

基于 BERT-BiGRU-CRF 的配电网故障 辅助决策的知识图谱研究及应用

宋 达¹ 袁 龙¹ 肖孝天¹ 杜雪雪² 尚晓霞¹ 杨子晗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：随着电网信息化建设水平的不断提升，电网领域存在着大量的半结构化或非结构化的文本数据，但多源异构的电力数据无法直接应用到基于深度学习的模型参数训练，且人工标注电力文本数据的成本较高。为深度挖掘电网领域文本数据，满足高效响应的业务需求。首先，本文提出了基于 BERT-BiGRU-CRF 的深度学习模型，对配电网故障文本数据进行知识抽取，可有效解决电力领域小样本数据实体识别效果差的问题。其次，建立配电网故障调度处置的知识图谱，将多源异构的电力领域的的数据转化为知识；再次，设计实验证明本文所提配电网故障处置辅助决策功能的有效性，模型的准确率达到 96.15%， F_1 值达到 98.04%；最后，利用 Neo4j 图数据库可视化展示建立的知识图谱，并在配电网故障处置调度辅助决策中的应用进行分析。

关键词：配网故障调度处置；知识图谱；深度学习；知识抽取

2025.04.DQGY
23

0 引言

随着电力系统物理信息的深度融合和新能源的快速发展，电网领域数据呈现出多源异构等特征，配电网故障类型日益复杂，目前配电网发生故障后主要依赖调度人员的主观工作经验进行决策^[1]。电网发生故障时，调度人员需要大量查阅故障处置预案、调度规程、历史故障记录、设备缺陷台账记录等半 / 非结构化文本数据，这种故障处置方式不仅时间成本较高，而且查找结果碎片化，易丢失重要信息，导致故障处置执行效率低下^[2]，并且调度人员故障处置经验无法传承，为解决当前面临的问题，亟需使用人工智能技术将结构复杂的异构配网故障处置数据转化为知识，

为调度人员提供高效、快速的故障处置的关键信息，给出相应的故障处置辅助决策方案。

知识图谱 (Knowledge Graph) 是以三元组的形式可视化展示的语义网络，借助人工智能技术将非结构化的知识进行结构化表示，具备可解释性的特点^[3]。在电网领域，知识图谱的优势主要在以下三个方面进行展现，首先将配网设备、调度规程、故障预案等多源数据进行规范化表征；其次，利用自然语言处理技术，将非结构化的调度规程等文本数据，融合至知识图谱中，为配网故障辅助决策提供支持；最后，将配网故障处置知识图谱和人工智能等技术进行深度融合，解决配网故障调度辅助决策分析，提升配网运行

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)。

的可靠性^[4]。

近年来,国内外学者在电网领域的知识图谱的应用进行深度的研究。文献[5]提出了配网故障调度处置决策的知识图谱框架,从五个方面对配网故障知识图谱进行建立。文献[6]采用TextCNN技术对故障预案文本进行自动分类,提出LR-CNN和BiGRU-Attention模型,实现电网故障预案的实体命名识别和关系抽取,从而构建基于电网故障预案的知识图谱。文献[7]针对电力调度领域的文本数据,提出了BiLSTM-CNN-CRF的调度文本实体识别模型,支持电力调度知识图谱的构建。文献[8]本文介绍了一种运用迁移学习模型的电网故障处理文本数据实体识别方法。此方法能够在小样本标注数据的情况下,实现较高的实体识别精度。

综上所述,基于风险预案、配网设备缺陷等文本数据的体量小且人工标注成本高,致使传统实体识别模型效果差。本文以调度风险预案、配网设备拓扑、配网缺陷库、配网故障处置数据和调度规程文本数据为研究对象;设计了一种本体层与数据层相结合的配网故障知识图谱建立方法;采用BERT-BiGRU-CRF实体识别模型,以实现配网文本数据实体的抽取任务;最后利用Neo4j图数据库对抽取的知识进行存储,并进行可视化展示,以此实现配网故障处置的辅助决策应用方案。

