储能系统与工程

基于可扩展电池模型的储能电站故障并网影响与智能决策研究

李 岩[1]，孙宇飞[1]，单 宇[2]，乔俊杰[2]，曾祥瑞[2]，白燕斐[1]，张天硕[1]，谢心成[1]
（[1]华北电力大学电力工程系，河北 保定 071003；[2]国网江苏省电力有限公司淮安供电分公司，江苏 淮安 223001）

摘 要：当前，针对储能电站内部故障对电网影响的研究尚不充分，且缺乏相应的故障响应决策系统。为弥补这一不足，本研究提出了一种基于二阶电阻-电容（RC）等效电路的可扩展电池建模方法，该方法能够同时刻画单体电池性能和电站整体行为。在此基础上，构建了完整的并网电站模型，用以模拟多种运行工况下发生于不同层级储能单元的短路和开路故障。主要发现包括：集装箱式储能单元中，发生于储能变流器（PCS）输出端的三相短路会导致高压母线电流激增43.6倍、电压骤降42%；电柜内短路会引起最高1.19倍的电流增大；而集装箱和电柜内的开路故障所造成的风险则相对有限，影响微小。此外，本文还引入了一种深度学习-大语言模型（LLM）算法，该算法融合了卷积神经网络（CNN）、双向长短期记忆网络（BiLSTM）和自注意力（A）机制，在对12种故障类型的识别中实现了超过98.4%的准确率。通过利用检索增强生成（RAG）技术，将故障识别结果与本地大语言模型及领域专用知识库相融合，该系统具备智能决策的能力。

关键词：储能电站；电站并网；故障诊断；动态二阶RC等效电路模型；卷积神经网络-长短期记忆网络；大语言模型
doi：10.19799/j.cnki.2095-4239.2026.0380
中图分类号：TM 912　　文献标志码：A　　文章编号：2095-4239（XXXX）XX-1-19

Grid-impact analysis and intelligent decision-making for energy storage station faults based on a scalable battery model

LI Yan[1], SUN Yufei[1], SHAN Yu[2], QIAO Junjie[2], ZENG Xiangrui[2], BAI Yanfei[1], ZHANG Tianshuo[1], XIE Xincheng[1]
([1]Department of Electrical Engineering, North China Electric Power University, Baoding 071003, Hebei, China; [2]Huai'an Power Supply Branch, State Grid Jiangsu Electric Power Co., Ltd., Huai'an 223001, Jiangsu, China)

Abstract: Research on the impact of internal faults in energy storage power stations on the grid remains limited, with a lack of fault response decision-making systems. To address this gap, this study proposes a scalable battery modeling method using a second-order resistor-capacitor (RC) equivalent circuit, which captures both individual cell performance and overall station behavior. A comprehensive grid-connected power station model was developed to simulate short-circuit and open-circuit faults across multi-level energy storage units under various operating conditions. Key findings include: three-phase short circuits at the power

收稿日期：2026-05-07；修改稿日期：2026-06-10。
基金项目：国家重点研发计划（2023YFB2408200）。
第一作者及通信联系人：李岩（1985—），男，博士，副教授，研究方向为深度学习及储能建模等，E-mail：yan.li@ncepu.edu.cn。
引用本文：李岩, 孙宇飞, 单宇, 等. 基于可扩展电池模型的储能电站故障并网影响与智能决策研究[J]. 储能科学与技术, XXXX, XX(XX): 1-19.
Citation：LI Yan, SUN Yufei, SHAN Yu, et al. Grid-impact analysis and intelligent decision-making for energy storage station faults based on a scalable battery model[J]. Energy Storage Science and Technology, XXXX, XX(XX): 1-19.

conversion system (PCS) output terminals of containerized units cause a 43.6-fold current surge and 42% voltage sag on the high-voltage bus; short circuits in electrical cabinets result in up to 1.19-times current amplification; open-circuit faults in containers and cabinets present insignificant risks. Additionally, a deep learning-large language model (LLM) algorithm was introduced, combining convolutional neural network (CNN), bidirectional long short-term memory (BiLSTM), and self-attention (A) mechanisms to achieve over 98.4% accuracy in identifying 12 fault types. By integrating fault recognition results with local LLMs and domain-specific knowledge bases using retrieval-augmented generation (RAG) technology, the system is able to make intelligent decisions.

Keywords: Energy storage power station; Power station grid connection; Fault diagnosis; Dynamic 2-RC equivalent circuit model; Convolutional neural network - Long short-term memory; Large language model

1 引 言

全球变暖与化石燃料的日渐枯竭正推动电力能源系统从以火电为主导向以可再生能源为主导转型[1]。然而，可再生能源发电具有间歇性和不可控性，给电网带来了电压暂态加剧、频率波动、可靠性降低以及电能质量下降等新的挑战[2]。储能电站能够在可再生能源功率波动时提供调节能力，有效缓解电网的频率波动、电压暂态和电能质量问题，已成为现代电网不可或缺的组成部分[3]。储能电站的精细化建模对于提升其性能具有关键作用，因此，已有大量学者对储能、电网与多种可再生能源相集成的系统开展了建模研究，在维持电网稳定[4]、提升经济调度效率[5]以及优化储能容量配置[6]等方面取得了显著进展。然而，随着储能电站规模的持续扩大，其安全风险也逐渐显现[7]。储能电站的安全问题不仅直接关系到其自身的可持续发展，也已成为学术界和社会讨论的重大关切[8]。

储能电站故障对电网影响的研究紧迫但尚显不足。鉴于实验研究成本高且风险大，基于仿真的研究成为一种切实可行的替代方案。然而，以保障储能电站安全为目标的仿真研究面临若干挑战：第一，现有研究大多聚焦于单体电池[9-11]，涉及实际储能电站中电池串并联结构的文献十分有限，缺少一种能够根据电站结构配置、从单个电池扩展至整个储能电站的可扩展电池模型；第二，在储能电站故障建模方面，部分研究采用简化处理方式，例如有学者[12, 13]研究了直流侧故障对电网侧的影响，但并未对储能电站内部的故障进行探讨，此类简化模型无法刻画储能电站复杂的内部特性，导致研究焦点局限于联络线故障；第三，在储能电站发生故障后，精确而快速的决策对于防止故障蔓延至关重要，尽管人工智能与深度学习技术正在快速进步，但本领域仍缺少同时集成这两类技术的智能决策支持系统。为解决上述挑战，本研究提出一种可从单个电池单元扩展至整个储能电站的可扩展模型，能够同时刻画单体性能和电站整体性能。随后，建立完整的储能电站并网模型，通过计算分析储能电站内部故障对电网的影响。在此基础上，进一步构建融合人工智能与深度学习的智能决策支持系统，以辅助故障处理并提升储能电站的安全性。

开发面向储能电站的可扩展电池模型具有挑战性，原因在于既需要选择合适的电池模型，又需要理清储能电站内部电池的串并联结构。在电池模型选择方面，电化学模型虽然精度较高，但计算量过大，鉴于当前的计算能力，难以用于大规模储能系统的仿真[14]。相比之下，等效电路模型能有效捕捉电池的电流、电压和荷电状态（SOC）等特性，在基本不损失精度的前提下减轻了计算负担，因此更适合本研究。已有多种等效电路模型用于模拟电池的外部特性[15]。然而，综合考虑精度与计算复杂度之间的权衡，动态二阶电阻-电容等效电路模型在当前研究中被广泛采用[10, 11]。该模型在仿真电池充放电特性方面具有较高精度，且在构建电池簇模型时表现出良好的可扩展性；其灵活性使其能够实现多层级储能单元的建模，十分适用于大规模储能电站的仿真。为确定电站内部电池的串并联结构，本研究将对位于中国西北地区的一座储能电站进行实

地调研，以分析其内部电池的拓扑配置。

为研究储能电站内部故障对电网的影响，必须建立一个完整的储能电站并网模型。在该领域，已有大量学者对储能电站的并网控制策略和拓扑优化开展了深入研究。目前，储能单元[12, 13]依赖储能变流器（PCS）完成交直流变换以及并网。然而，这些研究主要关注储能电站的正常运行特性或联络线故障，尚未充分挖掘储能电站内部故障对电网侧的潜在影响。为填补储能电站内部故障对电网影响方面的研究空白，本文基于实际电站结构，建立了储能电站并网电磁暂态模型，重点分析储能电站内部故障所引起的电压、电流和功率变化及其对电网侧各电力设备的影响。

在储能电站的应用中，构建融合人工智能（AI）与深度学习算法的智能决策支持系统，对于提升未来储能电站的安全性至关重要。在深度学习算法中，卷积神经网络（CNN）在特征提取方面表现优异，而长短期记忆网络（LSTM）则擅长处理时序数据。因此，CNN-LSTM 混合模型已在相关领域得到广泛应用[16, 17]。此外，近期研究表明，引入注意力机制和双向长短期记忆网络（BiLSTM）可以进一步提升算法的精度[18, 19]。基于此，本研究提出采用 CNN-BiLSTM-A（卷积神经网络-双向长短期记忆网络-自注意力机制）算法，以期在储能电站故障分类中取得更优性能。然而，对于储能电站的应急响应人员而言，仅仅识别出故障类型还远远不够，快速获取有效的应对策略，对故障的早期处置至关重要。近年来，以美国 OpenAI 和中国 DeepSeek 为代表的人工智能技术快速迭代，推动大语言模型（LLM）在多个领域取得重大突破[20]。将大语言模型与数据库相结合，能够实现 AI 辅助决策，为复杂问题提供高效的解决方案。尽管如此，AI 辅助决策在储能电站故障早期预警领域仍属空白。本文认为，引入大语言模型技术可显著提升应急响应效率，为储能电站的智能化安全管理提供有价值的实践贡献。基于上述分析，本文主要工作如下：

1）提出了一种基于实际电站的可扩展电池建模方法，用于构建储能电站模型。该方法采用二阶 RC 等效电路建立电池单元模型，并利用等效电路原理，在可接受的误差范围内实现快速的多层级储能单元建模，从而能够对大规模储能电站进行精确建模。

2）建立了完整的并网电站模型，构建了涵盖多层级、多工况和多故障类型的仿真环境，用以分析储能电站内部故障对电网运行的影响。本研究基于仿真揭示了储能电站内部故障对电网侧的影响。

3）提出了一种将 CNN-BiLSTM-A 深度学习算法与大语言模型（DeepSeek）相集成的智能决策系统。其中，CNN-BiLSTM-A 算法能够对高维时序故障数据进行精确分类，而大语言模型则结合储能电站知识库，智能生成应急响应策略，从而显著缩短故障应急处置时间，提升事件处理效率。

2　储能集装箱模型

储能电站是一个由电芯、电池模组、电池包、电池柜和集装箱等多个层级构成的高度复杂系统。本节将首先通过 HPPC（混合脉冲功率特性）实验获取电芯的动态特性，并基于实验数据构建二阶 RC 等效电路模型；随后，依据实际电站的层级结构，将电芯模型逐步扩展至储能集装箱模型。

