

DOI:10.11784/tdxbz202506032

面向智能楼宇运维知识图谱构建的事件联合抽取方法

景涛¹, 杨挺², 宋金钊³, 张颖媛⁴, 王天昊³

(1. 天津大学未来技术学院, 天津 300072; 2. 天津大学电气自动化与信息工程学院, 天津 300072;
3. 国网天津市电力公司电力科学研究院, 天津 300384; 4. 国电南瑞科技股份有限公司, 南京 211106)

摘要: 楼宇作为电力系统最末端用能单元, 在突发运维事件发生时, 高效的故障诊断与检修工作直接关系到供电连续性与用户用电体验。知识图谱能够高效抽取楼宇运行过程中的非结构化数据实体及其关联属性, 为故障诊断与智能运维提供有力支持。但传统抽取方法在多触发词与论元关联多事件的场景下抽取完整率低, 难以有效支撑楼宇运维知识图谱构建。对此, 提出一种面向楼宇运维知识图谱构建的事件联合抽取方法。首先, 研究基于点互信息与左右熵的自适应阈值分词算法, 精确切分运维领域文本字词; 其次, 定义楼宇运维知识图谱多元关系统一表达范式, 应对同一论元具备多重角色的问题; 然后, 训练领域专属的大语言模型——LouYSpanBERT, 构建触发词边界标记驱动的楼宇运维事件联合抽取框架, 通过“触发词检测-边界标记-论元抽取”三级联合抽取提高事件抽取精度; 最后, 以某园区运维数据做实例分析, 与 4 个已有模型比较, 所提方法执行典型的论元分类 AC 任务时, F1 值有效提升了 5.08%、9.81%、13.36%、14.99%, 并且本文将抽取结果通过 Neo4j 实现楼宇运维知识图谱可视化展示。

关键词: 事件联合抽取; 知识图谱; 分词算法; 触发词边界; 论元分类

中图分类号: TM64 文献标志码: A 文章编号: 0493-2137(2026)05-0507-13

Event Joint Extraction Method for the Construction of Intelligent Building Operation and Maintenance Knowledge Graphs

Jing Tao¹, Yang Ting², Song Jinzhao³, Zhang Yingyuan⁴, Wang Tianhao³

(1. School of Future Technology, Tianjin University, Tianjin 300072, China;
2. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;
3. Electric Power Research Institute, State Grid Tianjin Electric Power Company, Tianjin 300384, China;
4. NARI Technology Co., Ltd., Nanjing 211106, China)

Abstract: As the final energy-consuming unit of a power system, buildings directly affect the continuity of power supply and the user's electricity experience. Therefore, efficient fault diagnosis and repair are crucial in the event of sudden operational breakdowns and maintenance events. Knowledge graphs can efficiently extract unstructured data entities and their associated attributes during construction, thereby providing strong support for fault diagnosis and intelligent operation and maintenance. However, traditional extraction methods achieve low extraction completeness in scenarios with multiple trigger words and multiple events associated with argument elements, making it difficult to effectively support the construction of building operation and maintenance knowledge graphs. In this regard, we develop an event joint extraction method for graph construction. First, an adaptive threshold word segmentation algorithm based on point mutual information and left-right entropy is studied to accurately segment text words and characters in the operation and maintenance field. Second, the unified expression paradigm of multiple relationships in the building operation and maintenance knowledge graph is designed to address the issue of the same argument having multiple roles. Next, a domain-specific large language model, LouYSpanBERT, is trained, and a joint extraction

收稿日期: 2025-06-19; 修回日期: 2025-09-08.

作者简介: 景涛 (1998—), 男, 硕士研究生, jingtao_@tju.edu.cn.

通信作者: 杨挺, yangting@tju.edu.cn.

基金项目: 智能电网国家科技重大专项(2030)资助项目(2024ZD0800800); 国家自然科学基金资助项目(62371338).

Supported by the National Science and Technology Major Project for Smart Grid (2030) (No. 2024ZD0800800), the National Natural Science Foundation of China (No. 62371338).

framework is constructed to extract operation and maintenance events driven by trigger word boundary markers. The accuracy of event extraction is improved through a three-level joint extraction of “trigger word detection-boundary marker-argument extraction.” Finally, the operation and maintenance data for a specific park are used as an example. Compared with four existing models, when the proposed method performs the typical argument classification (AC) task, the F1-score effectively increases by 5.08%, 9.81%, 13.36%, and 14.99%, respectively. Here, we visually display the extraction results in Neo4j to build an operational and maintenance knowledge graph.

Keywords: event joint extraction; knowledge graph; word segmentation algorithm; trigger word boundary; argument classification

建筑楼宇作为电力系统能量传输的“最后一公里”，直接承载着照明、空调、电梯、安防等末端用能设备，其安全稳定运行是电力系统最终价值实现的重要体现，也是保障整个配电网末端安全的核心环节。随着信息技术不断发展，城市信息化应用水平不断提高，智慧城市建设的脚步逐渐加快，在此过程中，楼宇运维水平决定了建筑运行的安全性、舒适性和节能效率^[1-2]。然而，楼宇运行过程中产生的海量多源异构数据却未能合理高效利用，其中包含传感器数据等结构化的数据，监控告警记录等半结构化数据，以及运维日志、报修单等非结构化数据，如何高效整合结构化与非结构化多源数据并深入挖掘数据间的关联关系，以提升楼宇故障诊断准确性和运维效率，仍然是一个亟待解决的难题。

伴随着人工智能技术的升级换代，知识图谱作为一种揭示文本数据中实体语义关联的图结构化知识库，在实现文本语义层次的关联融合、可视化展示复杂知识等方面具有独特优势^[3]。一方面，基于领域本体构建统一的概念层次体系，将运维数据中的故障类型、设备实体和维修时间等进行标准化定义，消除多源数据之间的语义歧义，确保知识融合对同一概念的理解一致^[4]；另一方面，知识图谱能够处理不同的数据存储格式的数据，将不同格式的文件进行整合和转换，实现数据的统一存储^[5]。因此，将楼宇运维数据构建为知识图谱可以挖掘文本数据间潜在的关联关系，辅助运维人员制定楼宇运维策略，实现从数据驱动到知识驱动的升级。

在知识图谱构建过程中，数据获取、知识抽取、知识融合与知识加工是主要环节^[6]。其中，知识抽取^[7]作为构建知识图谱的核心步骤，旨在从大量非结构化数据中提取有价值的信息。事件抽取^[8]是知识抽取领域的一个重要子任务，旨在从描述事件的文本中识别出事件及其组成元素，完整的事件抽取任务包括触发词检测、事件类型分类以及论元识别。在楼宇运维文本中，事件抽取可以用于自动识别诸如电梯故障、过压预警、断路器跳闸等运维日志或工单记录中的关键

信息，提取设备名称、故障位置、时间、运维人员等要素，构建实体-关系网络，显式表达文本数据中事件元素的关联规则，将非结构化文本转化为结构化知识。由于楼宇运维领域自身包含大量专业术语，事件类型丰富，通用抽取模型往往难以准确理解文本含义，影响关键词识别和实体关系抽取准确率，因此，设计基于楼宇运维场景的领域专属模型对于提高事件抽取精度具有重要意义。

事件抽取任务通常被定义为序列标注任务，根据抽取方法的不同划分为基于模式匹配的方法和基于机器学习的方法^[9]。模式匹配需要人工预先标注大量的语料，且抽取效果取决于人工标注的效果，同时由于预先制定的模式有限，难以覆盖所有的事件类型。近些年，随着人工智能技术和机器学习的发展，基于机器学习的事件抽取方法受到了众多学者的关注^[10]，现有方法分为流水线结构和联合抽取模型，在流水线结构中将事件抽取任务拆分为触发词检测和论元识别两个子任务，首先通过元素分类识别事件触发词以判断事件类型，再通过序列标注的方法识别事件论元，流水线结构构建过程简单，每个子任务独立设计，但在抽取过程中存在误差传递的缺点，触发词检测错误直接影响后续论元识别的准确率，且关键论元对事件类型判别的贡献无法反馈至触发词的检测中。为提高事件抽取的准确率，现有学者大多基于联合抽取模型开展研究。

在联合抽取任务中，将事件抽取任务构建为触发词抽取模块和论元识别模块，同时进行触发词检测与论元识别^[11-12]，模块间参数共享并在模型训练过程通过联合损失调参，以解决流水线结构中的错误信息传递与单向任务问题。然而，在楼宇运维文本知识库中往往信息密度高，一句话中会同时出现多个事件触发词^[13]；此外，同一实体在不同事件中可能承担不同的论元角色。传统的事件抽取模型进行“单触发-单角色”式抽取，可能仅关注某一触发词，忽略其余事件或角色，影响事件抽取完整性。文献[14]结合预训练语言模型 (ERNIE)、双向长短期记忆网络 (bidirec-

tional long short-term memory, BiLSTM) 和指针网络 (pointer network, PN) 构建了统一的信息抽取框架, 通过事件触发词抽取完成事件类型分类, 并提取语义特征识别事件相关论元. 文献[15]提出了一种基于跨度 Span 网络的重叠和嵌套事件级联解码联合学习模型, 集成预训练 BERT 模型和自适应事件融合模块完成触发词抽取, 结合多头自注意力和 BiLSTM 提取全局特征依赖关系, 进行论元识别. 二者均可有效解决一句话中包含多种事件类型的问题, 但未考虑一个论元同时属于多个事件时的论元识别问题.

