

DOI: 10.13382/j.jemi.B2508596

# 动态信息熵电动卡车锂电池故障检测\*

熊学涛<sup>1,2</sup> 张艳辉<sup>2</sup> 黄崇亨<sup>1</sup> 冯威<sup>2</sup> 李晓宇<sup>3</sup>

(1. 桂林理工大学机械与控制工程学院 桂林 541006; 2. 中国科学院深圳先进技术研究院 深圳 518067;

3. 深圳大学 深圳 518066)

**摘要:** 锂离子电池驱动的卡车作为重型电动商用车领域的新兴类别,其深度应用对我国加速交通运输领域“双碳”目标落地具有重要意义。然而,重型电动商用车在大电流充电过程中存在电池状态误报问题,引发不必要的停机,故障诊断准确性和运营效率低的问题。为解决上述问题,提出了一种基于卷积神经网络(CNN)、长短期记忆网络(LSTM)和动态自编码器(DYAD)融合的电池故障检测方法,用于解决电池状态变化与累积故障效应问题。采用编码器-解码器架构,利用CNN提取电池数据的空间特征,通过LSTM网络捕捉时间序列的动态演化规律,并借助DYAD信息熵处理电池系统的非线性特性,从而实现复杂故障模式的深度学习。模型架构通过CNN与LSTM的融合,有效提取了时空特征,引入多模态解耦技术实时监测关键特征误差,并结合全局可解释性分析与潜在空间可视化,显著提升了模型可信度与透明度。实验结果表明,该方法在真实数据集上达到了88.7%的受试者工作特征曲线下面积(AUROC),相比图动态网络(GDN)提升26.2%;通过重构误差分析,显著减少了因大电流充电事件引发的虚假报警,并实现了故障早期检测。

**关键词:** 重型电动商用车; 动态自编码器; 信息熵; 模型可解释性; 多模态解耦

**中图分类号:** TM912.9; TN911.23 **文献标识码:** A **国家标准学科分类代码:** 530

## Dynamic information entropy for lithium battery fault detection in electric trucks

Xiong Xuetao<sup>1,2</sup> Zhang Yanhui<sup>2</sup> Huang Chongheng<sup>1</sup> Feng Wei<sup>2</sup> Li Xiaoyu<sup>3</sup>

(1. College of Mechanical and Control Engineering, Guilin University of Technology, Guilin 541006, China;

2. Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518067, China;

3. Shenzhen University, Shenzhen 518066, China)

**Abstract:** Lithium-ion battery-powered trucks, as an emerging category in the field of heavy-duty electric commercial vehicles, their in-depth application is of great significance for China to accelerate the implementation of the “dual carbon” goals in the transportation sector. However, heavy-duty electric commercial vehicles have the problem of false battery status alarms during high-current charging, which leads to unnecessary shutdowns, low accuracy in fault diagnosis and low operational efficiency. To address the above issues, this paper proposes a battery fault detection method based on the fusion of convolutional neural network (CNN), long short-term memory network (LSTM), and dynamic autoencoder (DYAD), which is used to solve the problems of battery state changes and cumulative fault effects. The encoder-decoder architecture is adopted. The spatial features of battery data are extracted by CNN, the dynamic evolution law of time series is captured by LSTM network, and the nonlinear characteristics of the battery system are processed with DYAD information entropy, thereby achieving deep learning of complex fault modes. The model architecture effectively extracts spatio-temporal features through the integration of CNN and LSTM, introduces multimodal decoupling technology to monitor key feature errors in real time, and combines global interpretability analysis and potential spatial visualization, significantly enhancing the credibility and transparency of the model. The experimental results show that this method achieves an area under the receiver operating characteristic

收稿日期: 2025-07-24 Received Date: 2025-07-24

\* 基金项目: 国家自然科学基金面上项目(52177219)、广东省基础与应用基础研究基金(2023A1515240014)、深圳市科技计划重点项目(JCYJ20220818103416035)资助

curve (AUROC) of 88.7% on the real dataset, which is 26.2% higher than that of the graph dynamic network (GDN). By reconstructing error analysis, false alarms caused by high-current charging events have been significantly reduced, and early fault detection has been achieved.

**Keywords:** heavy-duty electric commercial vehicles; dynamic autoencoder; information entropy; model interpretability; multimodal decoupling

## 0 引言

当前行业监测数据显示,商用电动卡车的实际利用率仅为同级柴油车的 23%~30%,这意味着需要部署 3.6~3.8 辆电动车才能完成一辆柴油车的工作量,这构成了当前电动货运领域最核心的运营瓶颈<sup>[1]</sup>。这种低利用率直接引发了两大严峻挑战:1) 经济成本激增,车辆为弥补运力缺口而高强度运行,导致电池更换频繁,其费用可高达车辆本身价值的 40%~50%,严重削弱了电动车的经济性;2) 环保效益缩水,实际运营中的低效,使得车辆全生命周期的碳排放减少量比理论预测值低了 17%~29%,未能充分实现电动化的环保初衷。尽管在优化场景下,电动卡车可展现出 15%~54% 的运营成本优势,但这一潜力在特定场景下难以释放。特别是电动重卡,其使用场景(如矿山运输)具有高负荷、长时间、高强度的特点,与乘用车截然不同。这种极端工况对电池系统的工作强度和耐久性提出了远超常规的挑战,预示着其潜在的故障率可能更高,进一步加剧了上述的经济与环保问题。鉴于电动矿用卡车独特的运行模式和高故障风险,沿用通用的检测方法已不足以应对。因此,需针对其应用场景,开发专门的故障检测模型。该模型旨在提前预警和诊断潜在故障,从而提高车辆可靠性、降低非计划停运时间、控制维护成本,真正释放电动重卡在商业运营中的价值。