2.1　HPPC 实验

HPPC 实验为二阶 RC 等效电路模型的构建提供了关键的数据支撑[11]。本研究选取中国西北某储能电站所使用的、由宁德时代（CATL）生产的 314Ah 电芯作为基本储能单元。HPPC 实验平台如图 1 所示。HPPC 实验平台从左至右依次由上位机控制系统、包含温控器与充放电测试仪的测试系统以及实验电芯三部分组成。在具体功能上，位于左侧的上位机控制系统主要供实验人员设定充放电条件，并负责记录电流、电压等关键实验数据；居于中部的测试系统承担核心控制与环境调节任务，其中由福建星云电子公司生产的 BAT-NEEFLCT-0530N-V001 型充放电测试仪可通过计算机对电池的充放电过程进行精确控制并自动导出实验数据，而由上海佰亿公司生产的 B-T-107 型温控器则与充放电测试系统相连，用于在电芯运行过程中保持恒定温度；位于右侧的实验电芯作为基本储能单元，采用的是由宁德时代生产的 314Ah 电芯,相关技术参数已在图 1 中标出，它与西北某储能电站实际使用的电芯完全一致，为构建二阶 RC 等效电路模型提供了关键的数据支撑。

电池在 25°C 环境下按照 HPPC 实验规程进行测试，该过程与文献[9]中所描述的 HPPC 实验流程

类似。实验结果如图2所示。放电电流设置为0.2C（62.8A），脉冲充/放电电流同样设置为0.2C（62.8A）。实验开始时，电芯处于满充状态，先静置60分钟，以确保电化学状态稳定。随后，电池持续放电30分钟，再静置30分钟。接着，进行一次10秒的放电脉冲，静置40秒后，再施加一次充电脉冲，并再次静置40秒。此后，电池继续放电30分钟，再静置30分钟，以此模拟电芯的动态运行特性。实验在不同SOC水平下记录数据，以分析电芯在不同荷电状态下的响应特性。实验在SOC为1（100%）至0.1（10%）的范围内进行，每隔0.1记录一次。图2a和图2b展示了HPPC实验过程中电芯的电流和电压变化，图2(c)和图2(d)则反映了脉冲工况下的电流和电压特性。

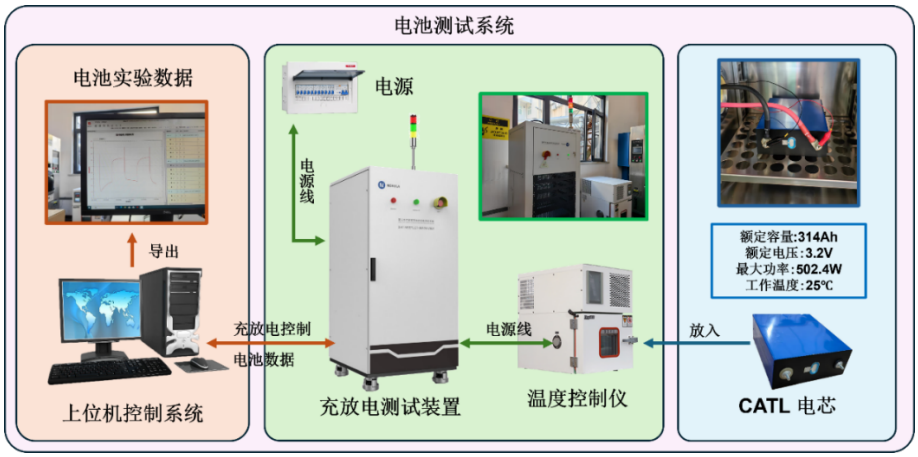
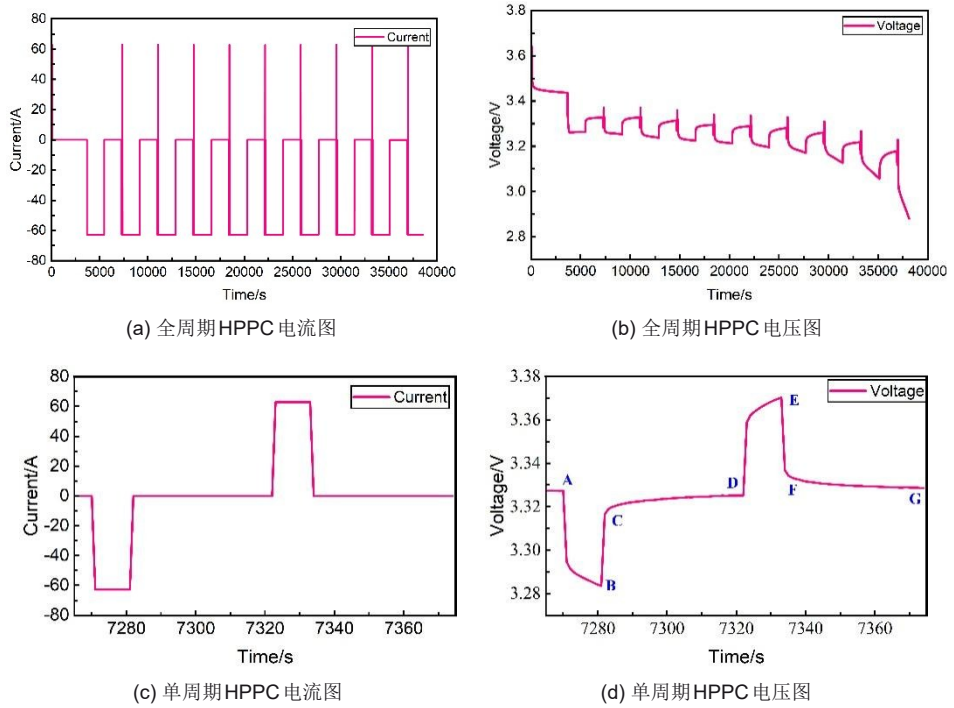


图1 HPPC实验平台

Fig. 1 HPPC experiment platform



(a) 全周期HPPC电流图　(b) 全周期HPPC电压图

(c) 单周期HPPC电流图　(d) 单周期HPPC电压图

图2 HPPC实验全周期与单周期电压和电流曲线[9]

Fig. 2 Full and single cycle voltage and current curves from HPPC experiment[9]

为验证所选电芯动态特性的代表性，本文进一步对10块同型号314 Ah储能电芯开展HPPC实验，结果表明各电芯在相同测试条件下的电流曲线、电压响应及脉冲恢复特性高度一致，说明采用代表性电芯参数建立二阶RC等效电路模型并进行系统级扩展建模具有合理性。

2.2　动态二阶RC等效电路模型

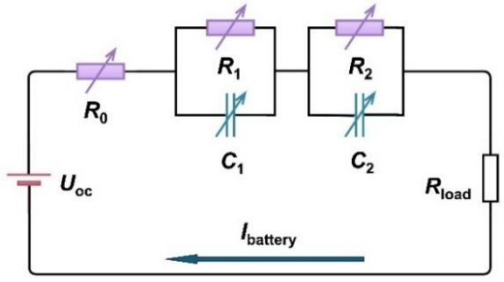


图3　二阶RC等效电路模型

Fig. 3　2-RC equivalent circuit model

二阶RC等效电池模型由两个并联的RC网络、一个欧姆内阻和一个电压源组成，如图3所示。在该模型中，U_{oc}和U_L分别表示电路的开路电压和端电压；R_1和R_2分别为电化学极化电阻和浓差极化电阻；C_1和C_2分别为电化学极化电容和浓差极化电容。此外，R_0表示欧姆内阻，I_L表示流经电压源的电流。应用基尔霍夫第一定律和第二定律可得：

$$\begin{cases} U_L = U_{oc} - I_L R_0 - U_1 - U_2 \\ \dfrac{dU_1}{dt} = \dfrac{I_L}{C_1} - \dfrac{U_1}{C_1 R_1} \\ \dfrac{dU_2}{dt} = \dfrac{I_L}{C_2} - \dfrac{U_2}{C_2 R_2} \end{cases} \tag{1}$$

其中，U_1表示R_1和C_1两端的电压，U_2表示C_2和R_2两端的电压。此外，SOC是一个可用于估算模型内任意参数的函数。电池荷电状态的计算采用安时积分法，其计算公式如下：

$$S = S_0 - \frac{1}{C_N}\int \eta I_L \, dt \tag{2}$$

式中，η表示库仑效率，本研究中取值为1；C_N表示电池容量；S即SOC，S_0表示电池的初始荷电状态。

该模型中各参数随SOC的变化关系可通过HPPC实验获取。在图2(d)中，A至B段为脉冲放电过程，B至D段为放电后的静置阶段，D至E段为脉冲充电过程，E至G段为充电后的静置阶段。欧姆内阻参数可根据放电瞬间（B至C段）的电压跳变和充电结束时刻（E至F段）的电压变化来确定。R_0的计算公式如下：

$$R_0 = \frac{(U_C - U_B) + (U_E - U_F)}{2I_L} \tag{3}$$

脉冲放电静置阶段电压的缓慢上升主要受电池内部极化电阻和极化电容的影响。这一过程对应图2d中C至D段。在此阶段，二阶RC电路呈现零输入响应特性。电池在C至D段任意时刻的工作电压可表示为：

$$U = OCV_D - I_L R_1 e^{-\tau_1 t} - I_L R_2 e^{-\tau_2 t} \tag{4}$$

式中，OCV_D表示电池在D时刻的开路电压，τ_1和τ_2为时间常数，且$C_1 = \dfrac{1}{\tau_1 \times R_1}$，$C_2 = \dfrac{1}{\tau_2 \times R_2}$。已知$I_L$=62.8A，可利用拟合工具得到不同SOC下的$C_2$、$C_1$、$R_2$、$R_1$、$R_0$的取值，如表1所示。为描述SOC与参数$C_2$、$C_1$、$R_2$、$R_1$、$R_0$之间的关系，本文采用六次多项式进行拟合，该方程以SOC为自变量，相应的拟合曲线由式(5)给出。

表1　不同SOC水平下的放电特性参数

Table 1　Criteria for discharge profiles at particular SOC levels

SOC	$C_2(F)$	$C_1(F)$	$R_2(m\Omega)$	$R_1(m\Omega)$	$R_0(m\Omega)$
0.9	2354363	4014	0.49682	0.10441	0.52310
0.8	1869213	4679	0.46332	0.11092	0.51510
0.7	1576832	3739	0.50064	0.12365	0.51750
0.6	1615981	4223	0.49427	0.11003	0.53500
0.5	1394888	3985	0.51210	0.11019	0.54620
0.4	1190550	4254	0.48838	0.11723	0.55330
0.3	984948	3951	0.49745	0.12470	0.55454
0.2	785093	4607	0.46783	0.13261	0.53660
0.1	400668	8897	0.27834	0.19761	0.54220

$$\begin{cases} C_2 = -7.648e5 \times S^6 + 1.607e6 \times S^5 - 8.216e5 \times S^4 - \\ \quad 3.76e5 \times S^3 + 4.861e5 \times S^2 - 1.542e5 \times S + \\ \quad 1.99e4 \\ C_1 = -2.625e8 \times S^6 + 8.544e8 \times S^5 - 1.074e9 \times S^4 + \\ \quad 6.609e8 \times S^3 - 2.087e8 \times S^2 + 3.396e7 \times S - \\ \quad 1.472e6 \\ R_2 = -0.00265 \times S^6 + 0.0397 \times S^5 - 0.09338 \times S^4 + \\ \quad 0.09013 \times S^3 - 0.04226 \times S^2 + 0.009541 \times S - \\ \quad 0.0003342 \\ R_1 = 0.05141 \times S^6 - 0.1607 \times S^5 + 0.1979 \times S^4 - \\ \quad 0.122 \times S^3 + 0.03964 \times S^2 - 0.006514 \times S - \\ \quad 0.0005564 \\ R_0 = 0.01217 \times S^6 - 0.04142 \times S^5 + 0.05689 \times S^4 - \\ \quad 0.03922 \times S^3 + 0.01361 \times S^2 - 0.002115 \times S + \\ \quad 0.0006514 \end{cases} \tag{5}$$