针对楼宇运维事件抽取任务处理多触发词与论元关联多事件的复杂段落时, 存在抽取完整率低的问题, 本文提出一种触发词边界标记驱动的楼宇运维事件联合抽取框架, 定义其名为 LouYSCaPE 模型: 检测触发词边界标记即时启动相应论元识别, 保证触发词与论元的完整抽取, 并定义新的多元关系统一表达范式, 避免论元关联多个事件时关系混乱、抽取准确率低的问题, 最终通过楼宇运维知识图谱可视化展示抽取效果. 本文具体开展了以下研究:

(1) 针对事件抽取任务中楼宇运维领域专业术语识别难的问题, 提出基于最小熵与点互信息的自适应阈值分词算法, 准确切分触发词和论元, 提高抽取准确率;

(2) 定义“事件类型-论元角色-论元”的楼宇运维知识图谱多元关系统一表达范式, 将传统“多种关系类型”表征为论元角色属性, 消除论元关联不同事件时存在的冗余关系问题;

(3) 利用楼宇运维语料对 SpanBERT 进行领域预训练, 提升模型对专业术语的向量表达, 构建触发词边界标记驱动的事件联合抽取框架, 检测到触发词边界标记时即时进行相应事件论元识别, 提升完整事件抽取精度;

(4) 以某园区实际运维数据为例进行事件抽取与知识图谱构建, 结果表明本文所提方法在解决多触发词与论元关联多事件的问题上优于现有模型, 保证楼宇运维图谱具有较好的准确性和完整性.

1 面向楼宇运维文本改进基于最小熵原理与点互信息的中文分词算法

建筑楼宇运维多源异构数据包括人员记录的运维日志、报修单以及楼宇自动化系统 (building automation system, BAS) 的监控告警记录、传感器数据等. 相较于英文文本中词语通过空格等分割符做出

明确划分, 中文文本由连续字符组成, 词语之间不具备明显的分割, 边界不易判定, 增加了事件抽取任务中楼宇运维领域专业术语识别的难度. 分词任务作为事件抽取的前置工作, 分词的错误会传递到下游抽取任务, 造成触发词定位不准或论元角色识别错误, 影响整个事件抽取效果. 因此, 为提高事件抽取任务中触发词抽取和论元识别的准确率, 本文对传统分词模型进行改进, 提出一种基于点互信息与左、右熵的自适应阈值中文分词算法, 通过计算相邻两字的点互信息与成词的左、右熵, 评估词汇的上、下文适应性进而完成更精准的分词处理, 基于点互信息与左、右熵的自适应阈值分词算法流程如图 1 所示.

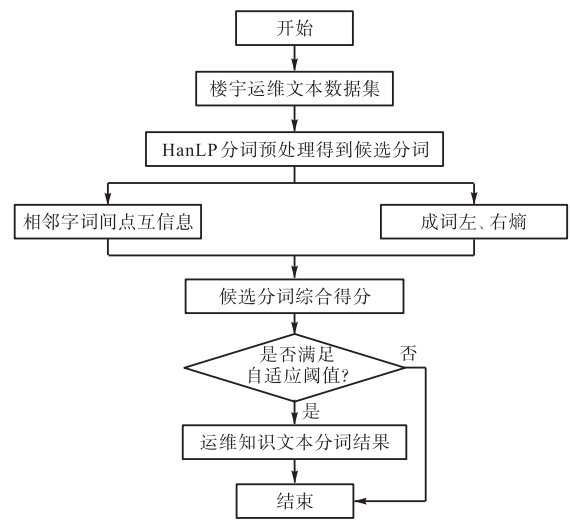


图 1 基于点互信息与左、右熵的自适应阈值分词算法
Fig.1 Adaptive threshold word segmentation algorithm based on point mutual information and left-right entropy

点互信息 (pointwise mutual information, PMI)^[16] 是基于互信息 (mutual information, MI) 的一个度量指标, 用相邻字词之间的 PMI 衡量其内部黏合程度, PMI 越大说明分词间内部联系越紧凑, 更倾向于组成一个词语. 对于由连续 n 个字组成的候选分词 $w = c_1c_2c_3 \cdots c_n$, 其 PMI 计算式为

$$p_{\text{PMI}}(w) = \frac{1}{n-1} \sum_{i=1}^{n-1} \lg \frac{P(c_i c_{i+1})}{P(c_i)P(c_{i+1})} \quad (1)$$

式中: $p_{\text{PMI}}(w)$ 为点互信息计算值; c_i 、 c_{i+1} 分别为候选分词 w 中第 i 个和第 $i+1$ 个字; $P(c_i)$ 为字 c_i 出现的概率; $P(c_i c_{i+1})$ 为字对 $c_i c_{i+1}$ 出现的概率.

同时, 引入左、右熵衡量候选分词两端上、下文的多样性, 熵越大表明该侧上、下文多样性强, 熵越小表明分词周围字符较为固定, 短语边界明显, 该分词作为独立单元的可能性更大. 候选分词 w 的左、右

熵计算式分别为

$$H_{\text{left}}(w) = - \sum_{x_i \in C_{\text{left}}(w)} P(x_i|w) \lg P(x_i|w)$$

$$H_{\text{right}}(w) = - \sum_{y_i \in C_{\text{right}}(w)} P(y_i|w) \lg P(y_i|w)$$
(2)

式中: $P(x_i|w)$ 为字符 x_i 出现在候选分词 w 左侧的概率; $P(y_i|w)$ 为字符 y_i 出现在候选分词 w 右侧的概率; $C_{\text{left}}(w)$ 为 w 左侧字符集合; $C_{\text{right}}(w)$ 为 w 右侧字符集合.

将 PMI 与左右熵同时作为成词依据, 计算候选分词综合得分为

$$S(w) = p_{\text{PMI}}(w) - \lambda [H_{\text{left}}(w) + H_{\text{right}}(w)]$$
(3)

式中 λ 为衡量 PMI 与左右熵权重.

考虑到楼宇运维语料中候选分词字数与出现次数不同, 若采用固定阈值则会忽略部分长低频短语, 同时错误将短高频非短语进行分词. 因此, 本文结合候选词长度与出现频次动态调整自适应分词阈值, 提高短高频短语分词阈值, 使得长低频短语拥有更低阈值, 其计算式为

$$\theta(w) = \alpha \frac{\ln(1+l_w)}{\sqrt{1+f_w}} + \beta$$
(4)

式中: l_w 为候选分词 w 字数; f_w 为 w 出现次数; α 和 β 为调优参数, α 取值范围 [0.1, 5.0], 步长设置为 0.1, β 取值范围 [0, 5.0], 步长设置为 0.2. 本文通过交叉验证网格搜索算法确定 α 和 β 最优参数组合为 $\alpha = 1.7$ 、 $\beta = 1.4$.

候选分词 w 是否成词判定如下:

$$\begin{cases} S(w) \geq \theta(w) & \text{保留} \\ S(w) < \theta(w) & \text{舍弃} \end{cases}$$
(5)

若综合得分 $S(w)$ 大于分词阈值 $\theta(w)$, 则将 w 保留为分词单元, 否则舍弃该候选分词.

基于对上述中文分词特性的理解, 以基于最小熵原理与点互信息的中文分词算法作为研究基础, 通过动态调整分词阈值, 准确地切分触发词和论元字词, 提升事件抽取的准确性.