1 配网故障处置知识图谱的构建方案

目前主要有三种方法构建电网特定领域的知识图谱:自顶向下的方法、自底向上的方法以及两者相结合的混合方法^[9]。本文采用自顶向下构建模式层,自底向上构建数据层,进而两者相结合构建配网故障知识图谱,首先根据配网不同类型的文本数据,得到对应的本体及关系,构建知识图谱的模式层;然后在模式层主体类型的指导下,从配网异构数据中抽取相应

实体,从而构建知识图谱的数据层,其配网故障处置知识图谱的构建流程如图1所示。




图1 配网故障处置知识图谱的构建流程

本文选用调度风险预案、配网设备拓扑、配网缺陷库、配网历史故障处置记录和调度规程为研究对象,建立配网故障调度处置知识图谱框架。其中配网故障处置和配网缺陷数据通过属性链接到配网设备拓扑知识图谱。

知识图谱框架构建主要由以下步骤构成:

1) 模式层构建:通过对配网各类数据进行本体、关系和相应属性的抽取,形成对应的本体规则,用于配网故障处置知识图谱的本体层。

2) 数据层构建:主要由知识抽取、融合及更新等三部分组成。其中,知识抽取是在模式层主体类型的指导下,利用实体和关系抽取方法,从异构的数据中获取结构化的知识;知识融合是指构建完成知识图谱后,由于知识抽取的数据质量和多源异构问题,抽取的信息可能会出现错误或者冗余,影响知识图谱构建的质量,因此需要通过实体消歧、实体对齐对构建的知识图谱进行融合,以此来扩充知识图谱的内容量;知识更新是指在日常配网数据运维过程中,若发现存在新的配网知识或者在使用过程中发现图谱有内容缺失、错误等问题,则需要及时对构建的知识图谱进行知识更新,以提高知识图谱的质量。典型的配网故障处置知识图谱如图2所示。




图2 典型配网故障处置知识图谱

2 基于 BERT-BiGRU-CRF 模型的知识抽取

知识抽取是从配网非结构化的文本数据中，通过实体识别模型抽取出相应的命名实体及关系。

BERT 模型是基于双向 Transformer 架构的预训练模型，它是由 Google 公司于 2018 年提出的，可以同时考虑左右两侧的上下文信息，突破了传统 GRU 算法文本长度受限的瓶颈，可以深度捕捉丰富的上下文语义信息。本文所构建的 BERT-BiGRU-CRF 模型的网络架构图如图 3 所示，其中图 3 中 w_i 表示为词序列。




图3 BERT-BiGRU-CRF 模型的网络架构图

此外，BERT 通过掩码语言模型（Masked Language Model, MLM）和下一句预测（Next Sentence Prediction, NSP）功能来优化模型的参数。针对特定领域场景，BERT 通过微调（Fine-tuning）的形式，在通用预训练模型的基础上，针对特定任务进行训练和优化，以提高模型的泛化能力。由图 3 可知，采用已预训练的 BERT 模型，通过 BiGRU 模型的上下文语义特征的提取，将 BERT 层与 BiGRU 层输出的向量序列进行拼接，针对特定的场景，对预训练的 BERT 模型进行微调训练，可以实现使用较少的标注训练数据，得到较好的模型效果。

(1) BERT 层

将输入的配网文本数据进行分词，通过 Embedding 层将词序列 $w=[w_1,w_2,...,w_n]$ 转化为模型可以计算的向量序列 X ：

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

式中， H 为向量的维度，在 BERT 模型中设定维度为 768； E_i^t 为对词序列进行词嵌入编码； E_i^p 为对词序列进行位置信息的编码； E_i^s 为对词序列语句信

息的编码，通过以上 3 个编码信息的叠加融合，可得到输入向量 x_i 。在预训练的 BERT 模型输入 X ，得到 BERT 模型的输出向量序列 $S=[s_1,s_2,\dots,s_n]$ 。