式中，S代表SOC。

荷电状态-开路电压（SOC-OCV）是用于电池特性表征与建模的一对重要参数[21]。SOC与OCV之间通常呈非线性关系[22]，可通过OCV曲线加以描述。为此，本文基于HPPC测试数据，采用多项式拟合法对SOC-OCV曲线进行估算，目标是找到一个能够准确预测任意SOC下电池OCV值的函数。在HPPC实验中，将30分钟静置后的电压视为对应SOC下的OCV值，如图4所示。本文采用六次多项式对SOC-OCV曲线进行拟合，该多项式被确定为解决此类问题最适宜的函数形式[9]。SOC-OCV曲线的六次多项式拟合公式由式(6)给出。

$$U_{oc} = -9.413S^6 + 42.31S^5 - 69.34S^4 + 54.19S^3 - 21.52S^2 + 4.306S + 2.903 \tag{6}$$

2.3 电芯的串并联连接

第2.2节已建立了314Ah电芯的二阶RC等效电路模型。然而，在构建更高层级的储能单元时，仍面临两个关键挑战：（1）储能电站内部电芯的具体串并联拓扑结构在文献中未有明确记载；（2）储能电站中电芯数量庞大，导致仿真模型节点数超过50万个，对内存资源提出了极高的需求；（3）仿真时间随电芯数量呈指数增长，使得在对整站进行建模时，几乎无法评估和控制仿真时长。

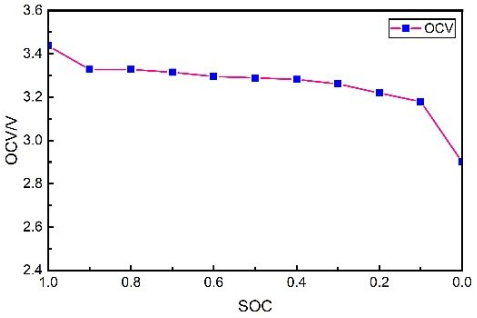


图4 SOC-OCV对应关系曲线

Fig. 4 SOC-OCV correspondence curve

为解决挑战（1），本研究对位于中国西北地区的储能电站内部结构进行了实地调研。图5展示了该储能集装箱的串并联拓扑示意图。该储能集装箱由电芯、电池模组、电池包和电池柜四个层级构成：13个电芯串联组成一个电池模组，4个电池模组串联组成一个电池包，8个电池包串联组成一个电池柜，12个电池柜并联构成一个完整的储能集装箱。基于此拓扑结构，构建储能集装箱模型，并将其作为储能电站并网模型中的核心储能单元，为后续的电网耦合分析提供精确的建模基础。

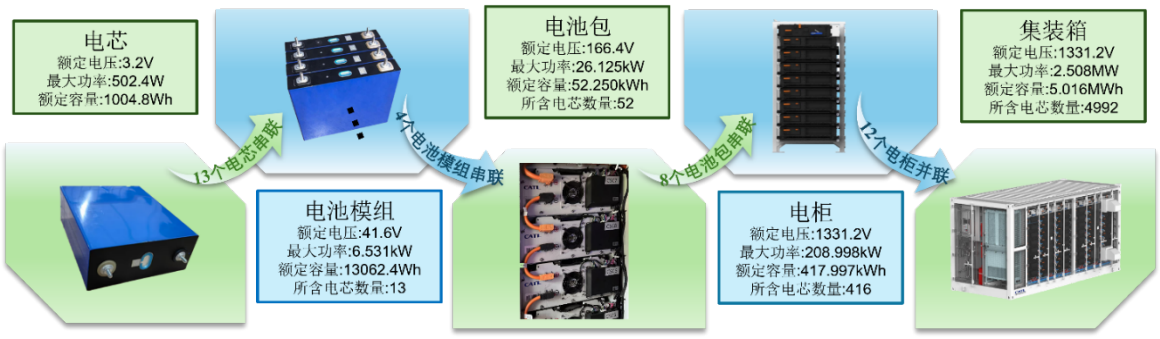


图5 实际储能集装箱内电芯串并联示意图

Fig. 5 Schematic diagram of battery cells in series and parallel in the actual energy storage container

为应对挑战（2）和（3），本文从等效电路建模的角度对电池簇结构进行了简化。任何电池簇均可等效为串联模块、并联模块或串并联混合结构。这种结构简化能够大幅降低仿真所需的内存和计算资源，从而提升效率，使大规模储能电站的系统级建模成为可能。本节在单体电芯二阶RC模型的基

础上，将电芯作为基本储能单元，依据电路的串并联特性构建储能集装箱模型。串联模块由多个电芯串联而成，电池模组的输出电压为各单体电芯电压之和；并联模块则由多个电芯并联而成，并表现出自均衡现象。一般认为，并联电路中各支路电压相同，总电流为各支路电流之和。串联电池模组与单体电芯的电压-电流关系由式(7)给出，并联电池模组与单体电芯的电压-电流关系由式(8)给出：

$$\begin{cases} I_m(t) = I_{c,1}(t) = I_{c,2}(t) = \cdots = I_{c,n}(t) \\ U_m(t) = U_{c,1}(t) + U_{c,2}(t) + \cdots + U_{c,n}(t) \end{cases} \tag{7}$$

$$\begin{cases} I_m(t) = I_{c,1}(t) + I_{c,2}(t) + \cdots + I_{c,m}(t) \\ U_m(t) = U_{c,1}(t) = U_{c,2}(t) = \cdots = U_{c,m}(t) \end{cases} \tag{8}$$

在公式中，$I_m(t)$代表流过电池模块的总电流，$U_m(t)$代表模块两端的端电压，$I_{c,n}(t)$代表流过第n个电芯的电流，$U_{c,n}(t)$代表第n个电芯两端的电压，其中n为串联连接的电芯数量，m为并联连接的电芯数量。当电池模块内各个独立电芯的阻抗参数相对接近时，串联电池模块的阻抗由公式9给出，而并联电池模块的阻抗由公式10给出：

$$\begin{aligned} Z_m(t) &= nR_{c0}(t) + \frac{nR_{c1}(t)}{1 + j\omega R_{c1}(t)C_1(t)} + \\ &\quad \frac{nR_{c2}(t)}{1 + j\omega R_{c2}(t)C_2(t)} \\ &= nR_{c0}(t) + \frac{nR_{c1}(t)}{1 + j\left(nR_{c1}(t)\right)\left(C_1(t)/n\right)} + \\ &\quad \frac{nR_{c2}(t)}{1 + j\left(nR_{c2}(t)\right)\left(C_2(t)/n\right)} \end{aligned} \tag{9}$$

$$\begin{aligned} Z_m(t) &= \frac{1}{m}R_{c0}(t) + \frac{R_{c1}(t)}{m + j\omega m R_{c1}(t)C_1(t)} + \\ &\quad \frac{R_{c2}(t)}{m + j\omega m R_{c2}(t)C_2(t)} \\ &= \frac{1}{m}R_{c0}(t) + \frac{R_{c1}(t)/m}{1 + j\omega\left(R_{c1}(t)/m\right)\left(mC_1(t)\right)} + \\ &\quad \frac{R_{c2}(t)/m}{1 + j\omega\left(R_{c2}(t)/m\right)\left(mC_2(t)\right)} \end{aligned} \tag{10}$$

在公式中，$R_{c0}(t)$代表电芯的欧姆内阻，$R_{c1}(t)$和$R_{c2}(t)$分别代表电芯的电化学极化电阻和浓差极化电阻，而$C_{c1}(t)$和$C_{c2}(t)$分别代表电芯的电化学极化电容和浓差极化电容。从上述公式可以看出，串联电池模块的电阻部分等效为电芯电阻的n倍，而串联电池模块的电容部分等效为电芯电容的$1/n$倍。对于并联电池模块，并联电池模块的电阻部分等效为电芯电阻的$1/m$倍，而并联电池模块的电容部分等效为电芯电容的m倍。$m\times n$电芯系统可以等效表示为二阶RC等效电路，如图6所示。$m\times n$电芯系统的参数如公式11所示。

$$\begin{cases} U_{mocv} = n \times U_{ocv} \\ Q_m = m \times Q_c \\ E_m = n \times m \times E_c \end{cases} \begin{cases} R_{m0} = nR_{c0}/m \\ R_{m1} = nR_{c1}/m \\ R_{m2} = nR_{c2}/m \end{cases} \begin{cases} C_{m1} = mC_{c1}/n \\ C_{m2} = mC_{c2}/n \end{cases} \tag{11}$$

在公式中，Q_m代表系统的电荷量，Q_c代表电芯的电荷量，E_m代表系统的总储能，E_c代表电芯的储能。R_{m0}、R_{m1}和R_{m2}分别代表系统的欧姆内阻、电化学极化电阻和浓差极化电阻。C_{m1}和C_{m2}分别代表系统的电化学极化电容和浓差极化电容。

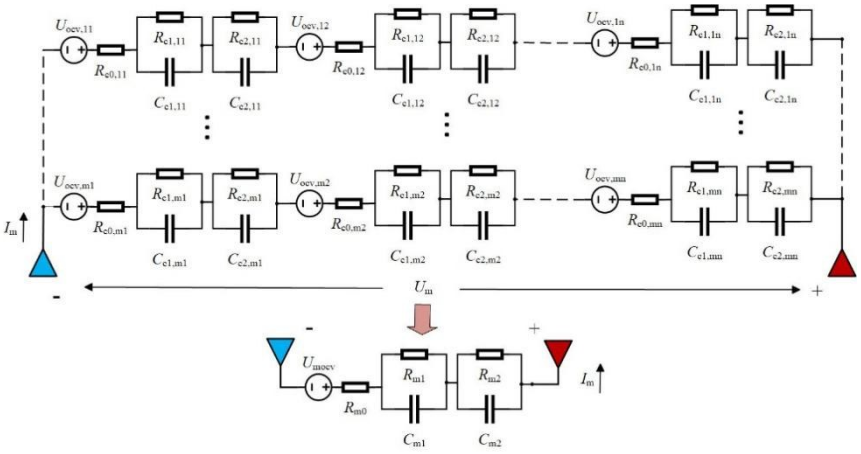
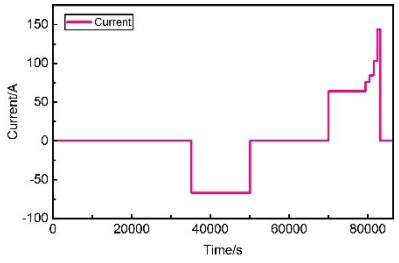


图6　具有n个串联电芯和m个并联电芯的电池簇等效电路

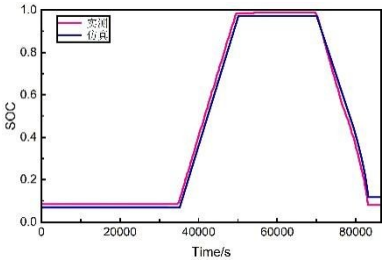
Fig. 6　The equivalent circuit of a battery cluster with n series-connected cells and m parallel-connected cells

