大面积连片；表面磕碰缺陷区域尺度为108 px，边界存在轻度不规则特征；表面划痕缺陷区域尺度为119 px，呈短线状分布且连续性有限；同时测得电芯电解液浸润均匀性为86%，处于85%~95%区间。对照表5所示的风险等级划分标准，进一步确定各类缺陷对应的量化得分： $D_{1x}=40$ ， $D_{2x}=65$ ， $D_{3x}=75$ ， $D_{4x}=100$ ， $D_{5x}=75$ 。综上得出：

$$D_x = 30\% \times 40 + 40\% \times 65 + 10\% \times 75 + 5\% \times 100 + 15\% \times 75 = 61.75 \quad (10)$$




图6 合格等级电池超声扫描与分割结果 (a)透射扫描图像 (b)反射扫描图像

Fig 6 Ultrasonic scanning and segmentation results of qualified grade batteries (a) transmission scanning image (b) reflection scanning image

该电池属于合格电池，存在轻微缺陷且可能影响长期服役稳定性，需定期专项监测。

基于图7 (a)、(b) 同一块严重缺陷电池的超声扫描图像及分割结果可知：电池内部气泡区域尺度为 13063 px，且呈明显的大面积连片聚集分布；表面磕碰缺陷区域尺度为 1429 px，局部边界破坏明显并伴随较强不规则形变；未检测到划痕与附着物缺陷，且浸润度 < 80%，表明低回波异常区域已出现较大范围分布。对照表5标准，判定气泡、磕碰及浸润度缺陷均为严重风险等级，划痕与附着物为正常等级，依据阈值-分数映射规则确定各类缺陷得分： $D_{1x}=10$ ， $D_{2x}=5$ ， $D_{3x}=100$ ， $D_{4x}=100$ ， $D_{5x}=15$ 。综上得出：

$$D_x = 30\% \times 10 + 40\% \times 5 + 10\% \times 100 + 5\% \times 100 + 15\% \times 15 = 22.25 \quad (11)$$

该电池远低于合格电池标准，属于风险电池，存在严重缺陷且易引发性能衰减或安全隐患，需复检维修或直接淘汰。

图8 (a)、(b) 分别为电池的超声透射与反射扫描图像，图 (c) 为反射图像经 Attention

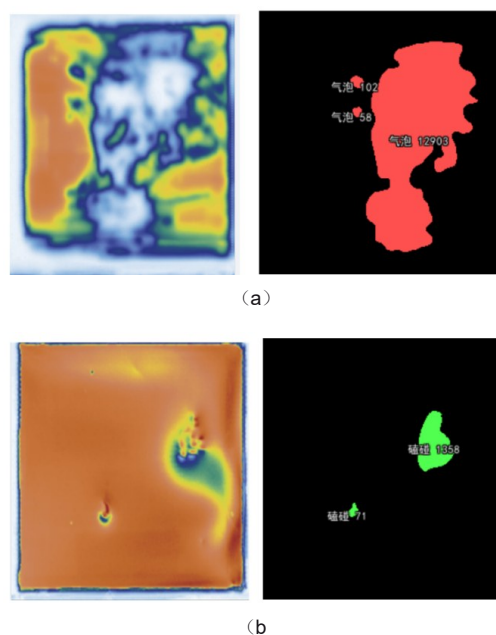


图7 严重缺陷等级电池超声扫描与分割结果 (a)透射扫描图像 (b)反射扫描图像

Fig 7 Ultrasonic scanning and segmentation results of batteries with severe defect grades (a) Transmission scanning image (b) Reflection scanning image

Residual U-Net 分割算法提取的缺陷分割结果。结果显示：电池表面附着物缺陷区域尺度为 4910 px，整体呈面状覆盖分布，但边界相对清晰，未表现出磕碰、划痕等结构性损伤特征；未检测到气泡、磕碰、划痕缺陷，电芯电解液浸润均匀性为 94%，整体浸润状态较为稳定。对照表5风险等级划分标准，综合判定： $D_{1x}=100$ ， $D_{2x}=100$ ， $D_{3x}=100$ ， $D_{4x}=35$ ， $D_{5x}=75$ 。综上得出：

$$D_x = 30\% \times 100 + 40\% \times 100 + 10\% \times 100 + 5\% \times 35 + 15\% \times 75 = 93 \quad (12)$$