2 楼宇运维知识图谱多元关系统一表达范式

在知识图谱多元关系表示中, 通常将多元三元组拆解为若干二元关系, 即以“事件类型-关系-论元”的形式连接两个节点. 然而, 楼宇实际运行日志以及报修工单通常在一条记录中描述多类事件的发生过程, 例如设备过压告警导致后续设备故障, 继而安排运维人员检修并上报故障原因, 其中包括 d 类事件 $N_{\text{evt}} =$

$\{e_1, e_2, \dots, e_d\}$ 与 x 个论元 $N_{\text{elt}} = \{a_1, a_2, \dots, a_x\}$, 若仍沿用“事件类型-关系-论元”范式, 需要为每对事件类型 $e_i \in N_{\text{evt}} = \{e_1, e_2, \dots, e_d\}$ (如过压告警、设备故障、设备检修) 与论元 $a_i \in N_{\text{elt}} = \{a_1, a_2, \dots, a_x\}$ (如设备名称、地点、事件、运维人员) 间的关系命名, 导致关系集 $O(|N_{\text{evt}}| \times |N_{\text{elt}}|)$ 冗余且命名标准难以统一. 因此, 本文提出一种新的多元关系统一表达范式——“事件类型-论元角色-论元”, 将事件类型与论元分别构建为图谱节点, 以论元角色作为连接事件类型节点与相应论元节点之间的边标签.

本范式将论元角色定义为关系集合, 即 $R = \{r_1, r_2, \dots, r_m\}$ 作为固定边标签, 关系类型数为 $|R| = m$; 且同一论元节点 a_j 通过相同角色边标签 r_j 与多个事件建立边关系, 保证该论元在所有相关事件中语义连接一致, 不会因事件类型不同而划分为多个关系名称, 避免同一论元在多个事件中担任不同“角色”导致关系混乱、抽取不准确的问题, 并简化图谱的关系类型管理, 表示为图 2 所示的多元关系事件. 以事件集合中某一事件 Γ 为例, 根据事件类型和论元创建事实节点, 并根据论元在事件中承担的角色构成该事件中的多元关系集合 R_Γ , 若事件 Γ 包含 n 个论元, 称 R_Γ 为 n 元关系, 知识图谱 G 可表示为 4 元组 $\{N_{\text{evt}}, N_{\text{elt}}, R, \{(\Gamma, R_\Gamma) | \Gamma \in N_{\text{evt}}, R_\Gamma \subseteq R\}\}$.

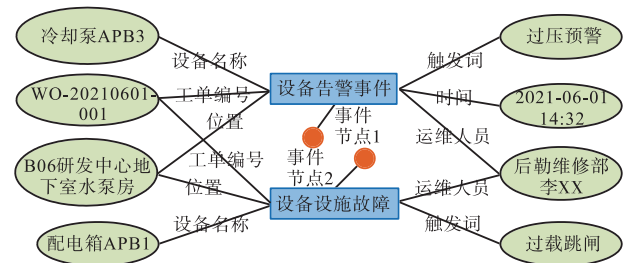


图 2 楼宇运维多元关系图谱表达范式示例

Fig.2 Example of the multi-relationship graph expression paradigm for building operation and maintenance

3 触发词边界标记驱动的楼宇运维事件联合抽取框架

在楼宇运维知识库文本中, 一句话中往往会同时描述多个事件, 现有的事件抽取方法通常采用多标签分类定位触发词, 得到一个触发词后忽略其他的触发信息, 导致抽取不完整^[17]; 此外, 同一个论元往往可能与多个事件类型关联, 若不能完整准确识别每个触发词下的论元, 会影响事件抽取任务的精度.

针对上述问题, 本文提出一种触发词边界标记驱

动的楼宇运维事件联合抽取框架,如图3所示.首先,通过楼宇运维微调 LouYSpanBERT 模型对输入文本进行编码,联合双向门控循环单元 Bi-GRU 层和条件随机场 CRF 模型进行多触发词的检测与定位,并在每个触发词前后分别插入始末标记以明确触发词边界;然后,标记后的序列再次进入 LouYSpanBERT 模型中编码,通过多头注意力机制捕捉触发词

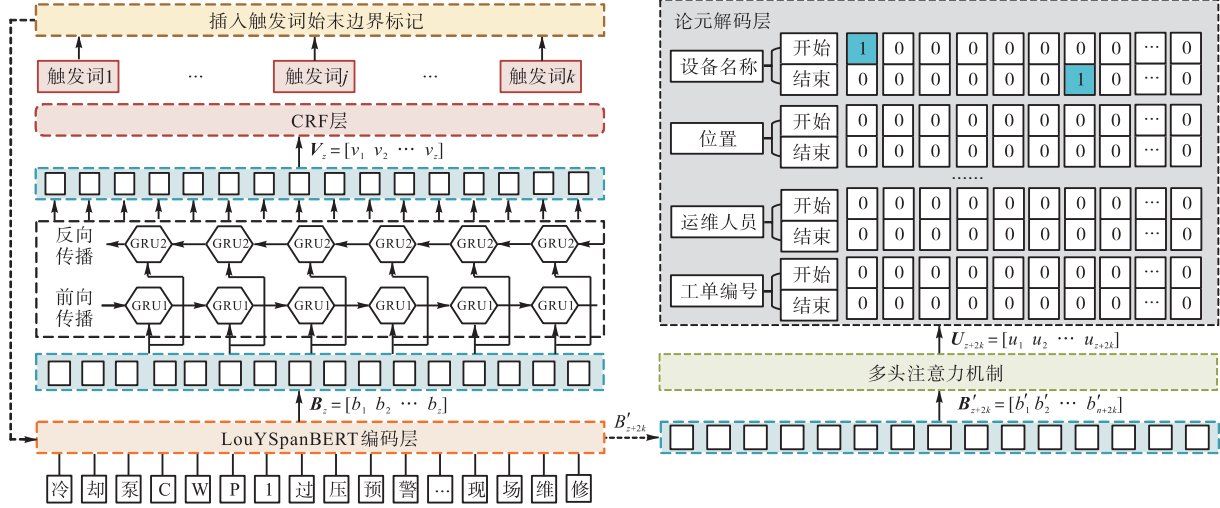


图3 触发词边界标记驱动的事件联合抽取框架

Fig.3 An event joint extraction framework driven by trigger word boundary markers

3.1 LouYSpanBERT 模型自适应预训练与触发驱动事件抽取框架微调

随着 transformer 结构的普及,大语料、大参数量的预训练模型给自然语言处理领域带来了巨大的突破,成为当前大语言模型发展的主流.其中,BERT 模型采用 transformer 架构,通过对文本进行双向编码捕捉句子的上、下文信息,被广泛应用于自然语言处理领域^[18].然而,随着模型规模的扩大,BERT 在训练和推理时对计算资源的需求也显著增加,训练时间延长,推理速度降低.

SpanBERT 是一种基于 BERT 的改进模型,通过引入一种新的训练目标 Span Boundary Objective(SBO),来更好地捕捉跨度(如短语、实体等)的内部结构和边界信息^[19].除了以 BERT 原有的预测掩码词的交叉熵作为训练目标,还将连续掩码词引入掩码边界词作为辅助训练目标,在训练时,取掩码词前后边界的两个词,且这两个词并不在掩码范围内,通过这两个词提取得到的特征向量,与掩码词的位置编码向量联合预测最终的词,模型能够更好地学习跨度级别的依赖关系和上、下文信息.

SpanBERT 预训练所采用的通用语料中很少出现冷却泵 CWP、断路器、过压预警等楼宇运维领域的专业术语,模型难以有效捕捉此类文本中的语义特

与全句的长距离关联,指针网络 PN 层遍历到触发词边界标记时,进行该触发词相关论元的识别,预测每个论元的始末位置,完成论元识别.该方法通过“触发词检测-边界标记-论元识别”三级联合抽取,既保证了多触发词环境下的完整检测,也将论元与其所属触发词一一对应,显著提升事件抽取的整体精度和完整性.

征.针对这一问题,本文首先收集选取《楼宇智能化设备的运行管理与维护》、《楼宇智能化系统的集成设计与施工》、设备运维手册、BAS 系统导出日志、运维工单记录表、巡检记录表等楼宇运维专业语料对 SpanBERT 进行领域自适应预训练,使模型再学习楼宇运维领域的术语、表达习惯和常见短语结构,保存楼宇运维领域专用 LouYSpanBERT 模型,预训练过程如图 4 所示.