为了验证所构建的等效电路模型的准确性，本研究选取了中国西北某储能电站特定日的实际运行数据进行仿真对比。电站电池柜的充放电行为如图7a所示，图中电池柜经历了一个完整的先充电后

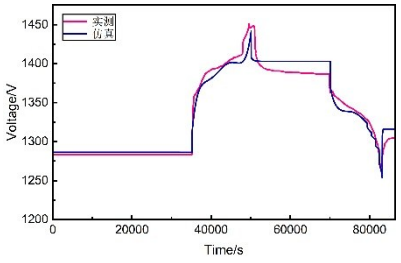
放电的循环，并且电流在放电阶段呈现持续增加的趋势。上述运行工况涵盖了典型的充放电过程，并且电流变化显著，因此具有很高的代表性。随后，基于所构建的等效电路模型，对包含416个电芯的电池柜进行了仿真，其中充放电条件和初始参数均设置为与实际运行相匹配。荷电状态（SOC）和电池柜电压的仿真结果分别如图7(b)和7(c)所示。对仿真结果的误差分析表明，最大电压误差约为44.42 V，对应的误差率为3.31%，而最大SOC误差为4.86%。上述仿真结果表明，所建立的等效电路模型表现出良好的准确性和适用性。



(a) 电柜电流



(b) 电柜SOC



(c) 电柜电压

图7 电池柜SOC与电压的仿真与实测对比图

Fig. 7 Comparison chart of simulated and measured cabinet SOC and voltage

3 储能电站仿真模型

为了提高系统的灵活性，现代兆瓦级储能电站通常采用集装箱式布局。储能电站并网模型由储能集装箱、变流器（PCS）、升压变压器、主变压器和电网（理想无穷大电源）等关键部件组成。在放电过程中，储能单元首先通过PCS将直流电转换为交流电，然后利用升压变压器升高电压以匹配配电网的电压等级。随后，电压由主变压器进一步升高并输送至电网。在充电过程中，能量流动的方向反转。电网电能经主变压器降压后进入配电网，接着由升压变压器和PCS将其转换为直流电，从而为储能单元充电。

3.1 模型结构

本研究基于中国西北某兆瓦级储能电站的拓扑结构和系统参数，构建了一个简化的大容量锂离子电池储能电站仿真模型，如图8所示。所采用的建模方法与文献[23]中描述的储能电站建模方法相似。储能部分的建模依据第2节中描述的实际储能集装箱拓扑进行，由底层单体电芯逐级等效扩展而来，单个储能集装箱的最大运行功率为2.508 MW，额定容量为5.016 MWh，如图5所示。此外，本文还对集成了PCS和升压变压器的IPS2000-07P/2500-G集成升压变流一体机（由深圳市汇川技术股份有限公司制造）进行了建模。在实际物理连接中，单个储能集装箱的直流侧接入该PCS，由PCS实现电能的双向交直流转换，其交流侧输出则连接至35kV/690V干式升压变压器。每个储能集装箱与其对应的集成升压变流器共同构成一个完整的储能模块。在系统整体拓扑结构中，20个这样的储能模块并联至35kV母线，随后通过主变压器进一步升压至110kV,最后通过一条15公里的架空线路连接至电网。

3.2 PCS模型及控制策略

储能变流器（PCS）的核心组件包括三相电压

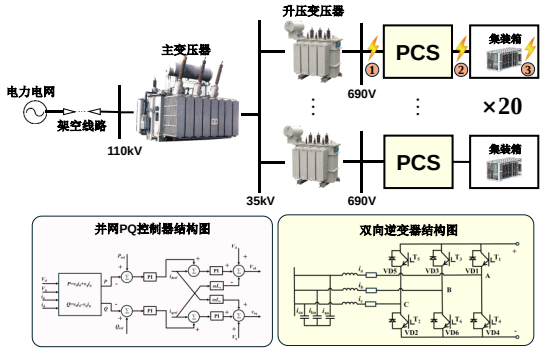


图8 储能电站并网模型结构图[23]

Fig. 8 Grid-connected model structure diagram of energy storage power station[23]

型双向变流器和LC（电感-电容）滤波器，如图8的黄色部分所示。本文采用三相电压型双向变流器，以实现储能单元与电网之间能量的双向流动。PCS交流侧通过LC滤波器与升压变压器相连，用于抑制变流器开关过程产生的高频谐波。LC滤波器的基本原理由公式12表示：

$$\begin{cases} 10f_n \leqslant f_c \leqslant \dfrac{f_s}{10} \\ f_c = \dfrac{1}{2\pi\sqrt{L_f C_f}} \end{cases} \tag{12}$$

在公式中，f_c代表LC滤波器的谐振频率；f_n为电网基波频率，f_s为开关频率，L_f为滤波器的电感，C_f为滤波器的电容。

考虑到LC滤波器容易发生振荡，在设计LC滤波器时会串联一个小电阻，以有效抑制振荡现象。滤波器的传递函数，即输出电压V_{out}与输入电压V_{in}之间的关系，由公式13给出。

$$G(j\omega) = \frac{V_{out}}{V_{in}} = \frac{\omega_0^2}{(j\omega)^2 + j\omega \cdot 2\xi\omega_0 + \omega_0^2} \tag{13}$$

式中，$\omega_0 = \dfrac{1}{\sqrt{L_f C_f}}$，$\xi = \dfrac{R}{2}\sqrt{\dfrac{C_f}{L_f}}$。

LC滤波器参数设计需兼顾谐波抑制能力与系统动态响应速度，并保证滤波器两端电压降不超过系统电压的10%[24]。本研究基于中国西北某储能电站的电气接线图进行LC滤波器的设计，其中系统电压为U= 690 V，系统频率为f_n=50 Hz，开关频率为f_s=10 kHz。利用公式12和公式13，计算得出滤波器参数为L_f=1mH和C_f=100uF。

在确定交流侧LC滤波器参数后，本文进一步采用基于dq轴解耦的恒功率控制策略对PCS并网运行过程进行建模。该控制策略采用功率外环和电流内环的双闭环结构，其中功率外环根据有功功率参考值P_{ref}、无功功率参考值Q_{ref}与实际测量值P_m、Q_m之间的偏差，生成d、q轴电流参考值。参考电流的计算公式如下：

$$\begin{cases} i_{dref} = \left(k_{p1} + \dfrac{k_{i1}}{S}\right)(P_{ref} - P_m) \\ i_{gref} = \left(k_{p2} + \dfrac{k_{i2}}{S}\right)(Q_{ref} - Q_m) \end{cases} \tag{14}$$

在公式中，k_{p1}、k_{i1}、k_{p2}和k_{i2}代表PQ控制器的比例和积分控制参数。d轴和q轴电压的计算公式如下：

$$\begin{cases} V_{sd} = \left(k_{ip} + \dfrac{k_{il}}{s}\right)(i_{dref} - i_d) + V_d - \omega L i_q \\ V_{sq} = \left(k_{ip} + \dfrac{k_{il}}{s}\right)(i_{qref} - i_q) + V_q + \omega L i_d \end{cases} \tag{15}$$

在$dq0$坐标系中，q轴分量V_q通常设置为0。实际的有功功率P和无功功率Q是通过测量获得的，计算公式如下：

$$\begin{cases} P = v_d i_d + v_q i_q \\ Q = v_q i_d - v_d i_q \end{cases} \tag{16}$$

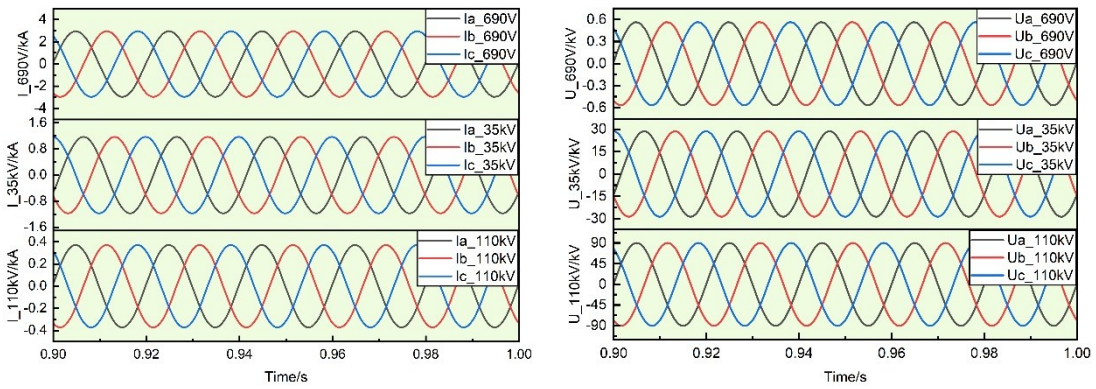
三相电压（V_a、V_b、V_c）和三相电流（i_a、i_b、i_c）首先通过锁相环（PLL）获取，再经派克变换转换为dq轴电压（V_d、V_q）和dq轴电流（i_d、i_q）。之后，利用式(16)计算有功功率P和无功功率Q，并将其与参考值P_{ref}和Q_{ref}进行比较。PI（比例-积分）控制器根据功率误差对电流进行调节。此外，系统还通过电压前馈补偿和交叉耦合补偿进一步优化控制性能。最终生成电压控制信号V_{sd}和V_{sq}，这些电压信号经派克反变换和PWM（脉宽调制）调制后，形成正弦调制信号，从而实现PQ解耦与恒功率控制。

3.3　仿真分析

针对储能电站并网模型，本文在不同荷电状态（SOC = 0.1、0.3、0.5、0.7、0.9）下分别开展仿真分析，并获取了690V、35kV和110kV电压等级下的三相电流和电压波形。仿真结果表明，在PCS恒功率控制作用下，并网侧三相电压和三相电流均能保持稳定正弦波形，不同SOC工况下的交流侧波形未出现明显差异，模型均可稳定输出50MW有功功率。因此，本文选取电站日常运行中较具代表性的中等荷电状态SOC = 0.5，展示系统稳态运行时段（0.9s－1s）的三相电流和电压波形，如图9a和图9b所示。该结果验证了所建模型在宽SOC范围内的稳定性与适用性。

4　故障仿真结果

储能电站的故障研究具有重要的工程价值和现实意义。第3节已介绍了储能电站的并网模型，并对其正常运行状态进行了仿真分析。本节将基于该模型开展储能电站的故障研究，分析内部短路和开路故障对电网的影响。具体而言，短路故障将设置在电芯、电池模组、电池包、电池柜和储能集装箱等不同层级，而开路故障则涵盖电池柜、储能集装



(a) 三相电流 (b) 三相电压

图9 正常运行工况下不同电压等级的三相电流与三相电压

Fig. 9 Three-phase current and three-phase voltage at different voltage levels under normal operating conditions

箱层级。此外，由于故障可能发生在充电、放电或待机等不同运行工况下，本节将对不同工况下的故障演化特性进行详细研究。电力系统涉及多个电压等级，本节将分析不同故障类型（短路、开路）、不同储能层级（电芯、电池模组、电池包、电池柜、集装箱）以及不同运行工况（充电、放电、待机）下的故障特性，共计2×5×3=30种工况。将对不同电压等级（690V、35kV、110kV）下采集的三相电流、三相电压、有功功率和无功功率数据进行分析，为储能电站故障研究提供仿真支撑。如第3节所述，储能电站在不同SOC水平下均能保持稳定运行，因此选取电站日常运行中常见的中等荷电状态SOC=0.5作为故障场景分析的代表性工况。

