

基于多模态特征融合的电网故障 知识库构建技术研究

谢才科¹ 肖孝天¹ 黄元行¹ 杜雪雪² 安 赛¹ 彭诗航¹

(1. 贵州电网有限责任公司贵安供电局 2. 贵州电网有限责任公司都匀供电局)

摘要：本文以配网故障处置预案文本和故障元件现场图像为研究对象，利用 ALBERT-BiLSTM-CRF 模型抽取文本实体、ALBERT-BiLSTM-Attention 模型抽取文本实体之间的关系，构建了电网故障文本知识图谱；利用 YOLOv8 模型得到带有故障标签的识别图像，并将文本知识图谱与故障图像进行配对连接，构建了面向电网故障数据的多模态知识图谱；最后利用 InteractiveGraph 工具进行知识存储与可视化展示。在性能对比实例验证中，上述三个模型在准确率、精准率、召回率、 F_1 值等方面均取得最优表现。

关键词：电网故障；多模态；知识图谱；神经网络

0 引言

随着社会用电量的不断提高，电力设备规模的持续增加，新能源电力系统的不断升级，电网故障变得日益复杂，对调度人员的故障处置效率提出更高要求。在电力系统故障处置过程中，调度人员通常需要依赖自身知识储备做出故障处置决策，但当前以人工经验分析为主的故障处置方式存在响应速度慢、处置准确性差、工作效率低等问题。针对电网设备运维工作高度依赖人工经验，大量多源异构数据难以挖掘利用，故障处置智能化水平较低等问题，基于知识图谱的电网故障知识库构建技术将调度领域的专家经验、故障处置预案转化为专业知识，为电网故障处置工作提供了实时辅助决策支撑，有效提高了故障处置效率

和智能化水平^[1]。

知识图谱是由 Google 公司于 2012 年提出，它是由实体、关系和相应属性构成的三元组。近年来，知识图谱在电力故障处理领域取得了较多的研究进展。文献 [2] 利用知识图谱技术将配网故障数据建立三元组，使用 Neo4j 图数据库技术将配网数据形成的三元组进行存储和可视化展示，辅助调度故障处置决策。文献 [3] 构建了电力设备缺陷领域的知识图谱，基于知识图谱构建了问答系统，可有效提高消除电力设备缺陷的效率。信息提取作为构建知识图谱的基础，实体抽取和关系抽取是信息抽取最重要的两个子任务。实体抽取可视为序列标注任务，通过事先制定的规则对输入语句进行模式匹配；关系抽取是获取多个

基金项目：中国南方电网一般科技项目（GZKJXM20210413）；贵州省科技支撑项目（黔科合支撑 [2023] 一般 345）。

实体之前存在的复杂相互关系^[4]。文献 [5] 构建基于 BiLSTM-CNN-CRF 的电网调度领域实体识别模型，取得了较高的识别准确率。

目前电网故障知识库知识通常来源于故障案例文本数据，而缺少视频、图像、音频等其他格式来源的故障信息。多模态知识图谱是在以文本为实体的传统知识图谱基础上增加了多种模态实体数据与不同模态实体数据之间的语义关系，具有更加丰富的知识。文献 [6] 使用 BiLSTM-CRF 模型提取文本实体和 YOLOv5 算法检测得到带有缺陷标签的图像，并结合电力文本数据与图像数据构建了面向电力设备缺陷数据的多模态知识图谱，最后利用 InteractiveGraph 图数据库存储抽取知识。

综上所述，本文通过融合文本知识图谱和故障识别检测图像，构建了面向电网故障数据的多模态知识图谱，有效解决了人工处置电网故障智能化低、准确性差等问题，并从准确率等方面对知识抽取结果、故障图像检测结果进行性能实例验证。

1 电网故障数据

1.1 电力故障处置预案文本

电网故障处置预案是基于调度经验制定的结构化或半结构化故障措施记录文本，记录了电网设备信息、重要故障设备处置预案等内容。预案文本数据结构复杂多样，其中包含故障名称、故障处置要点等非结构化数据。电网故障处置预案隶属于调度域，实体词具有很强的业务属性，本文需在充分考虑业务文本专业特点的前提下，制定预案实体类别及实体间关系定义。