为捕捉其中的语义信息,对于输入文本序列 $X_n = \{x_1, x_2, \dots, x_n\}$,SpanBERT 将每个字词关联为初始嵌入向量 H_n ,利用 transformer 结构的注意力机制将 H_n 编码为 Q, K, V 向量序列,即

$$Q = W_Q H_n, K = W_K H_n, V = W_V H_n \quad (6)$$

式中 W_Q, W_K, W_V 分别为查询矩阵、键矩阵、值矩阵,通过模型训练更新.

通过 softmax 函数将注意力权重矩阵归一化处理得

$$A_{\text{weight}}(Q, K) = \text{softmax} \left(\frac{QK^T}{\sqrt{d_k}} \right) \quad (7)$$

式中 d_k 为向量维度.

得到加权 V 向量,也即注意力层的输出为

$$A_{\text{attention}}(Q, K, V) = A_{\text{weight}} V \quad (8)$$

通过多个注意力头并行计算,将结果拼接并通过线性变换得到最终的注意力输出为

$$A_{\text{attention}}^{\text{multi}}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = C(A_{\text{attention}1}, A_{\text{attention}2}, \dots, A_{\text{attention}\mu})\mathbf{W}_O \quad (9)$$

式中: $C(\cdot)$ 为拼接函数; μ 为注意力头数量; \mathbf{W}_O 为输出权重矩阵。

在构建 LouYSpanBERT 领域专用模型的基础上,进行触发驱动的事件联合抽取框架微调,如图 4 所示,采用BIEO 标注策略标注触发词,在触发词前后插入 < TRIG_START > 与 < TRIG_END > 标记,并标出每个触发词下相应论元跨度,微调得到触发词边界标记驱动的楼宇运维事件联合抽取框架。

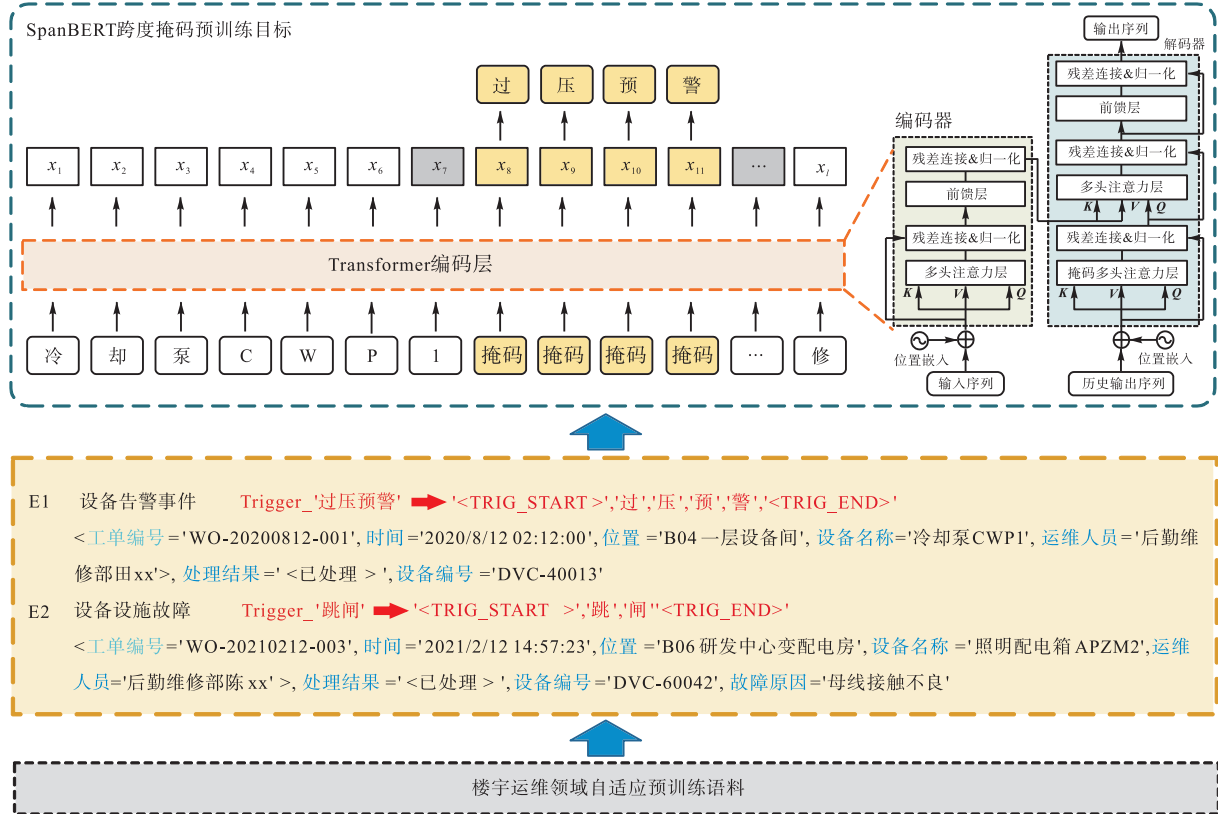


图 4 LouYSpanBERT 模型预训练与触发驱动事件抽取框架微调流程

Fig.4 Fine-tuning flow chart of the LouYSpanBERT model pre-training and trigger driver event extraction framework

3.2 双向门控循环单元

门控循环单元(gated recurrent unit, GRU)^[20]是循环神经网络(recurrent neural network, RNN)的变体,与传统的循环神经网络相比,GRU 具有更少的参数和更小的计算复杂度,通过引入门控机制控制信息的流动.其中,更新门决定了当前时刻的输入是否对当前状态进行更新,而重置门决定了如何将过去的状态与当前输入结合起来,从而能够有效捕捉长序列之间的语义关联,在处理长期以来关系时具有更好的性能。

当前时刻 GRU 输出的隐藏状态 h_t 计算式为

$$h_t = (1 - z_t)h_{t-1} + z_t\tilde{h}_t \quad (10)$$

式中: z_t 为更新门输出; h_{t-1} 为 $t-1$ 时刻隐藏状态; \tilde{h}_t 为候选隐藏状态,由 h_{t-1} 和 t 时刻输入 x_t 决定。

重置门决定是否重置上一时刻隐藏状态 h_{t-1} , 其输出 r_t 计算式为

$$r_t = \sigma(x_t W_r + h_{t-1} W_{hr} + B_r) \quad (11)$$

式中: σ 为 sigmoid 激活函数; x_t 为当前输入; W_r 为重置门权重矩阵; W_{hr} 为 h_{t-1} 在重置门中的权重矩阵; B_r 为重置门的偏置项。

重置门输出与当前输入 x_t 组成候选隐藏状态 \tilde{h}_t , 其计算式为

$$\tilde{h}_t = \tanh(x_t W_{ch} + r_t h_{t-1} W_{hh} + B_h) \quad (12)$$

式中: \tanh 为双曲正切激活函数; W_{ch} 、 W_{hh} 为权重矩阵; B_h 为隐藏状态的偏置项。

更新门输出 z_t 决定如何融合上一时刻隐藏状态 h_{t-1} 与候选隐藏状态 \tilde{h}_t , 其计算式为

$$z_t = \sigma(x_t W_z + h_{t-1} W_{hz} + B_z) \quad (13)$$

式中: W_z 为更新门权重矩阵; W_{hz} 为 h_{t-1} 在更新门中的权重矩阵; B_z 为更新门的偏置项。

双向门控循环单元(bidirectional-gated recurrent

unit, Bi-GRU)由两个方向的GRU组成,一个GRU从前向后处理序列,另一个GRU从后向前处理,结合双向模型和门控机制可以更有效地捕捉更多上、下文信息,处理双向依赖关系。

3.3 条件随机场

在实体识别过程中,便签之间存在复杂的依赖关系,例如,“过压预警”触发词的开始标签B-触发词与内部标签I-触发词是相邻的,而不会后接“断路器跳闸”内部标签I-故障现象。Bi-GRU主要关注局部上、下文,无法充分建模标签之间的依赖关系。因此,引入条件随机场(conditional random field, CRF)^[21]考虑相邻标签的依赖关系,建模标签之间的转移概率,引入标签转移得分。由于直接遍历所有标签序列计算较为复杂,采用维特比解码寻找序列标签全局最优路径,在每一步记录当前最佳路径及对应得分,最终回溯得到最优标签序列。