近年来,国内外学者对锂离子电池故障检测与诊断进行了广泛研究。在国际上,Ojo 等<sup>[2]</sup>提出了一种基于神经网络的锂离子电池热故障检测方法,通过学习温度分布模式实现故障识别。Li 等<sup>[3]</sup>开发了基于多维长短期记忆网络(MD-LSTM)的锂离子电池定量故障诊断方法,该模型捕捉时间序列数据中的动态变化,提高了故障量化精度。这些方法虽有效捕捉了电池的热、电压和内部短路故障,但对累积效应和超级充电场景下的非线性动态建模仍不足,容易导致虚假报警,且模型可解释性较低。

在国内,杨彦茹等<sup>[4]</sup>提出基于完备集合经验模态分解(CEEMDAN)和支持向量回归(SVR)的锂离子电池剩余使用寿命预测方法,通过信号分解提取特征,提高了预测准确性,但未充分考虑大电流充电下的累积故障效应。王君瑞等<sup>[5]</sup>开发了基于鲸鱼优化算法优化的变分模态分

解(WOA-VMD)和粒子群优化支持向量机(PSO-SVM)的锂离子电池内短路故障诊断方法,通过优化分解参数提取样本熵特征向量,实现诊断准确率 96.667%,显著优于支持向量机标准(SVM)。李振宇等<sup>[6]</sup>提出了一种海上平台直流微网系统复合型短路故障检测方法,该方法结合电流差动法与方向电流法,根据电流基本定律、各支路故障电流方向特性及变化量大小,实现对母线和支路短路故障的快速检测,这也为本文研究电池故障检测提供新思路,构建关键特征电压差作为模型训练输入,这些国内研究强调了优化算法在故障诊断中的应用,但仍存在对多模态数据融合和模型透明度的不足,特别是在电动卡车高负载场景下,误报问题突出,有待引入信息熵提取和自适应阈值等新方法进行改进。

现有电池故障检测系统面临 3 大关键局限性:1) 电池故障通常由多个时间点的累积效应和非线性动态变化引起,单一时间点的数据分析不足以表征长时间运行中复杂的故障演化过程;2) 当前深度学习算法通过学习数据集分布来检测异常,但在罕见充电模式下(如电动矿用卡车常见的高电流超级充电场景),可能将健康电池误分类为故障电池;3) 现有深度学习框架在决策过程中的可解释性不足,限制了其在关键电池管理任务中的可靠性和实际适用性。

为解决问题 1,本文提出了一种整合累积故障效应和非线性动态的演化过程分析方法。采用卷积神经网络(CNN)、LSTM 架构结合动态自编码器(DYAD),从充电片段中提取关键特征熵。通过对故障和正常电池特征簇的比较分析,确定模型适应的最优特征组合。对于问题 2,本文开发了一种时间序列自适应阈值重构误差评分方法,通过累积充电片段评分评估电池健康状况,有效缓解高电流超级充电场景中的误分类问题。对于问题 3,通过对损失函数、潜在空间分布和关键特征拟合度的可视化分析,增强模型的可解释性,从而实现直观的操作理解并提高决策过程的透明度。

## 1 CNN-LSTM 结合动态自编码器模型

### 1.1 CNN-LSTM 结合动态自编码器特征提取方法

为电动卡车锂电池故障检测开发的 CNN-LSTM 与 DYAD 集成的框架如图 1 所示。在特征提取阶段,输入数据来源充电片段的电压、电流、荷电状态(state of

charge, SOC) 等时间序列信号。随后, CNN 模块被用于捕获电池动态数据中的局部模式。CNN 通过卷积操作识别高维数据中的空间层次和局部相关性,能够有效检测电池退化的早期迹象,例如微小的电压波动或异常的温度分布<sup>[7-9]</sup>。然后, LSTM 网络对时间依赖性和全局动态特性进行建模。LSTM 擅长处理时间序列数据,能够追踪电池状态随时间的变化,捕捉可能预示故障的长期依赖关系,识别可能预示故障的潜在模式,例如持续的容量衰减或异常的内阻增长,从而为故障检测提供关键支持<sup>[10-12]</sup>。随后, DYAD 进行对捕捉了空间和时间的关系信息进行编码特征提取包括信息熵和相空间特征在内的电池健康关键信息。信息熵衡量电池状态的不确定性或

无序程度,是检测异常的敏感指标;相空间特征则源于动态系统理论,揭示电池运行模式及其转变,帮助识别偏离正常行为的细微变化。在动态自编码器训练阶段,本文引入 3 种损失函数作为模型优化约束,包括标签损失、变分正则化损失和对数似然损失。其中,标签损失通过监督信号引导模型学习故障与正常状态的区分边界,减少分类误差;变分正则化损失 (Kullback-Leibler) 通过最小化潜在空间分布与先验分布的差异,确保编码器的泛化能力;对数似然损失则聚焦于重构误差的量化。这些损失函数的联合应用,不仅有效捕捉了锂电池动态的非线性特征和累积故障效应,还显著提升了模型在高电流充电场景下的抗误报性能<sup>[13-15]</sup>。