1.2 故障现场图片

本文采集包含变压器、绝缘子在内的电力设备现场图像，包含正常设备图像和故障设备图像。由于现场实际采集图像数量较少，本文采用随机裁剪、旋转

等数据清洗方式，生成大量的虚拟图像数据，构建了图像数量充足的样本数据集。文本使用 LabelImg 标注软件对电力设备缺陷图形进行标注，得到包含目标位置边框和标签的 XML 格式数据文件。

2 多模态知识图谱构建

本文以电网故障处置预案和故障现场图像为研究数据，利用 ALBERT-BiLSTM-CRF 算法抽取文本实体、ALBERT-BiLSTM-Attention 算法抽取文本实体之间的关系，构建电力故障文本知识图谱；利用 YOLOv8 算法得到带有故障标签的识别图像，并将文本知识图谱与故障图像进行配对连接，构建面向电网故障数据的多模态知识图谱；最后利用 InteractiveGraph 工具进行知识存储。多模态知识图谱构建整体框架如图 1 所示。

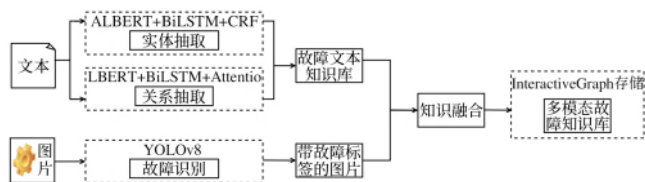


图 1 多模态知识图谱构建框架

2.1 基于 ALBERT+BiLSTM+CRF 的电网故障实体抽取

BERT 模型^[7]是在 2018 年由谷歌首次提出，它采用 Transformer 双向编码器和自监督学习架构，具有优秀的上下文语义表征能力。ALBERT 采用参数分解和跨层共享的方式，有效降低参数的维数灾，有效简化 BERT 模型以明显提高模型训练速度。

本文采用 ALBERT+BiLSTM+CRF 模型进行电网故障实体抽取，模型结构如图 2 所示。将配网原始文本输入数据通过输入层后，将其变为字序列数据 $w=(w_1, w_2, \dots, w_n)$ ，经过 ALBERT 层后被转换成向量序列 X ，如式 (1) 所示：

$$\begin{cases} X = [x_1, x_2, \dots, x_n] \in R^{n \times H} \\ x_i = E_i^t + E_i^p + E_i^s, i=1,2,\dots,n \end{cases} \quad (1)$$

式中， H 为向量维度； E_i^t 、 E_i^p 、 E_i^s 分别为对字序列的嵌入编码、位置信息编码和语句信息编码，将三者编码映射高维度的 ALBERT 层得到输入向量 X ，将其发送至多层 Transformer 得到含有多层语义的特征向量 T 。BiLSTM 模型利用双向流动的信息，可从正反方向提出输入序列的隐藏状态 $\overleftarrow{h}_1, \overleftarrow{h}_2, \dots, \overleftarrow{h}_n$ 和 $\overrightarrow{h}_1, \overrightarrow{h}_2, \dots, \overrightarrow{h}_n$ 。特征向量 T 输入到 BiLSTM 层获取基于上下文信息的语义特征，并将语义特征向量输入至 CRF 层，得到最优的实体标签，完成对文本实体抽取。

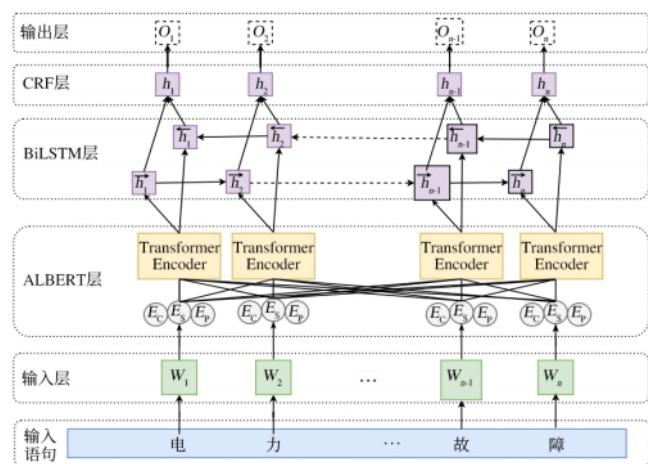


图2 ALBERT+BiLSTM+CRF 模型

本文采用 BIO 标注标准策略，实体标注以“B”、“I”、“O”开头，当预测的实体头部、中间和尾部全部正确后，才能判断该预测的实体标签正确。本文待预测的六类标签如表 1 所示。