对于输入特征序列 $H = \{h_1, h_2, \dots, h_n\}$ 和标签序列 $Y = \{y_1, y_2, \dots, y_g\}$, 标签序列得分函数计算式为

$$S_{\text{CRF}}(H, Y) = \sum_{i=0}^n (\mathbf{T}_{y_i, y_{i+1}} + \mathbf{P}_{h_{i+1}, y_{i+1}}) \quad (14)$$

式中: \mathbf{T} 为 y_i 与 y_{i+1} 标签之间转移分数矩阵; \mathbf{P} 为 Bi-GRU 输出特征向量 h_{i+1} 带有标签 y_{i+1} 的得分矩阵。

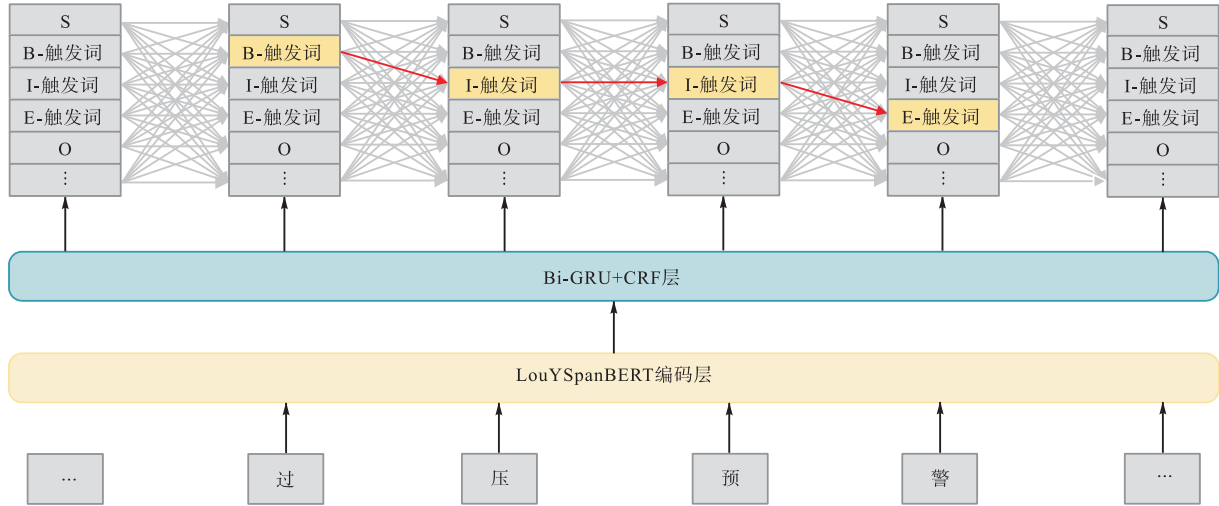


图5 CRF层维特比解码示例
Fig.5 CRF layer viterbi decoding example

3.4 指针网络层

第3.3节CRF层在完成楼宇运维文本的触发词抽取后,将 $\langle \text{TRIG_START} \rangle$ 、 $\langle \text{TRIG_END} \rangle$ 分别插入每个触发词前后得到新的标记序列,将其输入 LouYSpanBERT 转换为新的特征向量 \mathbf{B}'_{z+2k} , 其中, k 为触发词数量。考虑到一句话中论元的分布较为分散,首先经多头注意力机制增强触发词与论元间的特征表示,注意力输出计算过程如式(6)~(9)所示,将

将所有标签输出序列路径进行归一化处理,得到序列对应实体标签的概率。归一化预测标签序列计算式为

$$P(Y|H) = \frac{e^{S_{\text{CRF}}(H, Y)}}{\sum_{y' \in Y_H} e^{S_{\text{CRF}}(H, y')}} \quad (15)$$

式中: Y_H 表示所有可能的标签序列; y' 表示正确的标签序列。

最终,通过预测得分最高的标签序列,作为最终标签预测结果,其预测公式为

$$Y^* = \arg \max_{y' \in Y_H} S_{\text{CRF}}(H, Y_H) \quad (16)$$

以过压预警标识的标签预测为例,图5展示了输入文本到预测标签序列的解码过程,其中S为单字实体标签,O为非实体标签。CRF层计算Bi-GRU输出的特征向量标签得分,并通过维特比解码利用标签之间转移分数矩阵寻找全局最高得分转移路径,例如,触发词过压预警的首字标签B-触发词后面只能为同类中间或末尾标签I/E-触发词,而不允许直接出现其他类实体非首字标签,如位置非首字标签I-位置,根据标签的约束规则和转移分数,最终过压预警的预测标签为B-触发词、I-触发词、E-触发词、O-触发词。

注意力输出与 \mathbf{B}'_{z+2k} 特征向量做残差融合,并通过归一化层得

$$U_i = L_{\text{norm}}(\mathbf{B}'_{z+2k} + A_{\text{attention}}^{\text{multi}}) \quad (17)$$

将加权后的特征向量 U_i 输入到 PN^[22] 中进行解码,去识别所有可能的候选论元,采用二分类标记开始和结束位置。首先,利用一个线性层计算第 i 个字是论元开始位置和结束位置的分数分别为

$$\begin{cases} s_{PN,i}^{\text{start}} = W_{\text{start}} U_i + b_{\text{start}} \\ s_{PN,i}^{\text{end}} = W_{\text{end}} U_i + b_{\text{end}} \end{cases} \quad (18)$$

式中: W_{start} 、 W_{end} 为权重参数; b_{start} 、 b_{end} 为 PN 层解码的偏置参数。

再将线性层的输出通过 sigmoid 激活函数, 得到每个位置为论元开始和结束位置的概率分别为

$$\begin{cases} P_i^{\text{start}} = \frac{1}{1 + e^{-s_{PN,i}^{\text{start}}}} \\ P_i^{\text{end}} = \frac{1}{1 + e^{-s_{PN,i}^{\text{end}}}} \end{cases} \quad (19)$$

根据阈值(设定为 0.5)将概率转换为二分类标签, 即

$$\begin{cases} y_i^{\text{start}} = \begin{cases} 1 & P_i^{\text{start}} \geq 0.5 \\ 0 & \text{其他} \end{cases} \\ y_i^{\text{end}} = \begin{cases} 1 & P_i^{\text{end}} \geq 0.5 \\ 0 & \text{其他} \end{cases} \end{cases} \quad (20)$$

如果概率超过阈值, 则相应标记会被分配为标签 1, 否则为标签 0。

利用最近匹配原则将识别到的开始和结束配对获得候选论元集合。

3.5 损失函数

在楼宇运维事件抽取过程中, LouYSCaPE 模型选取触发词检测与论元识别联合损失函数。本文通过序列标注完成触发词检测, 式(14)给出 CRF 层标签序列得分, 采用负对数似然损失函数^[23]计算式为

$$\mathcal{L}_{\text{trigger}} = -\frac{1}{N} \sum_{i=1}^n \lg \frac{e^{S_{\text{CRF}}(H, Y)}}{\sum_{y' \in Y_{ii}} e^{S_{\text{CRF}}(H, y')}} \quad (21)$$

论元识别过程中 PN 层计算每个触发词下相应论元角色的起止指针交叉熵之和, 即

$$\begin{aligned} \mathcal{L}_{\text{argument}} &= \sum_{j=1}^k \left[\sum_{r \in R_j} \left(\mathcal{L}_{j,r,i}^{\text{start}} + \mathcal{L}_{j,r,i}^{\text{end}} \right) \right] = \\ &= \sum_{j=1}^k \left[\sum_{r \in R_j} \left(-\lg \frac{1}{1 + e^{-s_{PN,j,r,i}^{\text{start}}}} - \lg \frac{1}{1 + e^{-s_{PN,j,r,i}^{\text{end}}}} \right) \right] \end{aligned} \quad (22)$$

式中: R_j 为触发词 τ_j 对应的论元集合; $s_{PN,j,r,i}^{\text{start}}$ 和 $s_{PN,j,r,i}^{\text{end}}$ 分别为第 i 个字被识别为第 j 个触发词对应论元 r 开始和结束位置的得分。

最终通过超参数 λ 将两部分损失加权融合, 实现模型端到端联合训练为

$$\mathcal{L}_{\text{fusion}} = \mathcal{L}_{\text{trigger}} + \lambda \mathcal{L}_{\text{argument}} \quad (23)$$