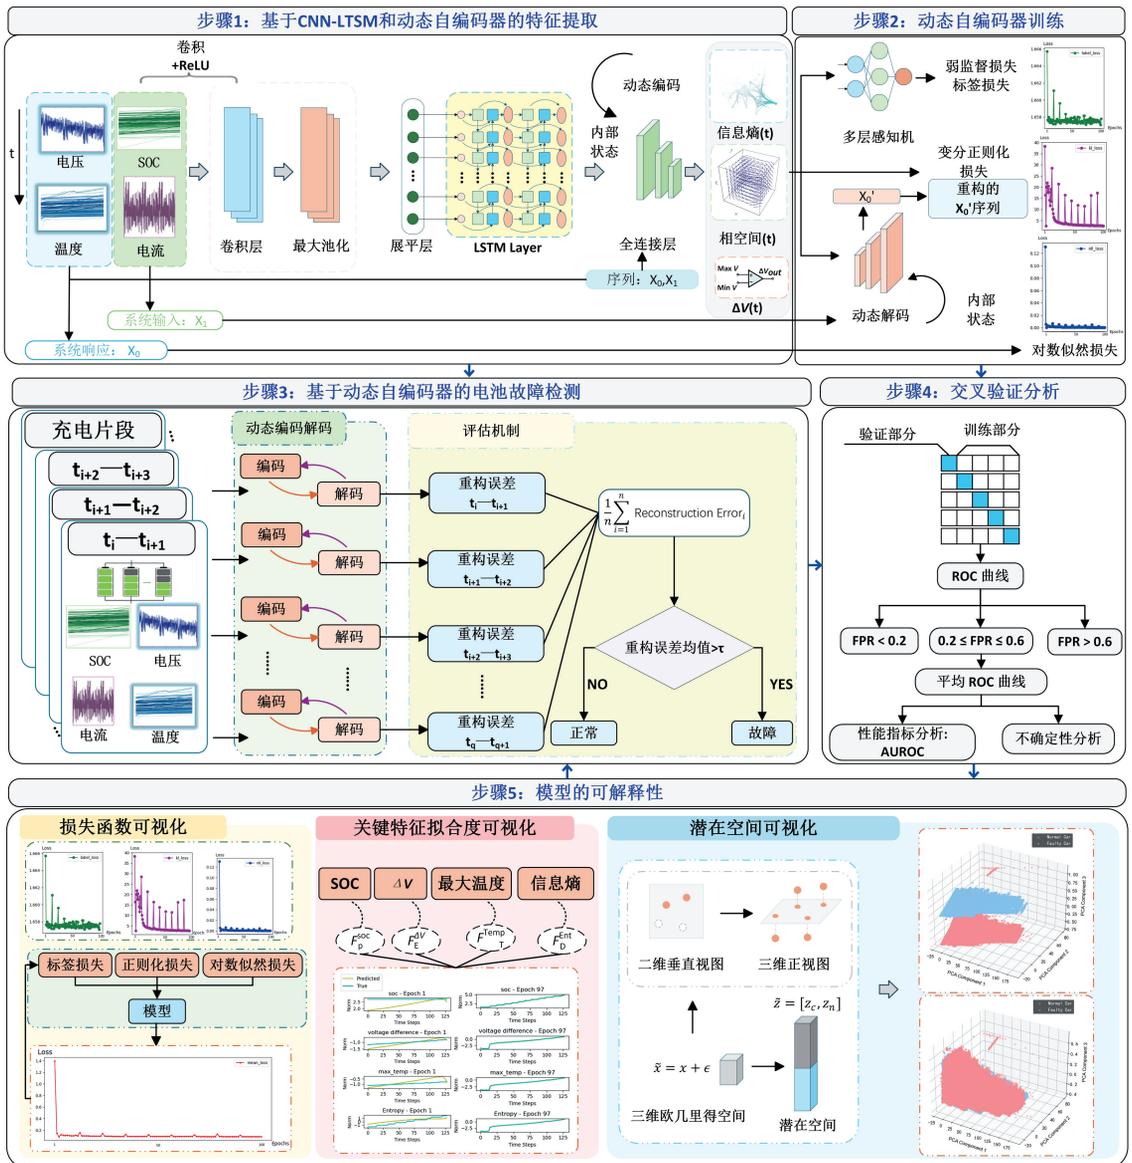


图 1 CNN-LSTM 与 DYAD 集成电池故障检测方法框架

Fig. 1 Framework of the CNN-LSTM and DYAD integrated battery fault detection method

## 1.2 CNN-LSTM 融合动态自编码器的故障检测框架

在故障检测阶段,编码器首先计算每个充电片段的重构误差 $\tau$ ,而集成 CNN-LSTM 与 DYAD 的框架则基于带有故障标签的充电片段,构建动态重构误差阈值。若充电片段的重构误差超过该阈值,则判定其为故障充电片段,并计为扣分项。通过累计所有充电片段的得分,最终评估该车辆是否为故障车辆。该步骤显著减少大电流充电事件引发的虚假报警,并实现故障早期检测<sup>[16]</sup>。为评估所提出的 CNN-LSTM 与 DYAD 集成框架的鲁棒性和泛化能力,本研究利用清华大学 EV 数据平台提供的充电片段数据集进行了五折交叉验证。该数据集包含 347 辆电动汽车的超过 69 万个充电片段,其中 55 辆为异常车辆,292 辆为正常车辆,数据涵盖电压、电流、SOC 等关键参数,并经工程师验证以确保可靠性。在五折交叉验证中,数据集被随机划分为 5 个子集,其中 4 个子集用于训练,1 个子集用于测试,循环进行 5 次,确保每个子集均有机会作为测试集。每次验证中,模型参数通过优化损失函数组合进行调整,输出受试者工作特征(ROC)曲线及带不确定区间的平均 ROC 曲线。经过 5 次迭代,模型的平均受试者工作特征曲线下面积(AUROC)达到 88.7%,表明模型在不同数据划分下的性能稳定。

通过损失函数可视化(揭示训练收敛过程)、关键特征拟合度评估(电压、信息熵、SOC 和最大温度)以及潜在空间可视化(展示正常与故障簇的分离度),本文模型的可解释性得以显著增强,提供直观洞察以提升故障检测的透明度和决策可靠性<sup>[17]</sup>。