表 1 电网故障待预测实体标签

编号	实体类型	开始标签	中间或结尾标签
1	变电站	B-变电站	I-变电站
2	设备	B-设备	I-设备
3	线路	B-线路	I-线路
4	故障	B-故障	I-故障
5	变压器	B-变压器	I-变压器
6	绝缘子	B-绝缘子	I-绝缘子

2.2 基于 ALBERT+BiLSTM+Attention 的电网故障实体抽取

本文同样采用 ALBERT 模型提取实体间关系。为进一步减少无关信息对模型提取结果的影响，本文在 ALBERT+BiLSTM 的基础上，使用注意力机制赋予关键特征信息更大的权重。本文使用 ALBERT+BiLSTM+Attention 模型进行电网故障实体关系抽取，模型结构如图 3 所示。注意力机制 Attention 分数由式 (2) 计算。BiLSTM 层获取的上下文语义特征经过 Attention 层按照重要程度进行权重计算，更为有效地抽取关键信息，即：

$$\text{Attention} = \text{Soft max} \left(\frac{QK^T}{\sqrt{d_k}} \right) \cdot V \quad (2)$$

式中， Q 为查询向量矩阵； K 为位置键向量矩阵； V 为值向量矩阵。

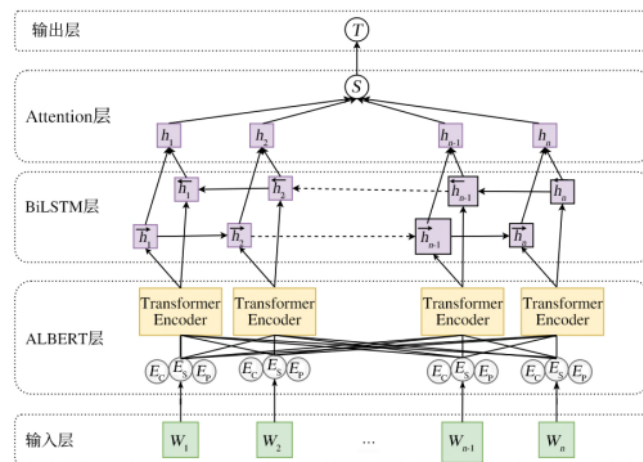


图3 ALBERT+BiLSTM+Attention 模型

本文定义的实体间关系标签的类别如表 2 所示。

表 2 电网故障实体间关系标签的类别

编号	实体 A 标签类别	实体 B 标签类别	关系标签
1	线路	变电站	属于
2	设备	变电站	属于
3	变压器	设备	属于
4	绝缘子	线路	属于
5	线路	故障	发生
6	设备	故障	发生

2.3 基于YOLOv8的故障图像检测模型

本文利用YOLOv8从现场采集的设备图像中识别定位设备故障种类，并结合电力文本知识图谱，构建了面向电网故障的多模态知识图谱。YOLOv8是由Ultralytics公司提出的一项目标检测领域突破性算法，在速度和准确性方面都取得了显著进步，其

基本结构如图4所示。YOLOv8通过卷积神经网络（CNN）和目标检测算法可快速准确地从图像中提取特征并预测对象的位置和种类。YOLOv8网络包含骨干网BackBone，颈部结构Neck和头部结构Head，并用c2f模块取代了YOLOv5模型的C3模块。