除短路和开路等拓扑型故障外，储能电站长期运行中还可能出现容量衰减、电芯不一致等参数型缺陷。本文所建立的可扩展二阶 RC 等效电路模型不仅可通过改变连接状态模拟短路和开路故障，也可通过修正等效储能单元的容量、内阻、极化电阻、极化电容等参数描述参数型缺陷。以容量衰减为例，可将等效储能单元容量由 C_N 修正为 $C_N^* = k_Q \cdot C_N$，其中 $0 < k_Q < 1$。在相同充放电电流作用下，容量衰减单元的 SOC 演化速度将加快，持续充放电裕度减小，但由于其不直接形成低阻通路，通常不会像短路故障那样引起 690 V、35 kV 和 110 kV 侧电流、电压及功率的瞬时突变。因此，本文后续重点针对对电网暂态影响更显著的短路和开路故障开展分析。

4.1 短路故障

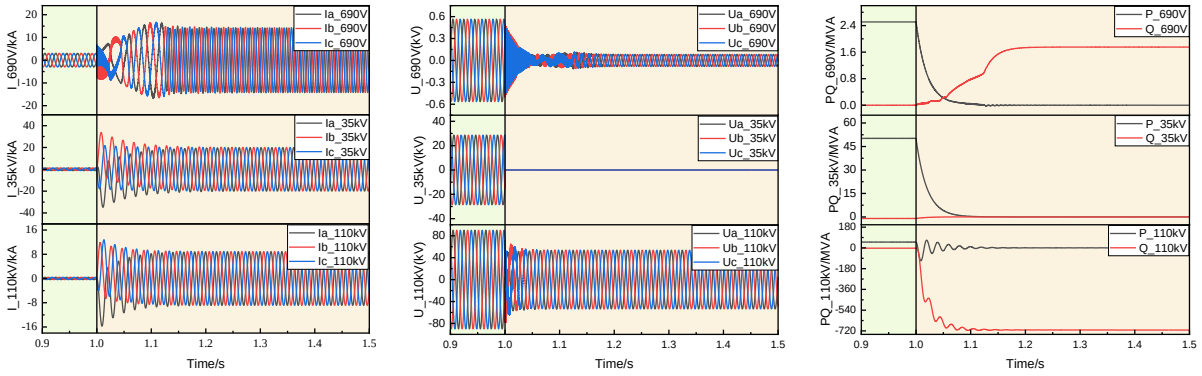
为清晰观察故障的动态演变过程，本研究将短路故障触发时刻统一设定在仿真开始后1秒。电芯、电池模组、电池包和电池柜的短路故障指将其正、负极直接短接。需要说明的是，由于储能集装箱由12个电池柜并联组成，在集装箱层级设置短路故障与在电池柜层级设置短路故障效果相同，因此，本文将集装箱层级的短路故障建模为储能变流器（PCS）输出侧的三相接地故障，这更能代表现场可能发生的严重故障类型。

在实际工程应用中，关键电气参数常被用于故障监测与诊断。因此，本研究在690V、35kV和110kV母线处分别设置了监测点。690V和35kV监测点位于故障支路上，以便更准确地捕捉故障对不同电压等级系统的影响。监测参数包括三相电流、三相电压、输出有功功率和输出无功功率（除特别说明外，文中无功功率均指感性无功），从而全面分析短路故障对储能电站及电网侧运行特性的影响。采样频率为10 kHz。

4.1.1 储能集装箱

储能集装箱变流器输出端发生的三相短路故障位于图8中的位置1。放电工况下的参数变化如图10所示。图10a给出了三相电流的变化情况，故障发生后，三相电流在0.1秒内急剧上升并失去稳定性，690V侧短路电流峰值为16kA，35kV侧为38.4kA，110kV侧为15.7kA。图10b展示了电压波动情况，690V电压在0.1秒内骤降至82V，35kV电压几乎降至零，110kV电压降至53kV。图10c反

映了有功功率和无功功率的变化，690V侧有功功率降为零，无功功率从0增至1.75 MVar；35kV侧有功和无功功率均降为零；110kV侧有功功率经短暂波动后最终降为零，无功功率从0激增至712 MVar。充电和待机工况下的短路故障也呈现出相似的参数变化特征。



(a)　三相电流　　(b)　三相电压　　(c)　有功功率与无功功率

图10　储能集装箱变流器输出端三相短路时690V、35kV和110kV侧三相电流、三相电压、有功功率及无功功率的变化情况

Fig. 10　Graphs of variations in three-phase current, three-phase voltage, active power, and reactive power at 690V, 35kV, and 110kV under a three-phase short circuit occurring at the output of the converter of the energy storage container

为清晰展示充电和放电工况下短路故障引起的参数变化，表2汇总了各参数的变化情况（待机工况下的参数变化与充放电工况相似，故不再单独列出）。其中，“+”表示增加，“-”表示减少；单独使用“-”表示该参数未出现可观测的变化。三相电流、三相电压和有功功率采用变化率表征，无功功率则采用变化值表征（正常工况下无功功率为零，无法使用变化率）。

从机理角度分析，三相短路发生后，故障点具有极低的接地阻抗，导致大量短路电流涌向故障点，产生严重的短路冲击。发生于690V侧的三相接地短路导致35kV和110kV侧电压显著跌落。同时，储能侧向电网的有功功率传输被中断，最终使有功功率降为零。为维持110kV母线电压的稳定，电网侧的无功功率流向故障点，其流过的无功功率被主变压器的等效感抗所吸收，从而提供暂时的电压支撑。类似地，储能侧PCS内部的容性元件消耗容性无功功率（相当于提供感性无功功率），其流过的无功功率被升压变流逆变单元中的变压器所吸收，进而为690V侧提供暂时的电压支撑。

除上述PCS交流侧三相接地短路故障外，考虑到实际工程中单相接地故障是较为常见的不对称短路类型，本文进一步补充了升压变压器35 kV出线端A相单相接地故障的仿真分析。与PCS交流侧三相接地短路主要用于表征储能集装箱交流输出端严重对称短路冲击不同，升压变压器35 kV出线端位于储能集装箱升压并网链路的交流出口处，在该位置设置单相接地故障能够反映储能集装箱接入

表2　不同层级短路故障下三相电流、三相电压、有功功率及无功功率的变化

Table 2　Under short-circuit faults at different levels, the changes in three-phase current, three-phase voltage, active power, and reactive power

电压等级	短路故障	储能集装箱		电柜		电池包等
	运行工况	放电	充电	放电	充电	-
690V	三相电流幅值	+540%	+577%	+8990%	+9509%	-
35kV		+3250%	+3813%	+127%	+132%	-
110kV		+4360%	+4305%	+119%	+122%	-
690V	三相电压幅值	-86%	-95%	-18%	-16%	-
35kV		-100%	-100%	-	-	-
110kV		-42%	-42%	-	-	-
690V	有功功率	-100%	-100%	-100%	-100%	-
35kV		-100%	-100%	-5%	-5%	-
110kV		-100%	-100%	-5%	-5%	-
690V	无功功率	+1.75Mvar	+1.1Mvar	-12Mvar	-12Mvar	-
35kV		0	0	-15Mvar	-15Mvar	-
110kV		-712Mvar	-712Mvar	-17Mvar	-17Mvar	-

35 kV 系统时较具代表性的不对称接地故障电气响应特征。故障时刻同样设定为1 s。

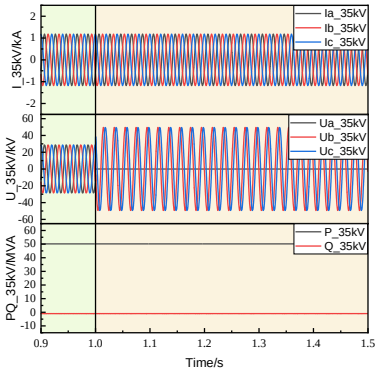


图11 升压变压器 35 kV 出线端 A 相单相接地故障下 35 kV 侧电气量变化

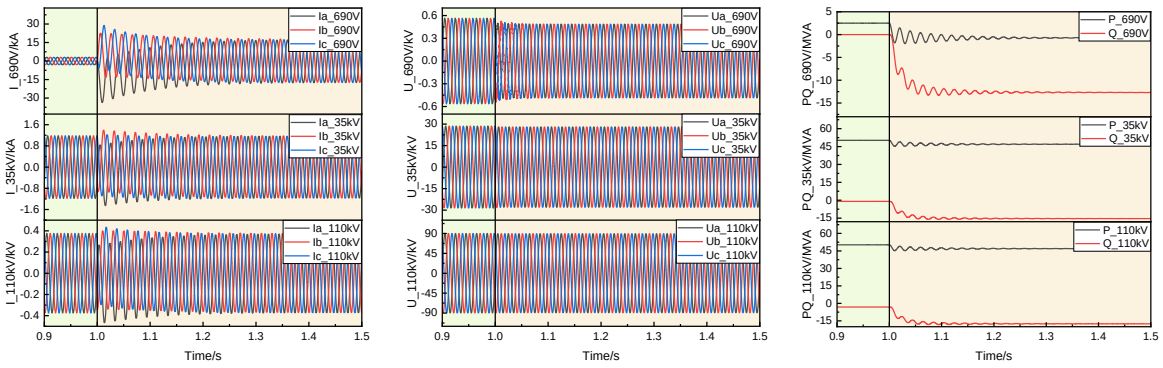
Fig. 11 Variations of electrical quantities on the 35 kV side under an A-phase single-line-to-ground fault at the outgoing terminal of the step-up transformer

图 11 给出了放电工况下35 kV侧三相电流、三相对地电压以及有功、无功功率的变化情况，充电和待机工况下的同类单相接地故障也呈现出相似的参数变化特征。由图可见，故障发生后，A相对地电压被钳位至接近0，B、C两相对地电压由正常相对地电压升高至接近线电压，而35 kV侧三相线电流、有功功率和无功功率未出现明显变化。其原因在于故障点两侧相邻变压器绕组均采用三角形接法，零序电流缺乏向PCS侧和110 kV电网侧传播的有效通道，因此该类故障并未形成类似三相短路的大电流冲击，而主要表现为局部相对地电压重构和健全相对地电压升高。进一步观察690 V侧、110 kV侧的数据发现，其电气量均未出现明显暂态变化，考虑到相关波形与正常运行状态基本一致，正文仅展示故障点所在35 kV侧的典型波形。由此可见，在该接线方式下，升压变压器35 kV出线端单相接地故障主要体现为局部绝缘应力增大，而对并网侧线电流和功率传输的影响相对较小。

4.1.2 电池柜

电柜正负极发生的短路故障位于图8中的位置2。当储能集装箱内单个电池柜发生短路时，690 V、35 kV和110 kV侧的三相电流、三相电压、有功功率及无功功率的变化如图12所示。充放电工况下短路故障引起的参数变化见表2，待机工况下的参数变化与充放电工况相似，故不再列出。