式中 $\lambda \in [0, 1]$ 通过交叉验证网格搜索算法确定, 以 0.05 为步长扫描 $[0, 1]$ 区间, $\lambda \in [0.60, 0.80]$ 时联合损失函数 F1 值波动小于 0.5%, 选取 F1 值最高的 $\lambda = 0.67$ 。

4 实验与结果分析

4.1 数据集与处理

本文以某园区实际运维情况记录做实例分析, 用以验证本文所提模型事件抽取有效性的数据来源包括楼宇 BAS 系统日志、检修记录、报修工单记录等, 经数据预处理得到所需文本语料, 采用图 4 所示标注方法进行序列标注, 共得到 1 600 条数据, 包含设备告警、供电故障、能耗异常、定期检修、设备维修等多种事件类型, 论元角色有设备名称、时间、地点、工单编号、维修人员、故障原因等, 其中训练集 1 280 条, 测试集 320 条。

4.2 评价指标

在楼宇运维事件联合抽取任务中, 预测的三元组中的所有元素都必须与标签完全匹配才被视为正确预测, 主要包括如下 4 种。

(1) 触发词识别(trigger identification, TI): 触发词预测结果与标注相同视作触发词识别正确。

(2) 触发词分类(trigger classification, TC): 根据触发词匹配正确的事件类型视作分类正确。

(3) 论元识别(argument identification, AI): 论元预测结果与标注相同视作论元识别正确。

(4) 论元分类(argument classification, AC), 即论元角色分类: 论元角色与标注相同视作论元分类正确。

每项指标均采用准确率(P)、召回率(R)及 F1 值(F1) 分别用于衡量模型的不同性能维度。其中准确率表示模型预测正确的样本占有所有预测样本的比例, 计算公式为

$$P = \frac{N_{\text{correct}}}{N_{\text{all}}} \quad (24)$$

式中: N_{correct} 表示模型预测正确的样本个数; N_{all} 为所有预测样本个数。准确率高意味着模型预测的结果中正确的比例较高, 错误率较低。

召回率表示模型预测正确的样本占有所有正确样本的比例, 计算公式为

$$R = \frac{N_{\text{correct}}}{N_{\text{actual}}} \quad (25)$$

式中 N_{actual} 表示所有正确样本的个数。召回率高意味着模型能够识别出更多的样本。

F1 值是准确率和召回率的调和平均数, 作为综合性能指标其计算公式为

$$F1 = 2 \times \frac{PR}{P + R} \quad (26)$$

4.3 实验环境及参数设置

实验环境配置如表 1 所示。

表 1 实验环境配置

Tab.1 Experimental environment configuration

实验环境	配置
运行系统	Windows 11
CPU	Inter (R) Core (TM) i7-6700 HQ CPU@2.60 GHz
GPU	NVIDIA GeForce GTX1060
Python	3.8
深度学习框架	pytorch 1.12.1, Transformer 4.28.1

实验参数设置如表 2 所示。

表 2 实验参数设置

Tab.2 Experimental parameter setting

轮次	学习率	批样本数量	优化器	自注意力层数	Transformer 层数	权重衰减
50	3×10^{-5}	4	AdamW	8	12	0.01

表 3 不同模型抽取结果对比

Tab.3 Comparison of extraction results from different models

模型	TI			TC			AI			AC		
	P/%	R/%	F1/%	P/%	R/%	F1/%	P/%	R/%	F1/%	P/%	R/%	F1/%
CasEE ^[24]	89.12	87.41	88.26	82.71	81.14	81.92	77.79	76.23	77.00	76.19	72.11	74.65
PLMEE ^[25]	84.63	83.97	84.30	78.93	76.32	77.60	72.23	71.74	71.98	74.03	68.72	71.28
BiLSTM-CRF ^[26]	91.33	80.92	85.81	85.71	72.52	78.57	79.61	72.91	76.11	75.44	69.43	72.31
OneEE ^[27]	88.42	86.86	87.63	82.91	83.11	83.01	80.82	80.11	80.46	77.98	78.04	78.01
本文模型	92.11	87.23	89.60	84.49	85.22	84.85	83.42	82.84	83.13	82.04	81.91	81.97

CRF 有效识别触发词及论元标签。

OneEE^[27]将事件抽取转换为词对关系识别任务，提出单阶段事件抽取模型，通过并行网络标记同时识别触发词与论元之间的关系。

由表 3 的实验对比结果可知，本文所提模型在楼宇运维事件抽取任务上表现较为出色，在 4 个评价指标上 F1 值均得到最高分数，最小提升了 5.08%，最大则提升了 14.99%。

PLMEE^[25]作为流水线型抽取模型，在各项任务中均表现不佳，尤其在 AC 任务中，所提模型实现了 F1 值 14.99% 的提升，可能是其本身存在的上下游错误累计问题所致，同时对长句多事件场景适应性差，难以有效检测到完整的触发词，影响后续对应论元的识别，事件抽取效果差。

与此相比，CasEE^[24]、BiLSTM-CRF^[26]、OneEE^[27]模型均为联合抽取模型。其中，BiLSTM-CRF^[26]通过 BiLSTM 捕捉长距离的语义依赖关系，其在 TI 和 TC 任务中均取得较高的准确率，分别取得了 91.33% 与 85.71% 的良好性能，但召回率较低，表明其在多触发词检测任务中同样表现不佳。

针对论元跨事件重叠的问题，CasEE^[24]模型通过

4.4 实验结果与分析

4.4.1 事件抽取结果

为验证本文模型在楼宇运维事件抽取上的有效性，使用 CasEE^[24]、PLMEE^[25]、BiLSTM-CRF^[26]以及 OneEE^[27]作为基线模型进行对比，对比结果如表 3 所示。

CasEE^[24]采用级联二进制层次化联合抽取框架，首先采用注意力机制进行事件类型分类，然后在此基础上抽取触发词以及论元，实现了端到端的事件抽取。

PLMEE^[25]属于流水线型结构，将事件抽取转换为触发词检测与论元抽取任务，提出基于 BERT 预训练语言模型的事件抽取流程。

BiLSTM-CRF^[26]采用序列标注方法进行事件抽取，通过 BiLSTM 的上下文依赖关系处理能力，对输入文本进行多层次的特征提取和处理，最终通过

级联二进制标注器预测论元的始末位置，可以完整抽取同一论元在不同事件中担任的角色，但触发词间未做边界标记，导致触发词与论元间的耦合不足，AI 与 AC 任务抽取准确率偏低。

OneEE^[27]表现次之，但本文模型与之相比，在 4 个任务中 F1 值分别提升了 2.25%、3.58%、3.32%、5.07%，一方面，本文模型采用领域专属模型 LouYSpanBERT 将输入文本转换为嵌入向量，增强模型对楼宇运维专业术语的理解能力；另一方面，插入的 < TRIG_START > 与 < TRIG_END > 准确触发 LouYSpanBERT + Bi-GRU + PN 模型开展相应论元识别，保证触发词与论元间的强关联性，通过指针网络预测每个论元的始末位置，因此在 AI 和 AC 抽取任务上均领先 4 个对比模型。

4.4.2 多触发词事件抽取结果

为进一步验证本文模型在段落多触发与论元关联多事件方面的有效性，按照事件数量 N 划分数据集，即 $N=1$ 、 $N=2$ 、 $N>2$ ，实验结果如图 6 所示。

以 TC 和 AC 任务开展多触发词事件抽取实验，图 6(a)中表明各个模型在抽取单个事件时 F1 值相差不大，其中 BiLSTM-CRF^[26]表现最佳，F1 为

88.11%，但当一句话包含多个触发词，尤其是触发词数量大于 2 时，抽取性能表现出显著差异，本文模型与之相比提高 16.68%，再次验证本文模型在处理多触发词事件的有效性。




图 6 多触发词事件抽取对比结果

Fig.6 Comparative results of multi-trigger event extraction

触发词抽取效果会直接影响后续 AC 任务中论元识别的精度，因此图 6(b)中展示了 PLMEE^[25]和 BiLSTM-CRF^[26]论元识别效果差，PLMEE^[25]在 N>2 时 AC 任务 F1 值仅为 61.23%。尽管 CasEE^[24]和 OneEE^[27]在 TC 任务中表现与本模型相当，但在抽取触发词相应论元时依然效果不佳，本文模型在 N>2 时 AC 任务 F1 值为 78.59%，与二者相比分别提升了 13.05%、10.64%，表明本文 LouYSCaPE 模型可有效处理同一论元关联多个事件的问题。