(2) BiGRU 层

双向门控循环单元（Bidirectional Gated Recurrent Unit, BiGRU）是一种改进的循环神经网络，通过引入门控机制可改善长序列数据依赖和梯度消失的问题。BiGRU 结合双向循环神经网络和 GRU 的优点，可以同时捕捉输入序列的上下文信息，提高模型的性能。

本文中，将 BERT 层输出的向量序列，输入到 BiGRU 层，生成包含上下文信息的向量序列 $O=[o_1,o_2,\dots,o_n]$ 。

(3) Concatenate 特征拼接层

将 BERT 层输出的向量序列 S 与 BiGRU 模型输出的向量序列 O 进行拼接操作，可得到更为丰富的文本语义特征向量序列，输出的向量序列经过全连接层和 Softmax 归一化，得到每个词对应的每个实体标签的得分向量序列 P 。

(4) CRF 层

条件随机场（Conditional Random Field, CRF）^[10] 常应用于执行多种序列标注任务。

在 BiGRU 模型后加入 CRF 层，可以为模型识别类型的预测结果添加约束，从而提高本文所构建实体识别模型的准确性，输出最优的实体标签。

3 算例分析

3.1 算例情况

为验证本文所构建 BERT-BiGRU-CRF 模型的有效性，选取某地 320 份配网历史故障记录为研究对象，选取历史故障记录中的“故障配网设备”和“故障处置过程”共计 640 条数据，经过分词标注后得到 3260 条文本数据，用于本文所构建模型的文本数据集。选择数据集的 80% 作为训练集，10% 作为验证集，剩余

的 10% 作为测试集对实体识别模型进行训练。

3.2 模型评估

本文采用通用的模型评估方法，对所构建的 BERT-BiGRU-CRF 模型进行评估，其中模型的评价指标分别为精确率（ P ）、召回率（ R ）和 F_1 值，评价指标的具体公式如下所示：

$$P = \frac{T_p}{(T_p + F_p)} \quad (2)$$

$$R = \frac{T_p}{T_p + F_N} \quad (3)$$

$$F_1 = 2 \frac{PR}{P + R} \quad (4)$$

式中， T_p 、 T_N 、 F_p 和 F_N 分别为混淆矩阵中的评价元素，其中 T_p 为示真正例， T_N 为真负例， F_p 为假正例， F_N 为假负例。

本文构建的 BERT-BiGRU-CRF 模型的参数设置如表 1 所示。

表 1 BERT-BiGRU-CRF 模型参数

编号	算法模型参数	模型参数取值
1	Transformer 层数	8
2	GRU 隐藏层维度	768
3	GRU 学习率	3×10^{-5}
4	GRU 维度	200
5	批大小	32
6	最大序列长度	128
7	CRF 学习率	2×10^{-2}
8	GRU 丢弃率	0.5
9	优化器	Adam

3.3 实验结果分析

实验环境为 CPU（Intel Core i7-13650HX 2.60GHz），GPU（NVIDIA GeForce RTX4060）、编程环境为 Python3.9，基于 Python 的 jieba 分词工具包、TensorFlow2.0 的操作平台。模型效果的评价指标选用 P 、 R 和 F_1 值，其中 F_1 值被用作衡量本文所构建实体识别模型整体性能的综合指标，反映了模型在实体识别任务中的表现。

为了验证本文所构建的 BERT-BiGRU-CRF 模型实体识别的有效性, 选取 BiGRU-CRF 模型作为对比, 实验结果分别见表 2 和图 4 所示。

表 2 实体识别模型结果对比 (%)

模型	精确率 P	召回率 R	F_1 值
BiGRU-CRF	92.66	95.73	94.17
BERT-BiGRU-CRF	96.15	99.40	98.04