## 1.3 动态自编码器关键参数计算

### 1) 信息熵

信息熵是一种热力学系统中无序程度的度量,通过电池参数的多变量概率分布进行操作化,差分熵计算提供了电化学状态不规则性定量表征<sup>[18]</sup>。

$$Entropy = - \int p(x) \log p(x) dx \quad (1)$$

其中,概率密度函数(PDF),记为 $p(x)$ ,量化了连续变量 $x$ 在特定点无穷小邻域内取值的可能性。

用于估计熵的概率密度函数 $p(x)$ 为:

$$p(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (2)$$

式中: $x_i$ 表示熵的样本值; $x$ 表示评估点; $h$ 对应于带宽参数。

$K$ 表示核函数,高斯核函数计算为:

$$K(u) = \frac{1}{\sqrt{2\pi}} e^{-\frac{u^2}{2}} \quad (3)$$

概率密度函数计算步骤如下:

(1) 计算电压差,对于每个批次样本,计算每个时间步长的电压差,以获得张量 $[batch, seq\_len]$ 。

(2) 应用高斯核,使用带宽为( $h=0.1$ )的高斯核来估计概率密度函数 $p(x)$ 。对于每个时间步长,内核都会评估 $x_i$ 对密度的贡献:

$$p(x_i) = \frac{1}{seq \cdot h} \sum_{i=1}^{seq} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{(x_t - x_i)^2}{2h^2}\right) \quad (4)$$

式中: $p(x_i)$ 为点 $x_i$ 处的估计概率密度; $seq$ 表示序列长度(时间序列数据中的时间步数); $h$ 表示高斯核的核带宽; $x_t$ 表示时间步长 $t$ 处的变量值。 $x_i$ 表示变量在时间步长 $i$ 的值; $\frac{1}{\sqrt{2\pi}}$ 表示高斯核的归一化常数; $\exp\left(-\frac{(x_t - x_i)^2}{2h^2}\right)$ 表示高斯核函数评估 $x_i$ 对 $x_t$ 密度的贡献。

(3) 归一化,在序列长度上对估计的 $p(x_i)$ 值进行归一化,以确保它们的总和等于 1,形成有效的 $p(x_i)$ :

$$p(x_i) = \frac{p(x_i)}{\sum_{i=1}^{seq} p(x_i)} \quad (5)$$

式中: $p(x_i)$ 为点 $x_i$ 处的估计概率密度, $\sum_{i=1}^{seq} p(x_i)$ :从 $t$ 为 1 ~  $seq$  的所有时间步长上的非正规化概率密度值之和。

### 2) 重构误差

平均重构误差数学表达式如下:

$$Mean\ Re\ Error = \frac{1}{n} \sum_{i=1}^n Re\ Error_i \quad (6)$$

其中,重构误差( $Error_i$ )量化了原始与重构的第 $i$ 个车辆运行数据序列之间的偏差,而段数 $n$ 定义了用于异常检测的时间分析窗口中整合的前序充电段数量,对于单个数据片段( $x_0, x_1$ )的重构损失定义如下:

$$RSErr_i = MSE(Decoder_\theta(z, x_0), x_1) \quad (7)$$

其中, $z = Encoder_\theta(x_0, x_1)$ , $x_0$ 表示输入信号(电流和 SOC), $x_1$ 表示系统响应(电压差、信息熵、相空间), $z$ 表示代表动态系统状态的潜在变量, $MSE$ 表示均方差。

### 3) 损失函数

总损失函数由以下方程定义:

$$Loss = nll\ weight \times NLL\ Loss + latent\ label\ weight \times Label\ Loss + \frac{KL\ Weight \times KLLoss}{batch\ size} \quad (8)$$

该模型包含 3 个正则化超参数:对数似然权重( $nll\ weight$ )、标签权重( $latent\ label\ weight$ )和变分正则化损失的权重加权系数,即 $\frac{KL\ Weight}{batch\ size}$ ,它们平衡了相应损失项的贡献。

对数似然损失函数的数学公式为:

$$NLLLoss = -\log p(y | x, \theta) \quad (9)$$

其中, $p(y | x, \theta)$ 表示在模型参数 $\theta$ 时,给定输入 $x$ 观

测目标  $y$  的条件概率。

标签损失函数表达式定义为：

$$LabelLoss = MSE = \frac{1}{N} \sum_{i=1}^N (\hat{y}_i - y_i)^2 \quad (10)$$

其中, 预测里程  $\hat{y}_i$  表示从代表车辆驾驶模式的潜在变量中解码的平均值,  $y_i$  对应于实际车辆运行期间测量的地面真实里程,  $N$  指定了批量维度, 表示每次训练迭代处理的独立采样轨迹的数量。

变分正则化损失函数表达式定义为：

$$KLLoss = -\frac{1}{2} \sum (1 + \log(\sigma^2) - \mu^2 - \sigma^2) \quad (11)$$

其中,  $\mu$  表示从输入数据编码的潜在变量的平均向量, 而  $\sigma^2$  量化潜在空间分布的协方差结构。式(11)中的 KL 损失由  $-0.5 \sum (1 + \log(\sigma^2) - \mu^2 - \sigma^2)$  给出, 在潜在变量  $z$  的 32 个维度上逐元素计算, 并通过求和进行汇

总。对于每个潜在维度, 变分正则化损失函数测量编码器的近似后验  $\mathcal{N}(\mu, \sigma^2)$  和前验  $\mathcal{N}(\mu, 1)$  之间的差异, 总损失是通过将所有维度和批量样本相加, 然后按批量大小进行归一化而获得的。该方法确保了潜在空间的鲁棒正则化, 支持电动矿用卡车基于序列数据的有效故障检测。

## 2 方法验证

### 2.1 实验验证

本文选择 4 个关键参数用于监测 SOC、电压差、最高温度和熵。这些特征在电池系统中具有内在物理意义, 直接反映运行状态和健康退化模式。如图 2 所示, 模型在初始训练阶段(第 1 到第 2 个训练周期)表现出显著的预测偏差, 这主要源于如下两个因素。