4.4.3 事件抽取训练轮次实验

在楼宇运维事件抽取中，AI 任务论元识别决定了所构建图谱的完整性，论元识别错误直接导致事件三元组不完整，因此针对所提模型与对比模型的训练情况，实验收集了 AI 任务 50 个轮次的 F1 值变化情况，如图 7 所示。

由图 7 可知，模型的 F1 值均在训练轮次达到一定次数后逐渐趋于稳定，其中，PLMEE^[25]和 BiLSTM-CRF^[26]模型结构相对简单，参数量少，因此收敛速度最快，10 次左右即可收敛，但 CasEE^[24]远远

达不到事件抽取任务要求。本文所提模型在训练轮次 14 次左右 F1 值趋于稳定，当模型遍历到触发词边界标记时即可进入论元识别，PN 层在 Span 区域上积累足够的正样本梯度，使得 AI 任务更快收敛。收敛速度与 OneEE^[27]接近，但取得了更高的精度，第 50 次迭代时与对比模型相比 F1 值分别提升了 7.96%、15.63%、9.22%、3.25%。综合收敛速度与抽取精度，本文所提模型在多触发多角色的楼宇运维事件抽取任务中取得更佳的抽取效果。

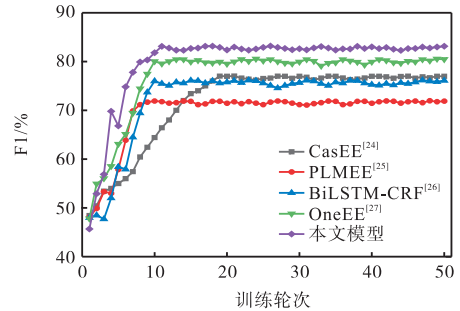


图 7 训练轮次-F1 值实验结果

Fig.7 Experimental results of training epoch vs F1 score

4.4.4 消融实验

楼宇运维事件抽取任务中，本文所构建的 LouYSCaPE 模型采用了领域专属 LouYSpanBERT 进行文本嵌入向量转换，在触发词前后增加触发边界标记，强化触发词与论元耦合性，并引入多头注意力机制捕捉长距离分散论元依赖关系。为验证各个模块在抽取任务中的有效性和相对重要程度，本节设置消融实验，对比结果如图 8 所示。在不改变其余实验参数的情况下，实验组设置如下。

实验组 1: 采用通用 SpanBERT 替换 LouYSpanBERT 模型；

实验组 2: 去除触发词边界标记<TRIG_START>、<TRIG_END>；

实验组 3: 去除论元识别任务中多头注意力模块，将 Bi-GRU 输出直接输入 PN 层中。

图 8 中展示了由于缺少领域自适应预训练，模型对楼宇运维专业术语理解不足，实验组 1 在 TI 和 TC 任务中表现明显不足，且 PN 层难以识别正确的 Span 跨度，导致论元识别精度低；触发词边界标记仅在论元识别阶段使用，不影响触发词检测，因此实验组 2 在 TI 和 TC 任务中表现基本与完整模型持平，但缺少边界定位使得论元难以与触发词对应，AI 与 AC 任务抽取精度显著降低，分别降低了 10.84%、14.36%；对于实验组 3 模型，缺少多头注意力模块使得多事件场景下长距离论元抽取性能下降。综上所

述,各个模块在事件抽取任务中协同作用,保证本文所提 LouYSCaPE 模型表现出最优性能。

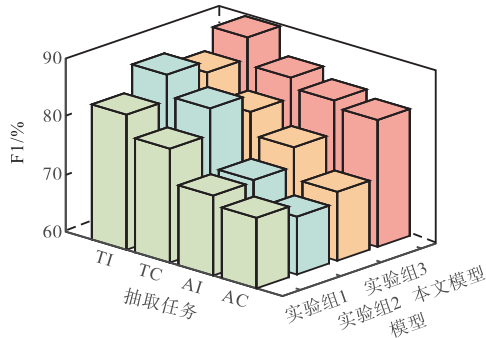


图8 消融实验对比结果

Fig.8 Compariative results of ablation experiments

4.4.5 楼宇运维事件抽取知识图谱可视化

本文所提出的面向楼宇运维知识图谱构建的事件联合抽取方法首先对运维文本进行分词预处理,准确划分触发词与论元边界,构建 LouYSCaPE 模型完成触发词与论元抽取,以解决传统抽取方法在多触发词与论元关联多事件场景中抽取完整率低的问题.并将论元角色赋予关系特性,建立“事件类型-论元角色-论元”多元关系统一表达范式,构建楼宇运维

知识图谱,构建流程如图9所示。

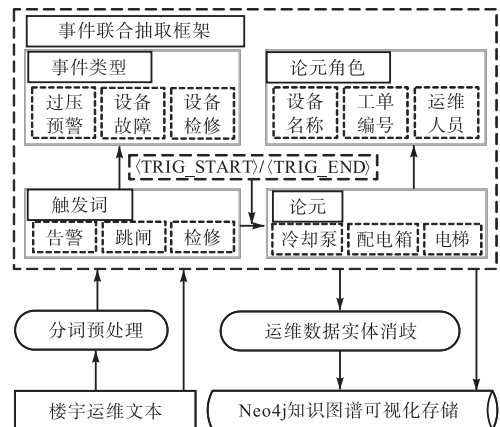


图9 楼宇运维知识图谱构建流程

Fig.9 Construction process for building operation and maintenance knowledge graph

选取某园区实际运维记录,将事件抽取结果通过 Neo4j 进行可视化展示,抽取得到工单编号、设备名称、故障原因等节点类型,将论元相应的论元角色构建为节点间关系,如图10所示.以电梯 014470 定期检修、冷却泵 CWP1 设备告警、照明配电箱 APZM2 供电故障 3 个事件为例展示了其中包含的论元信息。

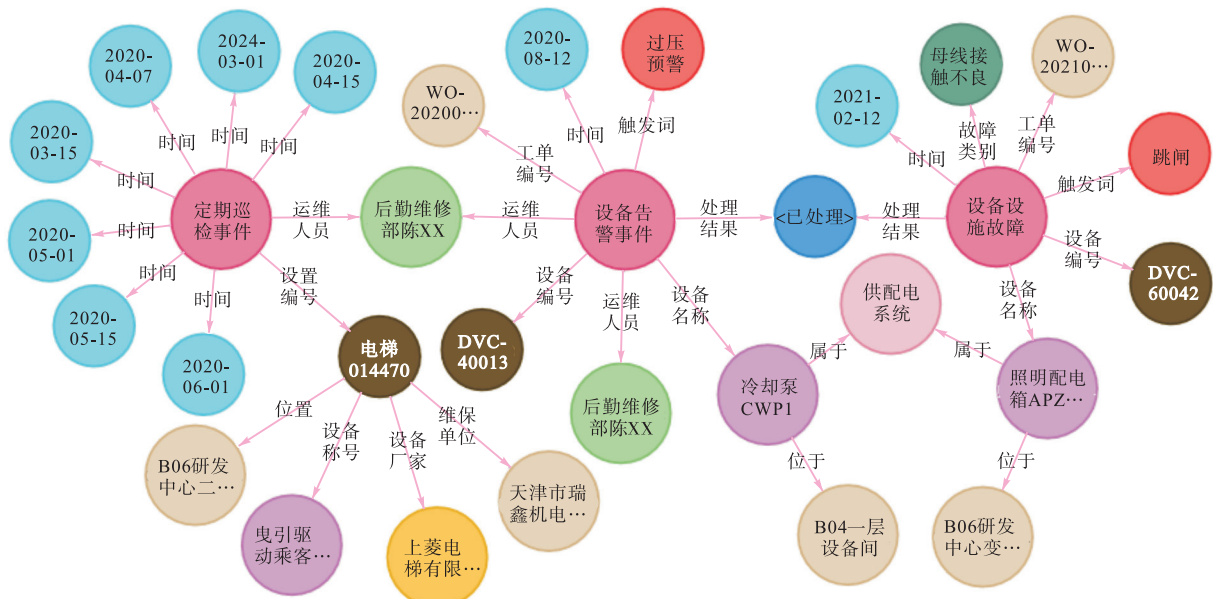


图10 楼宇运维知识图谱

Fig.10 Building operation and maintenance knowledge graph

5 结论

智能楼宇运维文本中存在多触发词共存与论元关联多事件的问题,导致传统事件抽取方法效果不佳,本文提出触发词边界标记驱动的楼宇运维事件联

合抽取框架,构建 LouYSCaPE 模型进行运维事件抽取,得到结论如下。

- (1) 提出了基于点互信息与左、右熵的自适应阈值分词算法,动态调整分词阈值提高专业术语切割准确率,提升触发词与论元边界识别准确率。
- (2) 设计了事件类型-论元角色-论元多元关系