YOLOv8的损失计算分为分类损失和回归损失。

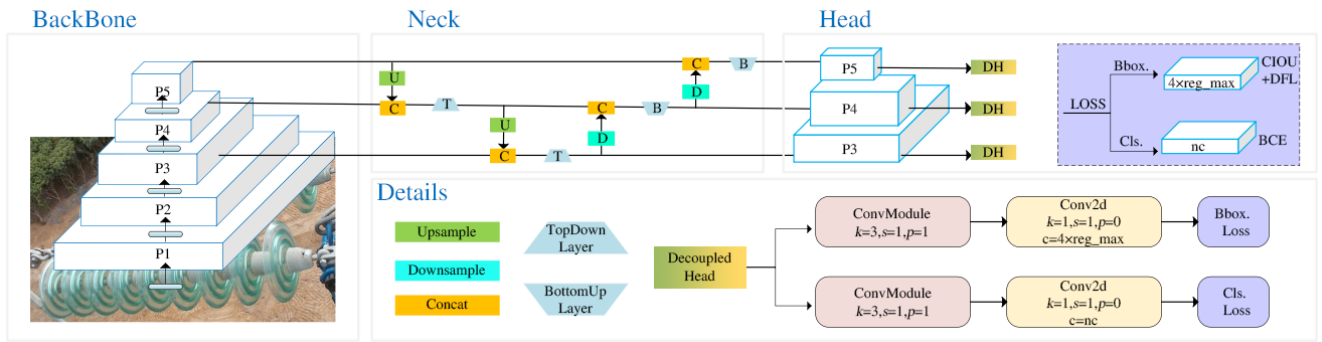


图4 YOLOv8 框架图

分类损失 Cls. Loss 采用交叉熵损失函数计算，如式(3)所示：

$$L = \frac{1}{N} \sum_i L_i = -\frac{1}{N} \sum_i \sum_{c=1}^M y_{ic} \frac{dy}{dx} \log(p_{ic}) \quad (3)$$

式中，N为类别数量；y_{ic}为符号函数；p_{ic}为观测样本i属于c的预测概率。

YOLOv8的回归损失采用CIOU+DFL方法计算，CIOU是预测目标框左、上、右、下边框距目标中心的距离。DFL计算方法如式(4)所示：

$$DFL(S_i, S_{i+1}) = -((y_{i+1} - y)) \log(S_i) + (y - y_i) \log(S_{i+1}) \quad (4)$$

式中，S_i为网络的sigmoid输出；y_i和y_{i+1}为检测图上区间顺序；y为标签值。

本文定义的电力设备故障种类如表3所示。

编号	设备	故障
1	变压器	正常
2	变压器	故障
3	绝缘子	正常
4	绝缘子	故障

2.4 多模态知识图谱

本文利用文本和图像两种模态数据，对文本知识图谱和检测后的电力故障图像通过标签进行融合匹配链接，并使用InteractiveGraph工具构建融合文本知识和图像信息等多元异构数据的多模态知识图谱。与常用的Neo4j图数据库相比，InteractiveGraph可存储图像等其他模态信息^[8]。多模态知识图谱架构如图5所示。

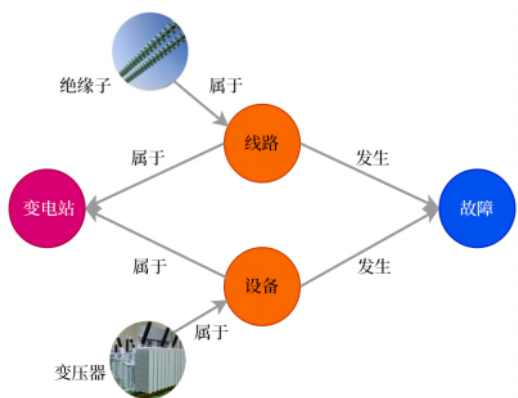


图5 多模态知识图谱框架图

3 实例分析

3.1 实例数据和评价指标

本文通过性能对比实例计算以验证实体抽取、关系抽取、故障图像检测等方法的性能质量。本文以某地区 300 份电网故障处置预案中的 1200 条故障处置语句作为文本知识图谱构建数据集；600 张现场故障图像作为原始数据集，经过随机旋转，裁剪，亮度变化的组合数据增强方法，获得 2000 张增强数据集。文本数据集和图像数据集分别以 80% 作为训练集，10% 作为验证集，剩余的 10% 作为测试集进行对模型的训练。