从机理角度分析，由于集装箱内12个电池柜采用并联结构，当一个电池柜发生短路时，等效于集装箱内所有电池柜同时短路，从而导致690 V侧短路电流显著增大。尽管故障支路的短路电流有所增加，但35 kV和110 kV母线仍与其余19个储能集装箱相连，因此其电流不会失稳。此外，故障支路电压跌落之后，电网侧向故障支路提供12 MVar的无功功率，该无功功率被升压变流逆变单元中变压器的等效感抗所吸收，从而维持690 V母线的电压水平。



(a) 三相电流 (b) 三相电压 (c) 有功功率与无功功率

图12 电池柜短路时690V、35kV和110kV侧三相电流、三相电压、有功功率及无功功率的变化情况

Fig. 12 Graphs of variations in three-phase current, three-phase voltage, active power, and reactive power at 690V, 35kV, and 110kV under the short-circuit condition of the battery cabinet

4.1.3 电池包、电池模组与电芯

电芯、电池模组和电池包的短路故障设置于图8中的位置3。仿真结果表明，在所有运行工况（充电、放电和待机）下，690 V、35 kV和110 kV

侧的三相电流、三相电压、有功功率和无功功率均未出现可观测的变化，如表2所示。其主要原因在于，电池柜内部的储能单元采用串联拓扑结构，短路故障发生后，故障支路的电压、电流和功率在整体输出层面并未表现出明显变化。因此可以得出结论：电池包、电池模组和电芯的短路故障对电网侧的影响极小。

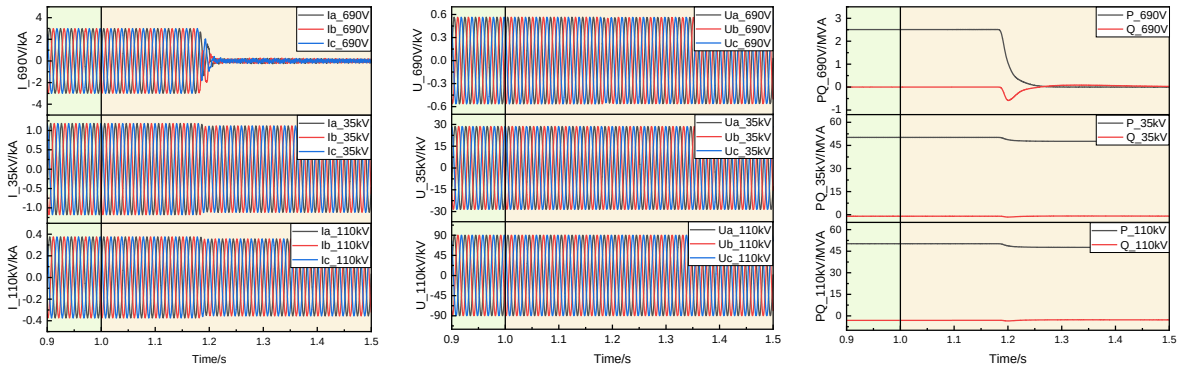
4.2　开路故障

本节将重点研究储能电站中发生的开路故障。开路故障统一设置在仿真开始后1秒触发。电芯、电池模组、电池包、电池柜或储能集装箱的开路故障，是指储能单元在正常运行过程中发生的连接断开。

4.2.1　储能集装箱

储能集装箱的开路故障位于图8中的位置2。690 V、35 kV和110 kV侧的三相电流、三相电压、有功功率及无功功率的变化如图13所示。图13a展示了690 V、35 kV和110 kV侧的三相电流波形：故障发生后，690 V支路的电流并未立即变化，而是在1.2秒时降至零；35 kV和110 kV侧的三相电流幅值也于1.2秒时分别下降了60 A和20 A。图13b给出了三相电压的波动情况，可以看出三相电压几乎未受影响。图13c反映了有功和无功功率的变化：故障后，690 V故障支路的有功功率降至零，无功功率虽出现轻微波动，但仍接近于零；此外，35 kV和110 kV侧的有功功率均下降了2.5 MW。充电工况下的开路故障也呈现相似的参数变化特征，而待机工况下的开路故障则不会引起任何可观测的参数变化。

为清晰展示充电和放电工况下开路故障引起的参数变化，表3汇总了各参数的变化情况（待机工况下参数变化不可观测，故不再列出）。其中，“+”表示增加，“-”表示减少；单独使用“-”表示该参数未出现可观测的变化。三相电流、三相电压和有功功率采用变化率表征，无功功率则采用变化值表征（正常工况下无功功率为零，无法使用变化率）。



(a)　三相电流　　(b)　三相电压　　(c)　有功功率与无功功率

图13　储能集装箱开路故障时690V、35kV和110kV侧三相电流、三相电压、有功功率及无功功率的变化情况

Fig. 13　Graphs of variations in three-phase current, three-phase voltage, active power, and reactive power at 690V, 35kV, and 110kV under the open-circuit fault condition of the container

从机理角度分析，储能集装箱发生开路故障后，故障支路电流降为零，相应的有功功率输出也变为零。然而，电流并未在断开的瞬间立即降为零，这主要是由于升压变流逆变单元内含有滤波电容，故障后电容经历短暂放电，在0.2秒内产生较小的电流和功率输出。与此同时，由于其他支路继续保持正常运行并起到稳定电压的作用，储能集装箱的开路故障不会对母线的电压造成影响。电网侧的有功功率损失仅对应于被断开的单个集装箱的输出功率。

4.2.2　电池柜

储能系统中单个电池柜的开路故障发生于图8中的位置3。690V、35kV和110kV侧的三相电流、三相电压、有功功率及无功功率的变化如图14所示。充放电工况下开路故障引起的参数变化见表3，待机工况下的参数变化不可观测，故不再列出。

从机理角度分析，电池柜开路故障的影响与储能集装箱开路故障相似，但影响程度更小。与储能

表3 不同层级开路故障下三相电流、三相电压、有功功率及无功功率的变化

Table 3 Under open-circuit faults at different levels, the changes in three-phase current, three-phase voltage, active power, and reactive power

电压等级	开路故障	储能集装箱		电柜		电池包等
	运行工况	放电	充电	放电	充电	放电/充电
690V		-93%	-95%	-8.3%	-8.3%	-8.3%
35kV	三相电流幅值	-5%	-5%	-	-	-
110kV		-5%	-5%	-	-	-
690V		-	-	-	-	-
35kV	三相电压幅值	-	-	-	-	-
110kV		-	-	-	-	-
690V		-100%	-100%	-8.3%	-8.3%	-8.3%
35kV	有功功率	-5%	-5%	-	-	-
110kV		-5%	-5%	-	-	-
690V		0	0	0	0	0
35kV	无功功率	0	0	0	0	0
110kV		0	0	0	0	0

集装箱开路故障相比，电池柜开路故障所引起的三相电流和有功功率降幅相对较小，这主要是因为单个电池柜所含的储能电芯数量较少，当其断开时，对系统整体电流和功率分布的影响有限。

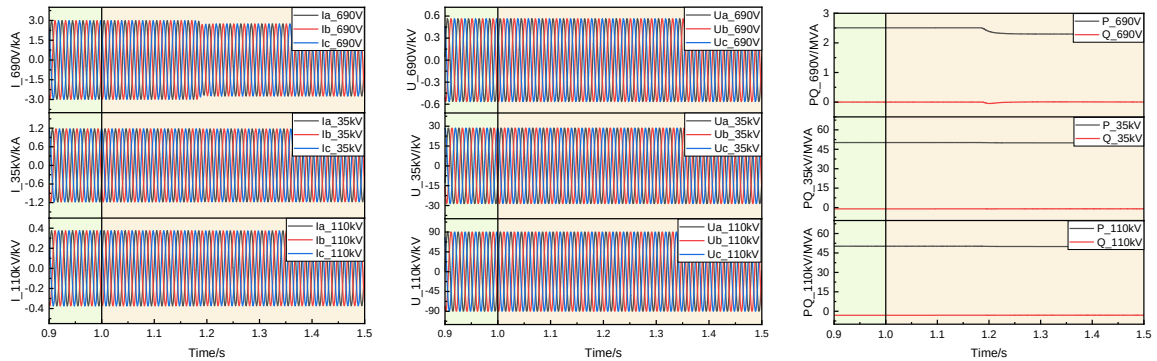
4.2.3 电池包、电池模组与电芯

电池包、电池模组和电芯的开路故障设置于图8中的位置3。由于电池柜内部的储能单元采用串联结构，电池包、电池模组和电芯等层级的储能单元发生开路故障时，其表现与电池柜开路故障一致。因此可以认为，储能电池包、电池模组和电芯发生开路故障后，三相电流、三相电压、有功功率及无功功率的变化与电池柜开路故障所观测到的现象相似。待机工况下的参数变化不可观测。

5 基于仿真时序数据的故障识别与智能决策

前文第2节建立了从电芯到储能集装箱的可扩展二阶RC等效电路模型，第3节构建了储能电站并网仿真模型，第4节进一步获得了不同故障类型、不同储能层级和不同运行工况下的电压、电流及功率时序响应。为了使仿真分析结果进一步服务于储能电站故障识别与应急处置，本文将前文仿真得到的电气量数据作为深度学习模型的输入，构建故障识别模型，并将识别结果与基于RAG的大语言模型辅助决策系统相结合。由此形成“电池建模—并网仿真—故障特征提取—故障识别—应急策略生成”的完整技术流程。

在上述仿真时序数据基础上，本文进一步构建深度学习故障识别与大语言模型辅助决策系统。深度学习算法对仿真生成的大量时序数据（三相电流、三相电压、有功功率和无功功率）进行处理，实现故障类型的精确识别，并将识别结果输入大语言模型。借助检索增强生成（RAG）技术，大语言模型能够基于相关国家标准进行推理与学习，最终生成具有决策指导意义的应对策略。该系统的整体架构将深度学习算法与大语言模型高效结合，提升了决策过程的自动化与智能化水平。系统示意图如图15所示。



(a) 三相电流 (b) 三相电压 (c) 有功功率与无功功率

图14 电池柜开路故障时690V、35kV和110kV侧三相电流、三相电压、有功功率及无功功率的变化情况

Fig. 14 Graphs of variations in three-phase current, three-phase voltage, active power, and reactive power at 690V, 35kV, and 110kV under the open-circuit fault condition of the battery cabinet