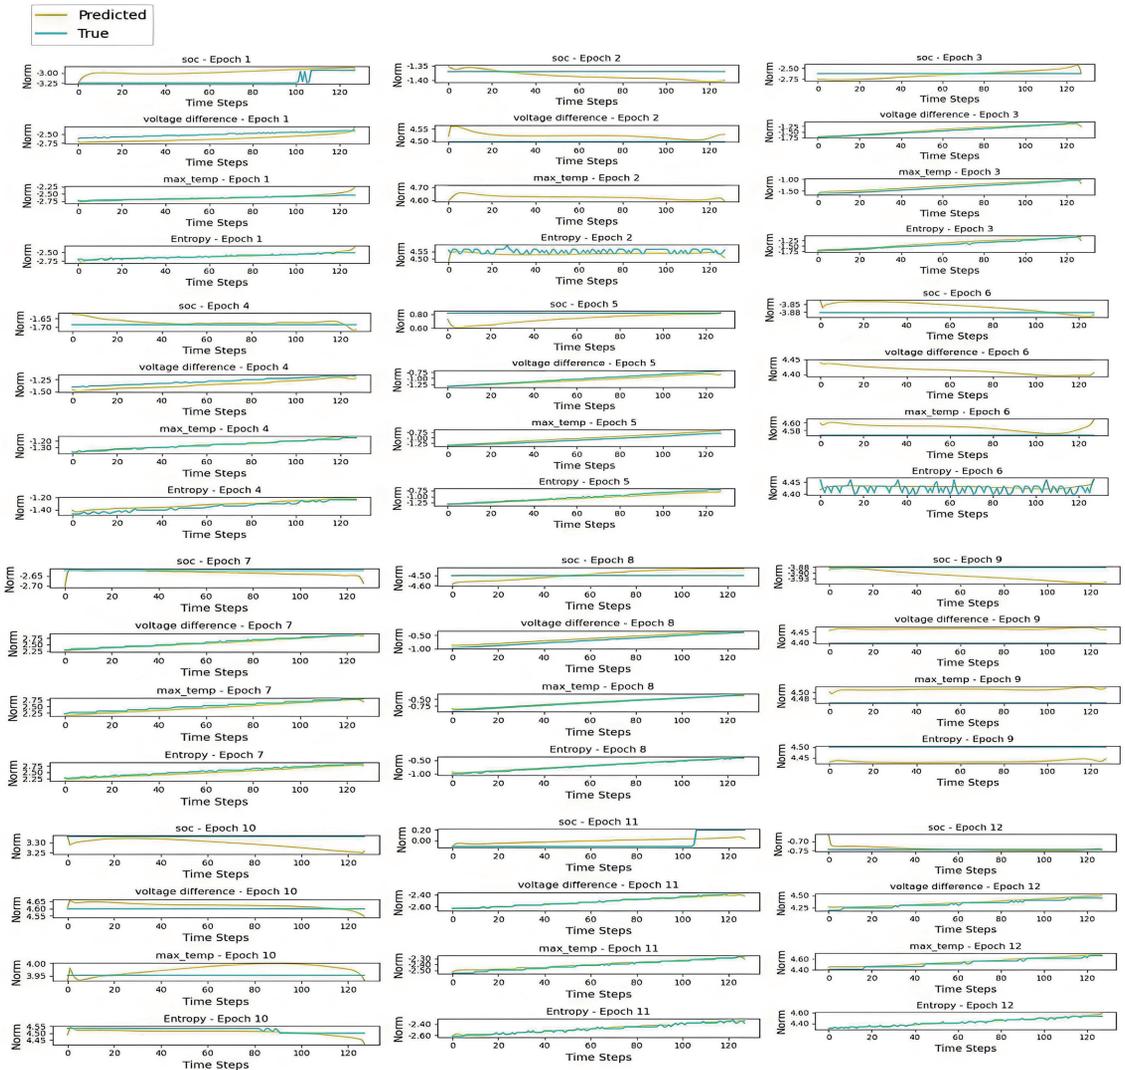


图 2 关键特征真实值与模型预测值的对比

Fig. 2 Comparison of true values and model predicted values for key features

首先,模型尚未完成对电池物理特征,如电压极差、温度梯度的特征提取,导致隐层神经元对输入数据的抽象表征能力不足;其次,随机初始化的权重参数尚未通过梯度下降算法进行有效调整,使得损失函数呈现剧烈波动。随着训练推进至第 3 个周期,模型通过特征捕捉机制逐步优化了对关键参数的拟合能力,这一阶段的性能跃升表明模型已初步建立对电池健康状态的判别能力。至第 12 个训练周期时,模型误差波动显著衰减,且在测试集上的拟合精度均达到工程应用阈值,验证了训练过程的收敛性。该模型整体展现出可靠性和稳定性。所选的 4 个关键特征准确捕捉了电池系统的运行状态,而在连续监控过程中通过迭代优化的预测,进一步验证了模型在实时故障检测场景中卓越的预测能力。

## 2.2 对比实验分析

引入信息熵特征显著提升了电池故障检测任务中模型的性能实验结果,如表 1 所示。信息熵作为量化系统状态不确定性的关键指标,与不包含信息熵特征的模型相比,引入熵度量后分类性能显著提升,AUROC 达到 88.7%,明显优于传统算法,如图动态网络(GDN)(AUROC:70.3%)、自编码器(AE)(AUROC:72.8%)和支持向量数据描述(SVDD)(AUROC:51.5%)。这一显著进步凸显了信息熵特征在复杂故障场景中的关键作用。信息熵特征通过量化电池运行期间数据分布的无序性,使得正常状态与潜在故障的区分更加清晰。这种方法为处理边界样本和模糊运行条件提供了关键的区分支持,有效减少了漏检和误报。

表 1 所考虑算法的 AUROC

Table 1 AUROC algorithms (%)