该样本在现行综合权重体系下仍满足优质等级判定标准。虽然表面附着物覆盖范围较大，但其主要表现为可清理的表层附着异常，未伴随内部结构损伤、高风险机械缺陷或显著浸润异常，因此对电池本体安全性与核心性能的影响有限。经清除附着物并复核壳体完整性后，可投入使用。

4 结论

本文针对电池全生命周期内外部缺陷检测与量化评估难题，提出融合双模式超声成像与深度视觉




图8 优质等级电池超声扫描与分割结果(a)透射扫描图像 (b)反射扫描图像 (c)反射图像分割结果

Fig 8 Ultrasonic scanning and segmentation results of high-quality grade batteries (a) Transmission scanning image (b) Reflection scanning image (c) Segmentation result of reflection image

的电池缺陷程度辨识方法。构建 36 块覆盖十类典型缺陷的缺陷电池样本，经双模式超声扫描与数据增强，形成包含 2500 余张图像的专用超声数据库，全面覆盖磷酸铁锂电池生产与服役全周期典型缺陷形态；设计 Attention Residual U-Net 网络，其 mIoU 达 0.8783、Dice 系数 0.9328，精准分割微小不规则缺陷；基于 K-means 聚类、AHP 及 FMEA 方法，建立含权重分配、分数映射的三级量化体系，划分四类质量等级。实例验证显示，本文方法可以精准辨识缺陷并量化风险，三类电芯分别判定为合格、风险、优质等级，评分与实际状态高度契合，有效弥补了传统检测短板，为实现电池质量管控的自动化、标准化与智能化转型提供了关键技术基础。

参考文献

- [1] Xie Yuxi, Xu Xiang, Liu Shiyao. Machine vision-based detection of surface defects in cylindrical battery cases[J]. *Journal of Energy Storage*, 2024, 101: 113949.
- [2] de Lime A B, Lein T, Maletti S, et al. Impact of electrode defects on battery cell performance: a mini review[J]. *Batteries & Supercaps*, 2022, 5: e202200239.
- [3] Phillips V A, Hugo J A. X-ray Hazard from Electron Microscopes [J]. *Science*, 1964, 143: 1120-1121.
- [4] Qu Zhe, Jiang Peng, Zhang Wei. Development and Application of Infrared Thermography Non-Destructive Testing Techniques[J]. *Sensors*, 2020, 20: 3851.
- [5] Nara H, Yokoshima T, Osaka T. Technology of electrochemical impedance spectroscopy for an energy-sustainable society[J]. *Current Opinion in Electrochemistry*, 2020, 20: 66-77.
- [6] Chacon X C A, Laureti S, Ricci M, et al. A review of non-destructive techniques for lithium-ion battery performance analysis[J]. *World Electric Vehicle Journal*, 2023, 14:305.
- [7] 郝奕帆, 祝夏雨, 王静, 等. 电池无损检测监测方法分析[J]. *储能科学与技术*, 2023, 12(5):1713-1737.
- HAO Yifan, ZHU Xiayu, WANG Jing, et al. Analysis of non-destructive testing and monitoring methods for batteries[J]. *Energy Storage Science and Technology*, 2023, 12(5): 1713-1737.
- [8] 靳欣, 张建茹, 王其钰, 等. 混合固液锂离子电池的热失控行为研究[J]. *储能科学与技术*, 2024, 13(1): 48-56.
- JIN Xin, ZHANG Jianru, WANG Qiyu, et al. Study on thermal runaway behavior of hybrid solid-liquid lithium-ion batteries[J]. *Energy Storage Science and Technology*, 2024, 13(1): 48-56.
- [9] Wang Yong, Lai Xin, Chen Qiang, et al. Progress and challenges in ultrasonic technology for state estimation and defect detection of lithium-ion batteries[J]. *Energy Storage Materials*, 2024, 69: 23.
- [10] Jia Xianyi, Zhu Jiangong, Michael Knapp, et al. A review of battery failure: classification, mechanisms, analysis, and management[J]. *Renewable and Sustainable Energy Reviews*, 2024, 207: 113949.
- [11] 李龙飞, 郑永泉, 万旺军, 等. 锂离子电池缺陷检测技术及失效机理分析研究进展 [J]. *材料导报*, 2025.
- LI Longfei, ZHENG Yongquan, WAN Wangjun, et al. Research progress on defect detection technology and failure mechanism analysis of lithium-ion batteries[J]. *Materials Reports*, 2025.
- [12] Williams D, et al. Battery age monitoring: Ultrasonic monitoring of ageing and degradation in lithium-ion batteries[J]. *Journal of Power Sources*, 2025, 596: 234028.
- [13] Peruñ G. Advances in Non-Destructive Testing Methods[J]. *Materials*, 2024, 17: 554.
- [14] Geng Chen, Wang Anqi, Zhang Yi et al. Operando monitoring of state of health for lithium battery via fiber optic ultrasound imaging system, 2025.
- [15] Riaz W, Qi X, Ji J, et al. Multi-Scale Feature Convolutional Modeling for Industrial Weld Defects Detection in Battery Manufacturing[J]. *Fractal and Fractional*, 2025, 9: 611.
- [16] Zhang Jing, Wang Yong, Jiang Bo, et al. Realistic fault detection of li-ion battery via dynamical deep learning[J]. *Nature Communications*, 2023, 14(1): 5940.
- [17] Kong Xin, Plett G L, Trimboli M S, et al. Pseudo-two-dimensional model and impedance diagnosis of micro internal short circuit in lithium-ion cells[J]. *Journal of Energy Storage*, 2020, 27: 101085.
- [18] Jiang Jun, Li Tao, Chang Chao, et al. Fault diagnosis method for lithium-ion batteries in electric vehicles based on isolated forest algorithm[J]. *Journal of Energy Storage*, 2022, 50: 104177.
- [19] Lu Jun, Xiong Rui, Tian Jun, et al. Deep learning to estimate lithium-ion battery state of health without additional degradation experiments[J]. *Nature Communications*, 2023, 14: 2760.
- [20] Yao Qiang, Song Xin, Xie Wei. State of health estimation of lithium-ion battery based on CNN - WNN - WLSTM[J]. *Complex & Intelligent Systems*, 2024, 10: 2919-2936.
- [21] 张有兵, 鲍俊挺, 潘红武, 等. 基于热电联合模型和深度学习的锂离子电池温度估计方法[J/OL]. *储能科学与技术*, 2026, 1-13.
- ZHANG Youbing, BAO Juntong, PAN Hongwu, et al. Lithium-ion battery temperature estimation method based on thermoelectric coupling model and deep learning[J/OL]. *Energy Storage Science and Technology*, 2026, 1-13.