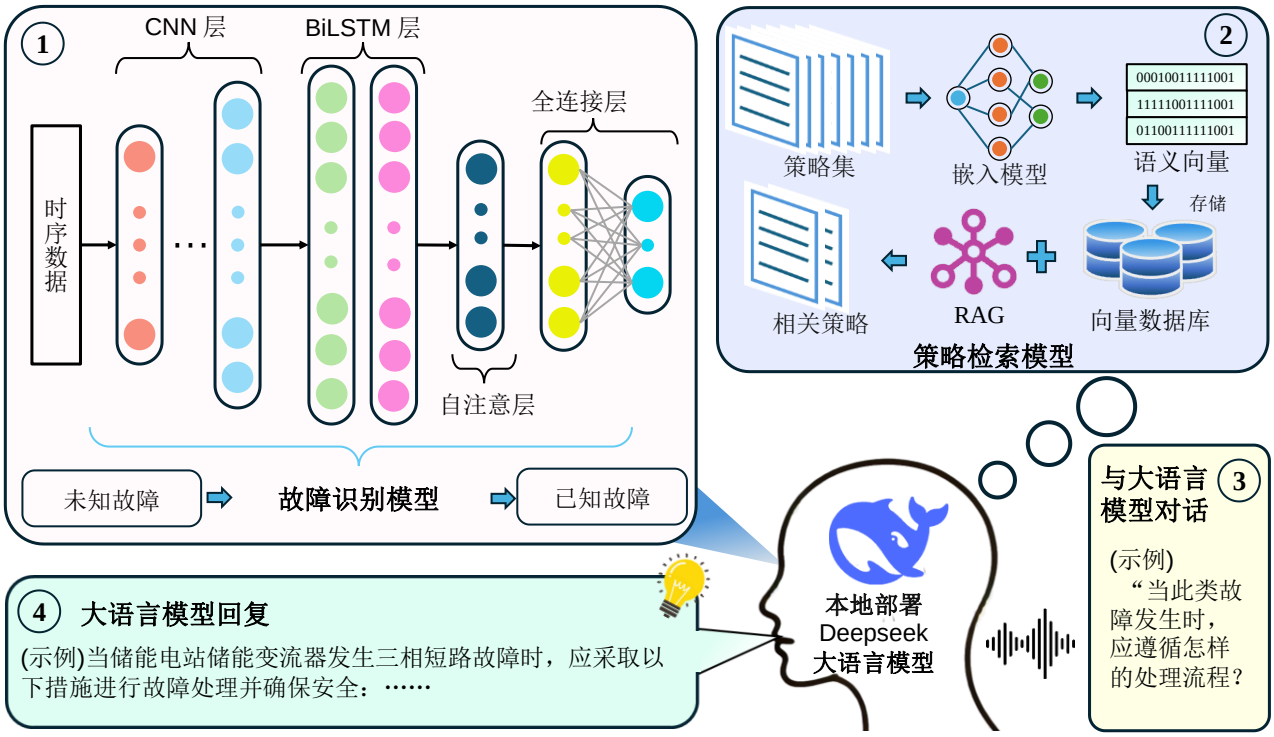


图 15　大语言模型辅助下储能电站应急策略示意图

Fig. 15　Schematic diagram of emergency strategies for energy storage power stations assisted by LLM

本文对所提出的深度学习算法进行了测试。利用 12 种故障场景下的时序数据对模型进行训练，随后从同类故障的仿真数据中提取新数据作为未知输入，以验证 CNN-BiLSTM-A 算法。最终结果表明，该算法能够对所有 12 种故障类型实现准确识别，准确率均超过 98.4%。

5.1　CNN-BiLSTM-A

本文所采用的故障识别数据来源于第 4 节储能电站故障仿真结果。具体而言，第 4 节分析了不同运行工况下、不同储能层级的短路和开路故障，并提取 690V、35kV 和 110kV 三个电压等级下的三相电流、三相电压、有功功率和无功功率作为输入特征。上述电气量能够反映故障发生后储能电站内部及电网侧的动态响应特征，因此可作为深度学习模型识别故障类型的基础数据。考虑到电芯、电池模组和电池包的短路故障与正常运行工况相似，而电芯、电池模组和电池包的开路故障又与电池柜开路故障相似，因此可识别的故障类型缩减为 3×2×2 =12 种。

为实现故障类型的快速识别，本文提出了一种融合 CNN、BiLSTM 与自注意力机制的深度学习算法。每种故障类型包含 690V、35kV 和 110kV 侧的三相电流、三相电压、有功功率和无功功率，共计 24 列数据。首先，将 24 维时序数据输入一个五层的一维卷积网络，其卷积核大小依次设置为 15、8、8、5、3，各层卷积通道数由 8 逐步增加至 128，从而对输入信号进行层次化的局部特征提取。每个卷积层之后均接有最大池化层，用于在保留最重要信息的同时降低特征维度。其次，将卷积层提取的特征输入至配置为两层的双向 LSTM 模块中。BiLSTM 以 79 个时间步（序列长度）作为输入，每层包含 64 个隐藏单元，通过门控机制捕捉序列中的长期依赖关系；其双向架构能够同时从前向和后向两个方向对序列进行时序建模。再次，在 BiLSTM 输出之后引入一个单层自注意力机制，对输出进行加权处理；该过程采用 SoftMax 归一化计算注意力权重，能够动态调整并突出对故障识别至关重要的时间步。最后，将 CNN、BiLSTM 和自注意力模块提取的融合特征输入一个全连接层进行分类，输出经 SoftMax 激活函数转化为最终的分类概率，实现多分类以区分不同的故障类型。

为进一步验证 CNN-BiLSTM-A 模型在储能电站故障识别任务中的有效性，本文在相同数据集、相同输入特征和相同测试条件下，选取 SVM（支

持向量机）、随机森林、CNN、LSTM、BiLSTM 和 CNN-BiLSTM 等模型作为基线方法进行对比分析。各模型均采用 690 V、35 kV 和 110 kV 侧的三相电流、三相电压、有功功率和无功功率作为输入特征，以保证不同算法之间具有一致的比较基础。不同故障识别模型的测试集识别准确率如图 16 所示。

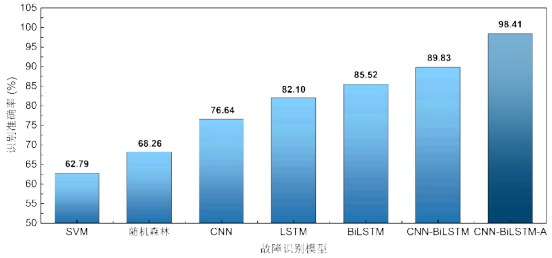


图 16　故障识别模型准确率对比图

Fig. 16　Accuracy comparison of different fault recognition models

由图 16 可知，SVM 和随机森林的识别准确率分别为 62.79% 和 68.26%，说明传统机器学习方法虽然能够对不同故障类型进行一定区分，但其对高维时序故障波形中复杂暂态特征的表征能力有限。单一 CNN 模型的识别准确率为 76.64%，表明卷积结构能够提取电压、电流和功率波形中的局部突变特征，但对故障演化过程中的长时序依赖关系刻画不足。LSTM 和 BiLSTM 的识别准确率分别为 82.10% 和 85.52%，说明循环神经网络能够更好地捕捉故障信号的时间演化规律，其中 BiLSTM 由于同时利用前向和后向时序信息，识别效果优于单向 LSTM。进一步地，CNN-BiLSTM 模型的识别准确率提高至 89.83%，表明局部特征提取与双向时序建模的结合能够有效提升储能电站故障识别性能。

在 CNN-BiLSTM 结构的基础上，本文进一步引入自注意力机制，构建 CNN-BiLSTM-A 模型。该模型的识别准确率达到 98.41%。上述结果表明，自注意力机制能够对故障发生前后的关键时间步赋予更高权重，从而突出对故障分类具有重要贡献的暂态特征。因此，本文所提出的 CNN-BiLSTM-A 模型能够更有效地融合局部波形特征、双向时序特征和关键时间特征，在储能电站故障识别任务中表现出更高的识别准确率。

5.2　LLM

在完成故障类型识别后，仅获得故障类别仍不足以支撑现场运维人员快速处置故障。因此，本文进一步构建 AI 辅助决策支持系统，将 CNN-BiLSTM-A 模型的输出作为大语言模型辅助决策模块的输入信息。上述输入信息直接来源于前文仿真分析结果和深度学习识别结果，使大语言模型生成的应急策略不仅依赖通用知识库，也能够结合具体故障场景下的电气响应特征，从而提高策略生成的针对性和工程适用性。具体而言，该系统融合检索增强生成（RAG）技术，能够从本地知识库中高效检索相关文献和国家标准，并将检索结果与故障详情一并通过 API（应用程序编程接口）输入本地部署的大语言模型，由后者生成针对性的故障处理策略。该系统在 Python 环境下开发，并通过 Ollama 平台将深度学习、RAG 技术与大语言模型集成为一个智能故障响应框架，在保障数据安全的同时提升故障决策过程的自动化与智能化水平。

本文聚焦于中国储能电站的故障应对策略。其中，GB/T 42312-2023、GB/T 42288-2022、GB/T 40090-2021、GB/T 34131-2023、GB/T 14048.2-2020、GB 38031-2020 和 GB/T 36276-2023 等国家标准对储能电站的故障应对策略作出了规定，本文将上述策略集用于构建知识库。在利用 CNN-BiLSTM-A 深度学习算法识别故障类型后，采用 RAG 检索技术搜索相关的策略集，随后由本地部署的大语言模型进行决策支持。

具体而言，本文以放电工况下集装箱侧升压变流器输出端的三相短路数据作为未知输入，经 CNN-BiLSTM-A 深度学习算法处理后，被正确识别为放电工况下的集装箱侧升压变流器输出端三相短路。故障类型识别完成后，RAG 技术从知识库中快速检索出最相关的文档。这些文档随后被导入大语言模型，并执行预设指令（例如“当此类故障发生时，应遵循怎样的处理流程?”）。经过深度推理后，大语言模型给出的结论如图 17 所示。

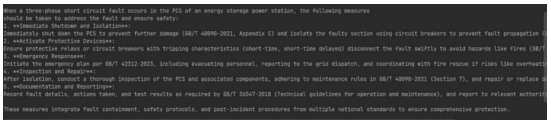


图 17　大语言模型基于国家标准提供的智能故障应对策略

Fig. 17　LLM provide intelligent fault response strategies based on national standards

为避免仅通过单一示例展示大语言模型生成结果，本文进一步对此辅助决策系统生成的故障应急策略进行定量评价。由于本文所生成的内容属于面向储能电站故障处置的开放式策略文本，传统BLEU（双语评估替代指标）、ROUGE（面向召回的摘要评估指标）等基于文本重合度的评价指标难以准确反映策略的工程合理性。因此，本文参考大语言模型生成结果评价中的量表化评价方法、基于参考答案与评分细则的细粒度评价方法，以及将长文本拆解为原子事实后逐条核查的思想[25-27]，从策略正确性、策略完整性和策略可执行性三个方面构建评价指标体系。

对于不同故障场景，首先依据储能电站运行规程、相关国家标准、故障仿真结果构建人工参考策略集。随后，将故障识别结果输入辅助决策系统，由大语言模型生成对应的应急响应策略。最后，将生成策略拆解为若干原子处置条目，并由10名评价人员进行独立评估，取平均值作为最终评价结果。参与评价的10名评价人员由3名电网企业工程技术人员，3名电气工程专业研究生、2名电气工程领域专家、2名宁德时代工程师组成。评价前，所有评价人员均获得相同的参考策略集。

本文定义的三个评价指标如下。

（1）策略正确性。策略正确性用于评价大语言模型生成的处置条目是否符合储能电站故障处理逻辑、国家标准和工程经验，是否存在错误操作或危险操作，其计算公式为：

$$S_{\mathrm{cor}}=\frac{1}{K}\sum_{k=1}^{K}\frac{N_{\mathrm{cor}}^{(k)}}{N_{\mathrm{gen}}}\times 100\% \tag{17}$$

式中，S_{cor}为策略正确性得分；K为评价人员数量，本文取K=10；N_{gen}为大语言模型生成的原子处置条目总数；$N_{\mathrm{cor}}^{(k)}$为第k名评价人员判定为正确、合理且不存在危险操作的处置条目数量。