方法	AUROC
CNN-LSTM+DYAD	88.7±5.8
GDN <sup>[8]</sup>	70.3±5.5
AE <sup>[8]</sup>	72.8±13.0
SVDD <sup>[8]</sup>	51.5±8.2
GP <sup>[8]</sup>	66.6
VE <sup>[8]</sup>	55.6

SVDD 方法的 AUROC 仅为 51.5%,表明其在捕捉复杂电化学退化模式方面的能力不足。与传统方法如高斯过程(GP)(AUROC:66.6%)和变异评估(VE)(AUROC:55.6%)相比,信息熵特征的集成在电池故障中表现出优越性能。

通过量化电化学参数分布的无序性,熵度量为内部状态转换提供了更深入的洞察,从而增强了对多种故障模式的适应性。

基于信息熵的模型更好地捕捉了电化学退化模式,验证了理论有效性,为在现实场景中部署基于熵的诊断方法奠定了基础。此外,该模型的高效性和鲁棒性使其

在复杂多变的电动车辆运行环境中具有广泛的应用潜力,为动力电池故障检测的智能化和精准化提供了新的技术路径。

## 3 结果与讨论

### 3.1 五折交叉验证结果

本文提出了一种针对重型电动商用车的云边协同检测模型,利用 CNN-LSTM 和动态自编码器提取关键特征,显著提升了故障检测性能。由于电池故障检测问题是一个二分类任务,本文选用 ROC 曲线(图 3)作为评估模型故障检测性能的主要工具,并以 AUROC 作为评价指标。通过融入信息熵特征,该模型实现了 88.7% 的 AUROC,进一步验证了模型在故障检测中的优越性。

通过五折交叉验证(图 3(a)~(e)),本文系统地阐明了重构误差阈值选择对锂离子电池故障检测效果的调控机制。实验结果表明,阈值配置调节了两种操作范式下的敏感性和可靠性权衡:零误报安全模式( $FPR=0$ )和在线监测平衡模式( $FPR=0.15$ )。在基线配置(图 3(a))中,过高的阈值配置在绝对安全约束下完全抑制了早期故障识别能力( $TPR=0$ )。优化后的第 5 种配置(图 3(e))通过动态阈值优化实现了显著的性能提升:在零误报场景下保持  $TPR=0.22$ ,同时在  $FPR=0.15$  时实现  $TPR>0.92$ 。ROC 曲线在低误报率区域( $FPR<0.2$ )呈现陡峭的上升轨迹,表明模型能够通过控制瞬时误报(例如,短暂的 BMS 误触发)捕获早期故障。

### 3.2 平均 ROC 曲线与不确定性分析

图 3(f)为带有不确定性量化的 ROC 曲线,其中阴影区域表示在离散误报率( $FPR$ )阈值下计算的真正性率( $TPR$ )的标准差范围。曲线表示平均 ROC 轨迹,而阴影区域量化了评估条件下  $TPR$  的可变性。曲线靠近左上角表明其优越的分类性能,在低  $FPR$  值下实现了高  $TPR$ ,反映了模型对正类检测的强大区分能力。值得注意的是,受限的不确定性带反映了五折交叉验证试验中  $TPR$  的低方差,突显了模型的稳定性,表明其在不同数据分布下具有一致的性能。这种稳定性,结合模型对异常值或特定数据分区引起的性能退化的抵抗能力,凸显了模型的鲁棒性。这些特性对于现实世界的电池故障检测应用至关重要,特别是在需要跨多样化操作场景提供可靠性能的电池故障检测中,ROC 曲线及其紧密的不确定性带的综合验证了模型的精确性和泛化能力,支持其在需要高置信度诊断系统的工业环境中部署。

### 3.3 模型可解释性

通过应用主成分分析(PCA),解构多维老化特征空间,并实现了显著的降维。提取高维数据的特征点云在

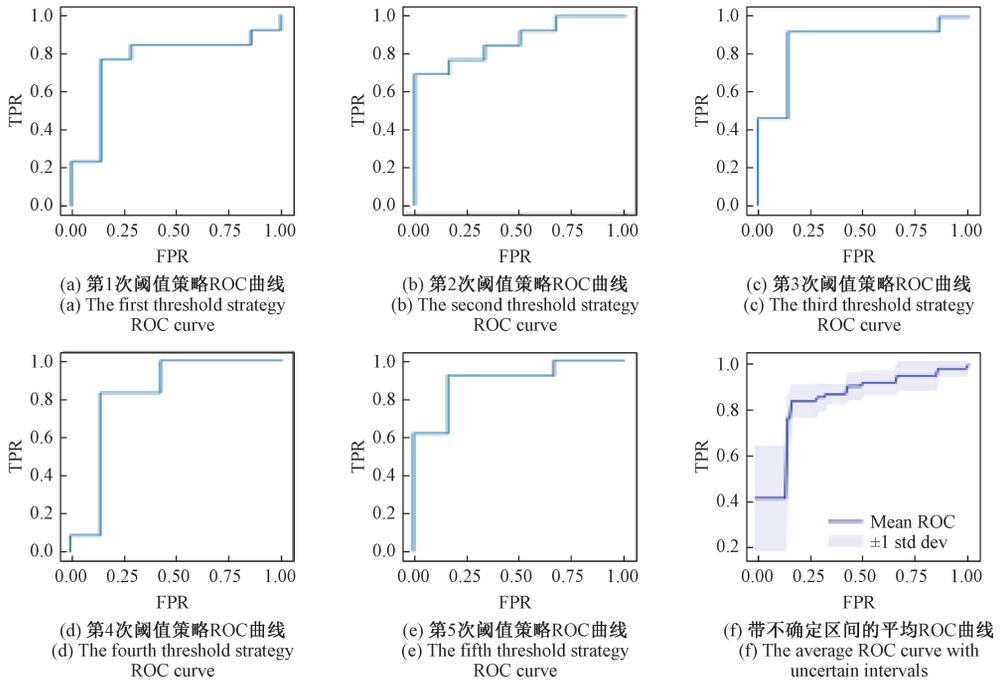


图 3 五折自适应误差阈值选择下的 ROC 轨迹演变

Fig. 3 ROC trajectory evolution under the selection of a 50% adaptive error threshold