- [22] Jia Yu, et al. Safety issues of defective lithium-ion batteries: identification and risk evaluation[J]. *Journal of Materials Chemistry A*, 2020, 8(25): 12472-12484.
- [23] Zhang Jing, Lv Xin, Zhang Hao, Liu Bo. AResU-Net: Attention residual U-Net for brain tumor segmentation[J]. *Symmetry*, 2020, 12(5): 721.
- [24] Guo Chao, Szemenyei M, Hu Yu, Wang Wei, Zhou Wei, Yi Yu. Channel Attention Residual U-Net for Retinal Vessel Segmentation[C]. ICASSP 2021, Toronto, Canada, 2021: 1185-1189.
- [25] 贾九汇, 林赞, 叶盛波, 等. 基于注意力残差 U-Net 的探地雷达杂波抑制方法 [C]// 中国电子学会电波传播分会, 西安电子科技大学. 第十九届全国电波传播年会论文集. 北方工业大学; 中国科学院空天信息创新研究院, 2025: 615-618.
- JIA Jiuhui, LIN Yun, YE Shengbo, et al. Ground penetrating radar clutter suppression method based on attention residual U-Net [C]//Radio Wave Propagation Branch of Chinese Institute of Electronics, Xidian University. Proceedings of the 19th National Radio Wave Propagation Conference. North China University of Technology; Aerospace Information Research Institute, Chinese Academy of Sciences, 2025: 615-618.
- [26] 王丽娜, 孙阳, 张红春, 等. 基于注意力的多尺度残差 U-Net 的海洋中尺度涡检测[J]. *海洋与湖沼*, 2025, 56(1): 64-76.
- WANG Lina, SUN Yang, ZHANG Hongchun, et al. Ocean mesoscale eddy detection based on attention multi-scale residual U-Net[J]. *Oceanologia et Limnologia Sinica*, 2025, 56(1): 64-76.