（2）策略完整性。策略完整性用于评价大语言模型生成的应急策略是否覆盖参考策略集中要求的关键处置环节，其计算公式为：

$$S_{\mathrm{com}}=\frac{1}{K}\sum_{k=1}^{K}\frac{N_{\mathrm{cov}}^{(k)}}{N_{\mathrm{ref}}}\times 100\% \tag{18}$$

式中，S_{com}为策略完整性得分；K为评价人员数量，本文取K=10；N_{ref}为参考策略集中应覆盖的关键处置环节数量；$N_{\mathrm{cov}}^{(k)}$为第k名评价人员判定生成策略实际覆盖的关键处置环节数量。

（3）策略可执行性。策略可执行性用于评价生成策略是否具有明确的操作对象、操作顺序和现场实施可行性。该指标采用1—5分专家评分法，评分由低到高依次表示“难以执行、可执行性较弱、基本可执行、可执行性较强、工程实施可行性强”。其归一化计算公式为：

$$S_{\mathrm{exe}}=\frac{1}{5K}\sum_{k=1}^{K}s_k\times 100\% \tag{19}$$

式中，S_{exe}为策略可执行性得分；s_k为第k名评价人员对生成策略可执行性的评分；K为评价人员数量，本文取K=10。

综合评分定义为三项指标的平均值：

$$S_{\mathrm{all}}=\frac{S_{\mathrm{cor}}+S_{\mathrm{com}}+S_{\mathrm{exe}}}{3} \tag{20}$$

表4给出了典型故障场景下此辅助决策系统生成策略的定量评价结果。

表4　辅助决策系统生成策略的定量评价结果

Table 4　Quantitative Evaluation Results of Strategies Generated by the Assisted Decision-Making System

代表性故障场景	策略正确性/%	策略完整性/%	策略可执行性/%	综合评分/%
集装箱层级短路	92.0	90.0	88.0	90.0
电池柜短路	91.0	87.5	86.0	88.2
电池包/模组/电芯局部短路	88.9	85.7	80.0	84.9
集装箱开路	91.1	91.4	86.0	89.5
电池柜开路	91.3	88.6	82.0	87.3
平均值	90.9	88.6	84.4	88.0

由表4可知，在5类代表性故障场景下，辅助决策系统生成策略的平均正确性、完整性和可执行性分别为90.9%、88.6%和84.4%，综合评分为88.0%。

总体来看，辅助决策系统生成策略在正确性、完整性和可执行性方面均具有较好的表现，能够为储能电站故障后的人工应急决策提供辅助参考。需要指出的是，本文所构建的大语言模型系统并不直接替代继电保护装置、调度指令或现场运行人员的最终判断，而是作为故障识别后的辅助决策工具。其主要作用是在故障发生后快速整合故障识别结果、仿真分析结论和本地知识库信息，生成结构化的应急处置建议，从而缩短故障分析和策略制定时间，提高储能电站故障应急响应效率。

6 结 论

本研究聚焦于储能电站的建模、故障分析与智能决策，构建了从电芯层级到并网储能电站的完整仿真系统，针对多种故障类型开展了安全分析，并引入人工智能技术实现了故障的智能诊断与应对策略生成。主要结论如下：

1）提出了一种基于实际电站的可扩展电池建模方法，用于构建储能电站模型。通过HPPC实验获取了宁德时代（CATL）生产的314Ah电芯的电流-电压特性。基于实验结果，分析了二阶RC等效电路中各关键参数——电化学极化电阻、浓差极化电阻、电化学极化电容、浓差极化电容、欧姆内阻和开路电压——随SOC的变化规律，并将其拟合为SOC在1至0.1区间内的连续曲线。利用等效电路原理，该方法能够在可接受的误差范围内实现快速的多层级储能单元建模，使大规模储能电站的精确建模成为可能。

2）建立了完整的并网储能电站模型，能够模拟储能电站内部的多种故障类型。在三种典型运行工况（充电、放电和待机）下，对储能电站的不同层级分别施加了短路和开路故障，并利用电网侧的三相电流、三相电压、有功功率和无功功率等关键电能质量指标，分析了储能电站内部故障对电网运行的影响。研究发现：a) 集装箱式升压变流器输出端的三相短路对电网构成严重风险，高压母线电流最大增幅达43.6倍，三相电压降幅达42%。而升压变压器 35 kV 出线端单相接地故障主要表现为局部相对地电压重构，未形成明显短路电流冲击。b) 电池柜内短路对电网存在较大风险，高压母线电流最大增幅达1.19倍；c) 集装箱内部开路故障的影响相对轻微；d) 电池柜内部开路故障的影响极小。

3）提出了一种将CNN-BiLSTM-A深度学习算法与大语言模型（DeepSeek）相集成的智能决策系统。其中，CNN-BiLSTM-A深度学习算法能够对12种高维时序故障数据进行精确分类，准确率达98.4%；基于中国储能电站国家标准，构建了储能电站应急响应策略知识库。一旦深度学习算法识别出故障类型，大语言模型便可结合储能电站知识库，智能生成应急响应策略，从而显著提升故障处理效率。

参考文献

[1] 刘志成, 彭道刚, 赵慧荣, 等. 双碳目标下储能参与电力系统辅助服务发展前景[J]. 储能科学与技术, 2022, 11(2): 704-716.
LIU, Zhicheng, PENG, Daogang, ZHAO, Huirong, et al. Development prospects of energy storage participating in auxiliary services of power systems under the targets of the dual-carbon goal[J]. Energy Storage Science and Technology, 2022, 11 (2): 704-716.

[2] 王守相, 王凯, 赵歌. 平抑有源配电网功率波动的储能配置与控制方法研究综述[J]. 储能科学与技术, 2017, 6(6): 1188-1195.
WANG, Shouxiang, WANG, Kai, ZHAO, Ge. Configuration and control of energy storage system for fluctuation mitigation in an active distribution network——A review[J]. Energy Storage Science and Technology, 2017, 6(6): 1188-1195.

[3] ROUHOLAMINI M, WANG C, NEHRIR H, et al. A review of modeling, management, and applications of grid-connected li-ion battery storage systems[J]. IEEE Transactions On Smart Grid, 2022, 13(6): 4505-4524.

[4] WANG Y, XU Y, TANG Y, et al. Aggregated energy storage for power system frequency control: a finite-time consensus approach[J]. IEEE Transactions On Smart Grid, 2019, 10(4): 3675-3686.

[5] YANG Y, YE Q, TUNG L J, et al. Integrated size and energy management design of battery storage to enhance grid integration of large-scale PV power plants[J]. Ieee Transactions On Industrial Electronics, 2018, 65(1): 394-402.

[6] GANESAN S, SUBRAMANIAM U, GHODKE A A, et al. Investigation on sizing of voltage source for a battery energy storage system in microgrid with renewable energy sources[J]. IEEE Access, 2020, 8: 188861-188874.

[7] 袁帅, 崔煜杰, 程东浩, 等. 2017-2024年全球电化学储能电站火灾爆炸事故统计分析[J]. 储能科学与技术, 2025,(6): 2362-2376.
YUAN, Shuai, CUI, Yujie, CHENG, Donghao, et al. Statistical analysis of fire and explosion accidents in electrochemical energy-storage stations from 2017 to 2024 throughout the world [J]. Energy Storage Science and Technology, 2025, (6): 2362-2376.

[8] XIA X, YUE J, GUO Y, et al. Technologies for energy storage power stations safety operation: battery state evaluation survey and a critical analysis[J]. IEEE Access, 2024, 12: 31334-31356.

[9] MONIRUL I M, QIU L, RUBY R. Accurate SOC estimation of ternary lithium-ion batteries by HPPC test-based extended kalman filter[J]. Journal of Energy Storage, 2024, 92: 112304.

[10] AMIR S, GULZAR M, TARAR M O, et al. Dynamic equivalent circuit model to estimate state-of-health of lithium-ion batteries[J]. IEEE Access, 2022, 10: 18279-18288.

[11] SUN J, KAINZ J. Optimization of hybrid pulse power characterization profile for equivalent circuit model parameter identification of li-ion battery based on taguchi method[J]. Journal of Energy Storage, 2023, 70: 108034.

[12] CAO X, WU Z, XIE X, et al. A fault ride-through method for LVDC

networks with photovoltaic energy storage systems[J]. IEEE Transactions On Sustainable Energy, 2023,: 1-11.

[13] FARAJI H, KHORSANDI A, HOSSEINIAN S H. Multi-level coordinated control of islanded DC microgrid integrated with electric vehicle charging stations with fault ride-through capability [J]. Journal of Cleaner Production, 2023, 420: 138372.

[14] DENG Z, HU X, LIN X, et al. A reduced-order electrochemical model for all-solid-state batteries[J]. IEEE Transactions On Transportation Electrification, 2021, 7(2): 464-473.

[15] LAI X, GAO W, ZHENG Y, et al. A comparative study of global optimization methods for parameter identification of different equivalent circuit models for li-ion batteries[J]. Electrochimica Acta, 2019, 295: 1057-1066.

[16] KIM T, CHO S. Predicting residential energy consumption using CNN-LSTM neural networks[J]. Energy, 2019, 182: 72-81.

[17] XU H, WU L, XIONG S, et al. An improved CNN-LSTM model-based state-of-health estimation approach for lithium-ion batteries [J]. Energy, 2023, 276: 127585.

[18] WAN A, CHANG Q, AL-BUKHAITI K, et al. Short-term power load forecasting for combined heat and power using CNN-LSTM enhanced by attention mechanism[J]. Energy, 2023, 282: 128274.

[19] SHI J, PENG D, PENG Z, et al. Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks[J]. Mechanical Systems and Signal Processing, 2022, 162: 107996.

[20] BOIKO D A, MACKNIGHT R, KLINE B, et al. Autonomous chemical research with large language models[J]. Nature, 2023, 624(7992): 570-578.

[21] ZHOU M, ZHANG J, KO C, et al. Precise prediction of open circuit voltage of lithium ion batteries in a short time period[J]. Journal of Power Sources, 2023, 553: 232295.

[22] TAO S, JIANG B, WEI X, et al. A systematic and comparative study of distinct recurrent neural networks for lithium-ion battery state-of-charge estimation in electric vehicles[J]. Energies, 2023, 16(4): 2008.

[23] ZHANG Y, YU Y, YANG G. Adaptive current differential protection principle for transmission line connected to energy storage power station based on phase and amplitude compensation[J]. Journal of Energy Storage, 2025, 111: 115468.

[24] MAO S, YU Z, ZHANG Z, et al. Parameter identification method for the variable order fractional-order equivalent model of lithium-ion battery[J]. Journal of Energy Storage, 2023, 57: 106273.

[25] LIU Y, ITER D, XU Y, et al. G-eval: NLG evaluation using gpt-4 with better human alignment[C]//. Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing, Singapore: Association for Computational Linguistics, 2023: 2511-2522.

[26] MIN S, KRISHNA K, LYU X, et al. FActScore: fine-grained atomic evaluation of factual precision in long form text generation[C]//. Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing, Singapore: Association for Computational Linguistics, 2023: 12076-12100.

[27] KIM S, SHIN J, CHO Y, et al. Prometheus: inducing fine-grained evaluation capability in language models[C]//. The Twelfth International Conference on Learning Representations, Vienna, Austria: International Conference on Learning Representations, 2024.