统一表达范式,将传统冗余关系表征转化为固定论元角色标签,解决同一论元在多事件中的角色冲突问题。

(3) 提出了一种触发词边界标记驱动的联合抽取框架,构建 LouYSCaPE 模型,通过在触发词前后插入 < TRIG_START > 与 < TRIG_END > 标记,即时启动触发词相应论元识别,实现多事件场景下触发词与论元的精准匹配。

(4) 基于园区运维数据以 TI、TC、AI、AC 4 类典型任务开展仿真验证,其中,直接反映事件抽取完整率的 AC 任务中,对比 4 个已有模型,本文方法 F1 值有效提升了 5.08%、9.81%、13.36%、14.99%。并且本文还将抽取结果通过 Neo4j 构建为楼宇运维可视化知识图谱,实现了智能楼宇设备状态、故障原因、维护措施的快速识别与追踪。

参考文献:

- [1] 张新长, 华淑贞, 齐 霁, 等. 新型智慧城市建设与展望: 基于 AI 的大数据、大模型与大算力[J]. 地球信息科学学报, 2024, 26(4): 779-789.
Zhang Xinchang, Hua Shuzhen, Qi Ji, et al. Progress and prospects of new smart city construction: AI-based big data, big models and big computing power[J]. Journal of Geo-Information Science, 2024, 26(4): 779-789 (in Chinese).
- [2] Dai Y X, Hasanefendic S, Bossink B. A systematic literature review of the smart city transformation process: The role and interaction of stake-holders and technology[J]. Sustainable Cities and Society, 2024, 101: 1-29.
- [3] Zhong L F, Wu J, Li Q, et al. A comprehensive survey on automatic knowledge graph construction[J]. ACM Computing Surveys, 2023, 56(4): 1-62.
- [4] 闫玮丹, 齐冬莲, 闫云凤, 等. 面向电力领域的知识图谱与大模型融合关键技术及其典型应用[J]. 高电压技术, 2025, 51(4): 1747-1762.
Yan Weidan, Qi Donglian, Yan Yunfeng, et al. Key technologies and typical applications of knowledge graph and large language model fusion in the power sector[J]. High Voltage Engineering, 2025, 51(4): 1747-1762 (in Chinese).
- [5] 张禹方, 袁之康, 高硕杰, 等. 基于跨模态数据的变压器套管故障知识图谱构建与应用[J]. 中国电机工程学报, 2025, 45(22): 9064-9074.
Zhang Yufang, Yuan Zhikang, Gao Shuojie, et al. Construction and application of knowledge graph of transformer bushing faults based on cross-modal data[J]. Proceedings of the CSEE, 2025, 45(22): 9064-9074 (in Chinese).
- [6] Yamashita D Y, Vechiu I, Gaubert J P. A review of hierarchical control for building microgrids[J]. Renewable and Sustainable Energy Reviews, 2020, 118: 109523.
- [7] 束嘉伟, 杨 挺, 耿毅男, 等. 面向电力知识图谱构建的重叠实体关系联合抽取方法[J]. 高电压技术, 2024, 50(11): 4912-4922.
Shu Jiawei, Yang Ting, Geng Yinan, et al. Joint extraction method for overlapping entity relationships in the construction of electric power knowledge graph[J]. High Voltage Engineering, 2024, 50(11): 4912-4922 (in Chinese).
- [8] Xu J H, Yang C, Kang X J. LAAP: Learning the argument of an entity with event prompts for document-level event extraction[J]. Neurocomputing, 2025, 613: 128-139.
- [9] Li Q, Li J X, Sheng J W, et al. A survey on deep learning event extraction: Approaches and applications [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 35(5): 6301-6321.
- [10] Wei Y, Bo L L, Sun X B, et al. Automated event extraction of CVE descriptions[J]. Information and Software Technology, 2023, 158: 107-118.
- [11] Guan Y, Chen J Y, Lecue F, et al. Trigger-argument based explanation for event detection[C]//Findings of the Association for Computational Linguistics: ACL 2023. Toronto, Canada, 2023: 5046-5058.
- [12] Yang J, Han S C, Poon J. A survey on extraction of causal relations from natural language text[J]. Knowledge and Information Systems, 2022, 64(5): 1161-1186.
- [13] Peng J R, Yang W Z, Wei F Y, et al. Prompt for extraction: Multiple templates choice model for event extraction[J]. Knowledge-Based Systems, 2024, 289: 111-124.
- [14] 刘万里, 雍新有, 曹开臣, 等. 基于提示学习的 ERNIE-BiLSTM-PN 通用信息抽取方法研究[J]. 电子科技大学学报, 2025, 54(3): 411-423.
Liu Wanli, Yong Xinyou, Cao Kaichen, et al. Universal information extraction method based on prompt learning with ERNIE-BiLSTM-PN[J]. Journal of University of Electronic Science and Technology of China, 2025, 54(3): 411-423 (in Chinese).
- [15] 齐云雷, 王 冰. 基于 span 指针网络的重叠和嵌套事件抽取联合学习框架[J/OL]. 控制工程, <https://doi.org/10.14107/j.cnki.kzgc.20240569>.
Qi Yunlei, Wang Bing. A framework for joint learning

- of overlapping and nested event extraction based on span pointer networks[J/OL]. *Control Engineering of China*, <https://doi.org/10.14107/j.cnki.kzgc.20240569> (in Chinese).
- [16] Padmakumar V, He H. Unsupervised Extractive Summarization Using Pointwise Mutual Information [EB/OL]. <https://arxiv.org/abs/2102.0272>, 2021-02-11.
- [17] Li Q, Guo S, Wu J, et al. Event extraction by associating event types and argument roles[J]. *IEEE Transactions on Big Data*, 2023, 9(6): 1549-1560.
- [18] Gardazi N M, Daud A, Malik M K, et al. BERT applications in natural language processing: A review[J]. *Artificial Intelligence Review*, 2025, 58(166): 1-49.
- [19] Joshi M, Chen D Q, Liu Y H, et al. SpanBERT: Improving pre-training by representing and predicting spans[J]. *Transactions of the Association for Computational Linguistics*, 2020, 8: 64-77.
- [20] Zhu Z J, Dai W H, Hu Y, et al. Speech emotion recognition model based on Bi-GRU and focal loss[J]. *Pattern Recognition Letters*, 2020, 140: 358-365.
- [21] An Y, Xia X Y, Chen X L, et al. Chinese clinical named entity recognition via multi-head self-attention based BiLSTM-CRF[J]. *Artificial Intelligence in Medicine*, 2022, 127: 102-112.
- [22] Veličković P, Buesing L, Overlan M C, et al. Pointer graph networks[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 2232-2244.
- [23] Yao H S, Zhu D L, Jiang B, et al. Negative log likelihood ratio loss for deep neural network classification [C]// *Proceedings of the Future Technologies Conference (FTC)*. San Francisco, USA, 2019: 276-282.
- [24] Sheng J W, Guo S, Yu B W, et al. CasEE: A joint learning framework with cascade decoding for overlapping event extraction[C]// *Findings of the Association for Computational Linguistics: ACL-IJCNLP 2021*. 2021: 164-174.
- [25] Yang S, Feng D W, Qiao L B, et al. Exploring pre-trained language models for event extraction and generation[C]// *Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Florence, Italy, 2019: 5284-5294.
- [26] Du X Y, Cardie C. Document-level event role filler extraction using multi-granularity contextualized encoding[C]// *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. 2020: 8010-8020.
- [27] Cao H, Li J Y, Su F F, et al. OneEE: A one-stage framework for fast overlapping and nested event extraction[C]// *Proceedings of the 29th International Conference on Computational Linguistics*. Gyeongju, Republic of Korea, 2022: 1953-1964.

(责任编辑:孙立华)