图 4 实体识别模型训练曲线图

由实验结果可知, 相较于对比模型 BiGRU-

CRF, 本文所构建 BERT-BiGRU-CRF 模型的精确率提高了 3.49%, F_1 值为 3.87%。这是由于 BERT 预训练模型不仅可以提取复杂的上下文特征向量, 还可以获取句子层面的语义特征, 通过上下文词语和句子间的语义关系, 可动态生成词向量, 从而有效解决配网故障处置文本中一词多义的问题。此外, 采用 BERT 预训练模型, 可有效解决配网故障数据不足的问题, 因此本文所构建模型的效果较好。

4 配网故障处置知识图谱的可视化与应用

本文选用某地区配网相关数据, 在本文所提出的知识图谱框架的指导下, 对配电网数据进行知识抽取, 共形成 5400 个配网领域实体和 3200 个命名实体间的关系, 根据识别关系的主体和客体进行链接, 即可形成配网故障三元组, 利用 Neo4j 图数据库对三元组进行存储和可视化表示。图 5 是部分构建的知识图谱可视化展示, 以配网设备拓扑知识图谱为主体, 其他类型配网数据通过设备映射到主体部分。




图 5 配网故障处置知识图谱 (部分)

当配网发生永久性单一故障时，首先由 SCADA 系统将故障信息上送至配网运行支持系统，利用本文构建的 BERT-BiGRU-CRF 模型对故障信息进行语义解析和实体识别，然后利用 Neo4j 图数据库中的查询语句，在构建的故障处置知识图谱中查询是否存在相同的故障类型；若存在，则返回与故障类型相应的故障处置要点和历史故障处置措施信息；若不存在，则由调度人员分析配网故障类型，查询知识图谱后返回相似的故障处置要点和历史故障记录信息。

5 结束语

本文基于配网多源异构文本语料，提出基于 BERT-BiGRU-CRF 的配电网故障处置知识图谱的构建方法，主要结论如下：

1) 针对配网故障异构文本数据体量小，实体识别模型效果差的问题，本文构建 BERT-BiGRU-CRF 的实体识别模型，利用 BERT 预训练的方法，在配网故障处置的场景下，能够有效解决配网故障文本数据体量小的问题；此外，将 BERT 层与 BiGRU 层输出的向量进行串联融合，可最大程度地从上下文中捕获配网故障文本数据的复杂特征，有效提高模型的性能。

2) 利用配网调度风险预案、配网设备拓扑、配网缺陷库、配网故障处置数据和调度规程等配网文本数据，利用构建的实体识别模型进行知识抽取，将其转化为三元组的形式，利用 Neo4j 图数据库对其构建的配网故障处置知识图谱进行可视化和应用分析，实现配网故障知识图谱辅助决策的功能。

参考文献

[1] 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.

[2] 刘丽，闫晓梅，李刚. 配电网故障处置中的知识图谱：进展、挑战与展望 [J]. 电力信息与通信技术，2023, 21 (7): 19-26.

[3] SINGHAL A. Introducing the knowledge graph: things, not strings[J]. Official Google Blog, 2012.

[4] 王骏东，杨军，裴洋舟，等. 基于知识图谱的配电网故障辅助决策研究 [J]. 电网技术，2021, 45 (6): 2101-2112.

[5] 乔骥，王新迎，闵睿，等. 面向电网调度故障处理的知识图谱框架与关键技术初探 [J]. 中国电机工程学报，2020, 40 (18): 5837-5849.

[6] 郭榕，杨群，刘绍翰，等. 电网故障处置知识图谱构建研究与应用 [J]. 电网技术，2021, 45 (6): 2092-2100.

[7] 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.

[8] 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.

[9] 宋亚奇，周国亮，朱永利. 智能电网大数据处理技术现状与挑战 [J]. 电网技术，2013, 37(4): 927-935.

[10] 谢庆，蔡扬，谢军，等. 基于 ALBERT 的电力变压器运维知识图谱构建方法与应用研究 [J]. 电工技术学报，2023, 38 (1): 95-106.

[11] 孔令巍. 知识抽取技术及知识图谱构建研究 [D]. 株洲：湖南工业大学，2023.

(收稿日期：2024-09-04)