本文利用 Accuracy（准确率）、Precision（精准率）、Recall（召回率）、 F_1 值等评价指标来评估模型的性能。计算四个指标需要用到混淆矩阵，如表 4 所示。

表 4 混淆矩阵

	真实类别为正	真实类别为负
预测类别为正	TP	FP
预测类别为负	FN	TN

四个评价指标由式（5）~ 式（8）所示：

$$A = \frac{TP + TN}{TP + FP + FN + TN} \quad (5)$$

$$P = \frac{TP}{TP + FP} \quad (6)$$

$$R = \frac{TP}{TP + FN} \quad (7)$$

$$F_1 = \frac{2PR}{P + R} \quad (8)$$

式中， P 、 R 分别为精准率和召回率。

3.2 电网故障文本实体识别实例分析

为了验证本文采用的 ALBERT-BiLSTM-CRF 方法的故障文本实体抽取的有效性，选择 BiLSTM-CRF 模型、LSTM-CRF 作为对比模型。其中，本文算法模型设置参数如表 5 所示。

表 5 电网故障文本实体识别算法参数设置

编号	算法模型参数	模型参数取值
1	Transformer 层数	8
2	LSTM 隐藏层维度	768
3	LSTM 学习率	1×10^{-5}
4	LSTM 维度	200
5	批大小	32
6	最大序列长度	128
7	CRF 学习率	1×10^{-2}
8	LSTM 丢弃率	0.25

3.2.1 故障文本实体识别结果与分析

为了客观评价本文所用方法的有效性，本文使用 BiLSTM-CRF 模型、LSTM-CRF 模型进行对比验证，电网故障文本识别结果如表 6 所示。

表 6 电网故障文本知识实体识别结果 (%)

模型	准确率	精准率	召回率	F_1 值
LSTM-CRF	75.83	85.88	81.11	83.33
BiLSTM-CRF	83.33	89.77	87.78	88.70
ALBERT-BiLSTM-CRF	90.83	95.40	92.22	94.03

由表 6 中的评价指标结果数值可知，ALBERT-BiLSTM-CRF 模型在三个模型中表现最好，与各个指标次优数值相比，准确率提升了 7.5%，精准率提升了 5.63%，召回率提升了 4.44%， F_1 数值提升了 5.33%。实例结果表明：本文所用的 ALBERT-BiLSTM-CRF 模型可以更有效地提取上下文语义信息，具有优秀的电网故障文本实体识别能力。

3.2.2 故障文本实体间关系识别结果与分析

为了减少无关信息对实体间关系提取结果的干扰，本文在实体识别模型的基础上融合了 Attention 注意力机制，为关键信息赋予更高的权重，有效提升了模型的性能。本文所用的 ALBERT-BiLSTM-Attention 实体间关系识别模型的参数设置与表 5 中相应的参数值相同。为了客观验证该模型的有效性，本文使用 BiLSTM-Attention 模型、LSTM-Attention 进行对比验证，电网故障文本实体间关系识别结果如表 7 所示。

表 7 电网故障文本实体间关系识别结果 (%)

模型	准确率	精准率	召回率	F_1 值
LSTM-Attention	73.33	86.96	80.00	83.34
BiLSTM-Attention	78.33	90.22	83.00	86.52
ALBERT-BiLSTM-Attention	86.67	93.75	90.00	91.67

由表 7 中的评价指标结果数值可知，ALBERT-BiLSTM-Attention 模型在三个模型中表现最好，与各个指标次优数值相比，准确率提升了 8.34%，精准率提升了 3.53%，召回率提升了 7.0%， F_1 值提升了 5.15%。实验表明：本文所用的 ALBERT-BiLSTM-Attention 可有效抵抗无关信息的干扰，提取更多的关键信息，在电网故障文本实体间关系提取领域具有优秀表现。

3.3 故障图像识别结果分析

为客观验证 YOLOv8 模型故障识别效果，本文使用 YOLOv5 模型、Faster R-CNN 模型作对比验证，三个模型在训练集上的损失值如图 6 所示，YOLOv8 的设置参数如表 8 所示；各个模型的故障识别准确率、精准率、召回率和 F_1 值如表 9 所示。