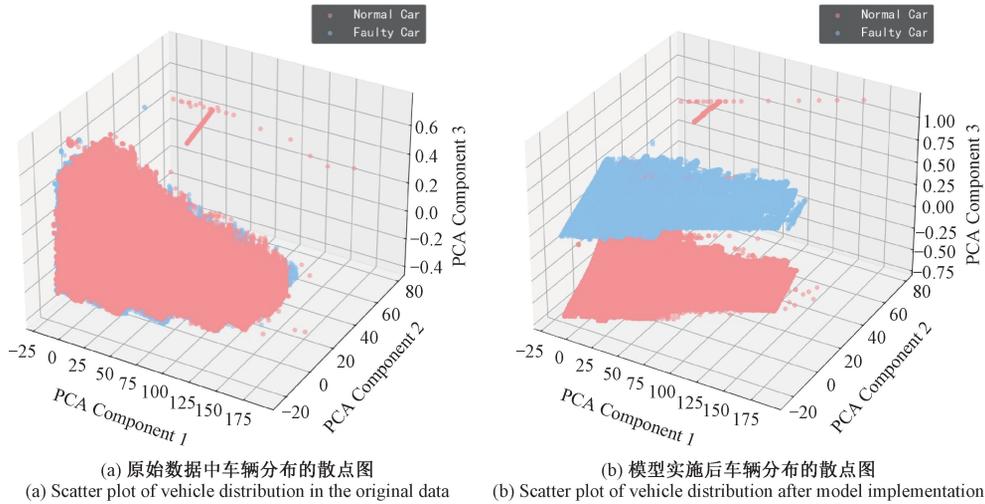


图 4 车辆分布模式的比较分析

Fig. 4 Comparative analysis of vehicle distribution patterns

三维空间中的分布,可以类比为三维欧几里得空间中的点云。然而,此类分布常被噪声成分所掩盖,类似于由于嵌入噪声导致的三维坐标中平面关系的退化<sup>[19]</sup>。降维过程通过将点云投影到新的特征空间来调整观察视角,明确分离并揭示原本隐藏在三维特征中的噪声成分<sup>[20]</sup>。并且在重构的特征空间中,每个主成分被设计为与原始数据中最大方差的方向对齐。这种对齐机制确保了特征表示的最大信息保留,因为主成分捕捉了数据变异性的

主要轴向,从而减少了冗余并突出了潜在的模式差异。第 1 主成分对应于数据中方差最大的方向,第 2 主成分则垂直于第 1 主成分并捕捉次大方差,以此类推。这种正交变换不仅简化了电池数据(如电压、电流和 SOC 序列)的结构,还增强了模型对非线性动态和累积故障效应的敏感性,避免了传统方法中信息丢失的风险。模型实施后车辆分布的散点图(图 4(b))所示,正常车辆与故障车辆之间呈现出明显的聚类模式与高离散度,验证了动

态自编码器模型的有效性及其在故障检测任务中的潜力。此外,在 CNN-LSTM 与 DYAD 集成电池故障检测方法框架(图 1)步骤 5 的损失函数可视化中,总损失函数随训练轮次增加,逐渐收敛,表明模型已达稳定状态。这意味着模型在训练过程中不断优化,能够较为准确地学习到电池数据中的特征模式与故障规律。通过对模型的可解释性分析,可以进一步探究模型是如何依据输入数据做出故障检测判断的。

## 4 结 论

开发的故障检测框架集成了 CNN-LSTM-DYAD 混合架构模型,通过增强的注意力加权机制将信息熵作为关键特征。在自适应阈值优化系统中,本文采用了基于实时参数分布的动态概率边界,优化了传统的静态阈值;并在模型中建立了多模态参数的关系,使得数据驱动能够准确检测出故障的电池驱动卡车。

该方法可进一步扩展至更多电动车辆应用场景,如城市物流车队或长途运输系统,以加速交通运输领域“双碳”目标的实现。未来研究方向包括整合更多传感器数据以提升多模态融合的鲁棒性;探索联邦学习机制,实现跨车辆数据的隐私保护共享;结合边缘计算部署框架,降低实时计算延迟,支持实际工业部署。同时,通过与行业标准对接,该技术有望推动重型电动商用车的标准化故障诊断体系建设,为可持续交通转型提供更强有力的技术保障。