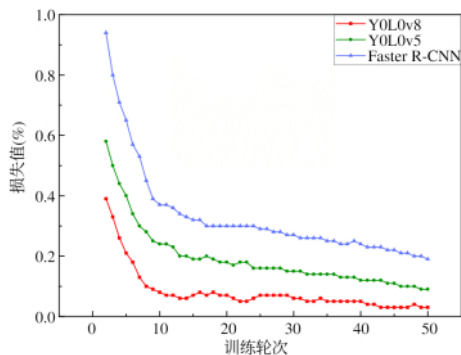


图 6 各个模型在训练集上损失值

从图 6 中的损失曲线可以看出，YOLOv8 损失下降得最快，损失值最小，结果表明在三个模型中 YOLOv8 的故障识别检测表现最优。从表 9 中的评价指标结果可知，YOLOv8 的四个评价指标均取得最优结果，相比次优指标结果，YOLOv8 的准确率提升了

5.0%，精准率提升了 3.78%，召回率提升了 2.5%， F_1 值提升了 2.9%。

表 8 YOLOv8 模型参数表

参数名称	数值
优化器	SGD
学习率	0.01
权重衰减	0.0005
优化器动量	0.937
批次大小	128
学习器调度	Linear
训练轮次	500

表 9 电网故障测试集图像识别结果 (%)

模型	准确率	精准率	召回率	F_1 值
Faster R-CNN	87.5	93.55	90.63	92.0
YOLOv5	91.0	94.94	93.75	94.2
YOLOv8	96.0	98.72	96.25	97.1

4 结束语

本文基于电网故障处置预案文本和现场故障图像数据，构建了面向电网故障数据的多模态知识图谱，主要结论如下：

1) 本文基于电网故障处置预案文本数据，采用 ALBERT-BiLSTM-CRF 模型提取文本知识实体，ALBERT-BiLSTM-Attention 模型提取文本实体间关系，构建了面向电网故障文本数据的知识图谱。在性能对比实例验证中，通过准确率、精准率、召回率和 F_1 值等四个评价指标验证两种模型均取得较好的性能。

2) 本文采用 YOLOv8 模型实现了现场图像中故障种类的快速识别检测，与 Faster R-CNN 模型和 YOLOv5 模型相比，YOLOv8 模型取得最好的性能表现。本文通过融合文本知识图谱和检测后带故障标签的图像，构建了包含配网故障处置预案和现场故障元件图像的多模态知识图谱，并在 InteractiveGraph 工具中进行存储与管理。

(下转第 57 页)

参考文献

- [1] 张锐, 刘剑青, 张伯远, 等. 基于迁移学习的电网故障处置知识图谱构建及实时辅助决策研究 [J]. 电力信息与通信技术, 2022, 20 (6): 24-34.
- [2] 叶欣智, 尚磊, 董旭柱, 等. 面向配电网故障处置的知识图谱研究与应用 [J]. 电网技术, 2022, 46 (10): 3739-3749.
- [3] 陈鹏, 邵彬, 石英, 等. 基于知识图谱的电力设备缺陷问答系统研究 [J]. 广西师范大学学报 (自然科学版), 2024, 42 (6): 149-163.
- [4] 张西硕, 柳林, 王海龙, 等. 知识图谱中实体关系抽取方法研究 [J]. 计算机科学与探索, 2024, 18 (3): 574-596.
- [5] 徐会芳, 张中浩, 谈元鹏, 等. 面向电网调度领域的实体识别技术 [J]. 电力建设, 2021, 42 (10): 71-77.
- [6] 姚奕, 陈朝阳, 杜晓明, 等. 多模态知识图谱构建技术及其在军事领域的应用综述 [J]. 计算机工程与应用, 2024, 60 (22): 18-37.
- [7] Devlin J. Bert: Pre-training of deep bidirectional transformers for language understanding [J]. arXiv preprint arXiv: 1810.04805, 2018.
- [8] 丁剑涛. 面向电力设备缺陷数据的多模态知识图谱研究 [D]. 西安: 长安大学, 2022.

(收稿日期: 2024-09-06)