## 参考文献

- [ 1 ] ZHAO P, ZHANG S, SANTI P, et al. Challenges and opportunities in truck electrification revealed by big operational data [ J ]. *Nature Energy*, 2024, 9: 1427-1437.
- [ 2 ] OJO O, LANG H, KIM Y, et al. A neural network based method for thermal fault detection in lithium-ion batteries [ J ]. *IEEE Transactions on Industrial Electronics*, 2020, 68(5): 4068-4078.
- [ 3 ] LI J, MAO Z, GU X, et al. A quantitative fault diagnosis method for lithium-ion battery based on MD-LSTM [ J ]. *IEEE Transactions on Transportation Electrification*, 2025, 11(1): 2266-2276.
- [ 4 ] 杨彦茹,温杰,史元浩,等.基于 CEEMDAN 和 SVR 的锂离子电池剩余使用寿命预测[J]. *电子测量与仪器学报*, 2020, 34(12): 197-205.  
YANG Y R, WEN J, SHI Y H, et al. Remaining useful life prediction of lithium-ion batteries based on CEEMDAN and SVR [ J ]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34 ( 12 ): 197-205.
- [ 5 ] 王君瑞,吴新举,赵东琦,等.基于 WOA-VMD 与 PSO-SVM 的锂离子电池内短路故障诊断方法[J]. *工程科学学报*, 2023, 45(12): 2162-2172.  
WANG J R, WU X J, ZHAO D Q, et al. Internal short circuit fault diagnosis method for lithium-ion batteries based on WOA-VMD and PSO-SVM [ J ]. *Journal of Engineering Science*, 2023, 45(12): 2162-2172.
- [ 6 ] 李振宇,王国玲,杨宇生,等.一种海上平台直流微网系统复合型短路故障检测方法[J]. *仪器仪表学报*, 2021, 42(1): 157-164.  
LI ZH Y, WANG G L, YANG Y SH, et al. A compound short-circuit fault detection method for DC microgrid system of offshore platform [ J ]. *Chinese Journal of Scientific Instrument*, 2021, 42(1): 157-164.
- [ 7 ] LV C, CAO S, ZHANG Y, et al. Methods studies for attached marine organisms detecting based on convolutional neural network[J]. *Energy Reports*, 2022, 8: 1192-1201.
- [ 8 ] ZHANG J, WANG Y, JIANG B, et al. Realistic fault detection of Li-ion battery via dynamical deep learning[J]. *Nature Communications*, 2023, 14(1): 5940.
- [ 9 ] 孙洁,刘梦,刘晓悦,等.LSTM 神经网络算法对锂电池故障信号检测的研究[J]. *现代电子技术*, 2022, 45(3): 7377.  
SUN J, LIU M, LIU X Y, et al. Research on fault signal detection of lithium battery based on LSTM neural network algorithm [ J ]. *Modern Electronics Technique*, 2022, 45(3): 73-77.
- [ 10 ] ZHANG K, HU X, LIU Y, et al. Multi-fault detection and isolation for lithium-ion battery systems[J]. *IEEE Transactions on Power Electronics*, 2021, 37 ( 1 ): 971-989.
- [ 11 ] YUN J, CHOI Y, LEE J, et al. State-of-charge estimation method for lithium-ion batteries using extended Kalman filter with adaptive battery parameters[J]. *IEEE Access*, 2023, 11: 90901-90915.
- [ 12 ] OJO O J, LIN X, LANG H, et al. A voltage fault detection method enabled by a recurrent neural network and residual threshold monitor for lithium-ion batteries[C]. 2021 IEEE Transportation Electrification Conference & Expo. IEEE, 2021: 813-820.
- [ 13 ] JIANG J, CONG X, LI S, et al. A hybrid signal-based fault diagnosis method for lithium-ion batteries in electric vehicles[J]. *IEEE Access*, 2021, 9: 19175-19186.
- [ 14 ] KAUR G, CHANAK P. An energy aware intelligent fault detection scheme for IoT-enabled WSNs [ J ]. *IEEE Sensors Journal*, 2022, 22(5): 4722-4731.
- [ 15 ] CUNANAN C, TRAN M K, LEE Y, et al. A review of heavy-duty vehicle powertrain technologies: Diesel engine

vehicles, battery electric vehicles, and hydrogen fuel cell electric vehicles[J]. *Clean Technologies*, 2021, 3(2): 474-489.

- [16] SHANG Y, LU G, KANG Y, et al. A multi-fault diagnosis method based on modified Sample Entropy for lithium-ion battery strings[J]. *Journal of Power Sources*, 2020, 446: 227275.
- [17] SADHUKHAN C, MITRA S K, BHATTACHARYYA S, et al. Modeling and simulation of high energy density lithium-ion battery for multiple fault detection [J]. *Scientific Reports*, 2022, 12(1): 9800.
- [18] 邵凯旋 何怡刚 汪磊. 基于多尺度熵分析与改进 SVM 的变压器故障识别[J]. *电子测量与仪器学报*, 2022, 36(6): 161-168.  
SHAO K X, HE Y G, WANG L. Transformer fault identification based on multi-scale entropy analysis and improved SVM [J]. *Journal of Electronic Measurement and Instrumentation*, 2022, 36(6): 161-168.
- [19] 殷逸冰, 文振华. 基于模态分量优化重构和稀疏表达的静电信号联合降噪方法[J]. *仪器仪表学报*, 2022, 43(2): 196-204.  
YIN Y B, WEN ZH H. A joint denoising method for electrostatic signals based on modal component optimization reconstruction and sparse representation [J]. *Chinese Journal of Scientific Instrument*, 2022, 43(2): 196-204.
- [20] COHEN M X. A tutorial on generalized eigen decomposition for denoising, contrast enhancement, and dimension

reduction in multichannel electrophysiology [J]. *Neuroimage*, 2022, 247: 118809.

## 作者简介



熊学涛, 2022 年于黑龙江八一农垦大学获得学士学位, 现为桂林理工大学硕士研究生, 主要研究方向为新能源汽车动力电池故障检测。

E-mail: xuetaoxiongxt@163.com

**Xiong Xuetao** received his B. Sc. degree from Heilongjiang Bayi Agricultural University in 2022. He is now a M. Sc. candidate at Guilin University of Technology. His main research interest includes fault detection in new energy vehicle power batteries.



张艳辉(通信作者), 2008 年于青岛科技大学获得学士学位, 2011 年于东北电力大学获得硕士学位, 2014 年于中国科学院深圳先进技术研究院副研究员, 主要研究方向为电池储能和检测算法。

**Zhang Yanhui** (Corresponding author) received his B. Sc. degree from Qingdao University of Science and Technology in 2008, M. Sc. degree from Northeast Electric Power University in 2011, and Ph. D. degree from the University of Chinese Academy of Sciences in 2014. He is now an associate researcher at the Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences. His main research interests include battery energy storage and Detection Algorithms.