

DOI:10.19344/j.cnki.issn1671-5276.2025.06.023

融合深度学习的航空发动机故障诊断知识图谱的构建及应用

刘威,肖玲斐,谭雨硕

(南京航空航天大学 能源与动力学院,江苏 南京 210016)

摘 要:航空发动机传统的故障诊断方法容易造成知识浪费,已逐渐无法满足复杂的工作需求,而知识图谱能有效应对此问题,故提出一种融合深度学习的航空发动机故障诊断知识图谱的构建及应用方法。基于深度学习提出 BERT-BiLSTM-Attention-CRF 的命名实体识别算法对航空发动机故障诊断语料进行实体识别,使用 BERT 生成字符嵌入特征, BiLSTM 获取上下文特征,引入注意力机制,分别突出前向和后向上下文的关键信息。实体识别实验结果表明:该实体识别算法能提高实体识别效果,为构建知识图谱提供先决条件。根据语料句法完成实体关系匹配,以 Neo4j 图数据库 utilizes 为基础对知识图谱进行高度可视化管理,并利用知识图谱设计智能问答系统,从而提高故障处置率,为自主故障诊断提供知识支持。

关键词:航空发动机;故障诊断;知识图谱;实体识别;知识问答

中图分类号:V23 **文献标志码:**A **文章编号:**1671-5276(2025)06-0126-05

Construction and Application of Knowledge Graph of Aero-engine Fault Diagnosis Based on Deep Learning

LIU Wei, XIAO Lingfei, TAN Yushuo

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract:In response to the challenge that traditional methods of diagnosing faults in aero-engine easily lead to knowledge wastage and gradual inadequacy for complex work demands, knowledge graphs can be an effective solution. This article proposes a method for constructing and applying a knowledge graph for the diagnosis of aircraft engine faults, integrating deep learning. A named entity recognition algorithm is introduced based on BERT-BiLSTM-Attention-CRF for identifying entities in the corpus of aircraft engine fault diagnosis. BERT is leveraged to generate character embedding features, BiLSTM is utilized to capture contextual features, and attention mechanisms are incorporated to highlight the key information from both forward and backward contexts. Experimental results in named entity recognition demonstrate that the proposed algorithm can enhance entity identification effectiveness, providing prerequisite for the knowledge graph construction. Based on corpus syntax, entity relationships are matched, and the Neo4j graph database is applied as the foundation for highly visualized management of the knowledge graph. And the knowledge graph is harnessed to design an intelligent question-answering, enhancing fault resolution rates and providing knowledge support for autonomous fault diagnosis.

Keywords:aero-engine; fault diagnosis; knowledge graph; entity recognition; knowledge Q&A

0 引言

航空发动机作为现代工业中的关键技术和产品,是国家科技、国防和经济发展战略的重要组成部分^[1]。由于航空发动机长期在高温、振动、高压的恶劣环境下运行,故不可避免地会出现一些故障^[2]。通过一些故障诊断算法,可以实现对部分故障的检测^[3]。随着我国航空发动机的发展,尽管积累了大量经验,但这些经验很多以非格式化的形式存储,维修人员仍需手动翻阅和查找,这种传统模式导致维修效率低下,且无法充分利用历

史故障信息^[4-5]。作为人工智能三大技术领域的知识图谱(knowledge graph)技术^[6],能有效解决上述问题,且已有相关科研人员将其运用至航空领域^[7-8]。借鉴知识图谱在医疗^[9]、社交^[10]和影评^[11]等诸多领域的成功应用,国内外已有相关文献将知识图谱引入故障领域,辅助实现系统故障诊断。文献[12]将知识图谱引入汽车故障诊断领域,对知识图谱汽车故障处理领域的应用进行了探索。文献[13]分析了基于人工智能的电力设备故障知识图谱的构建过程,初步实现了电力设备故障诊断和决策。在故障知识图谱构建中,

基金项目:国家自然科学基金资助项目(62373185)

第一作者简介:刘威(1997—),男,安徽宿州人,硕士研究生,研究方向为航空发动机故障诊断,sixvvvvv@nuaa.edu.cn。

知识抽取是图谱构建的关键,而实体识别是核心任务^[14]。文献[15]提出了一种 ID-CNN 的命名实体识别方法,在数据集上的实验验证了此方法的优势在于提高训练、测试速度。文献[16]对 Lattice Transform 的命名实体识别方法进行了研究,利用 Transform 获取字符长距离依存特征,从而提高实体识别精度。文献[17]提出 LR-CNN 模型,使用堆叠卷积神经网络获取字符和 n-gram 词语特征,引入 rethink 机制调整 n-gram 特征权重。而对于航空发动机故障诊断则存在句子长度有限、缺少充分的上下文信息等问题。

基于上述问题,本文构建故障诊断知识本体;提出 BERT-BiLSTM-Attention-CRF 实体识别算法。实验结果表明,所提出的实体识别模型可以提升实体识别效果;建立航空发动机故障知识图谱,对其进行可视化问答系统应用,实现故障知识的高效存储和查询。

1 航空发动机故障本体构建

构建航空发动机故障本体的目的是为了对概念、实体或属性进行显示约束,是从最顶层的概念开始对各类数据进行实体概念、关联关系和附加属性的细化,从而形成相应的本体规则,为后续的实体知识抽取提供规范。其主要步骤如下:1)和领域内的专家共同探讨航空发动机故障的业务需求,明确构建本体的应用目的;2)考虑其他领域是否有可重用的本体;3)构建航空发动机故障领域的概念体系,定义故障知识的核心概念;4)列出本体中的重要术语,对故障相关概念进行规范化处理;5)收集此领域专家、基层保障人员对故障知识本体的评价和改进意见;6)给本体补充实例。本文对于故障本体的构建,确定本体领域为航空发动机故障领域,最终构建一个具有实用性、共通性的故障知识本体模型,如图1所示。




图1 航空发动机本体构建示意图

2 实体识别模型

实体识别是构建知识图谱的核心任务,航空发动机故障知识文本是大量实体的有机组合,实体识别任务就是将文本中的具体实体按照定义的本体类型进行识别和标注。航空发动机故障实体识别是知识抽取模型的基础,实体识别的具体效果将对知识图谱的构建质量起到至关重要的作用。

本文改进 BERT-BiLSTM-CRF 模型,提出一种基于双向长短期记忆神经网络和条件随机场的识别算法,同时通过加入自注意力机制来实现实体识别任务,航空发动机故障实体识别模型如图2所示。




图2 航空发动机故障诊断实体识别模型

2.1 BERT 模型

BERT 在自然语言处理方面具有很强的语义表征优势,在文本输入之后采用 BERT 进行训练,产生词向量,获取语境化的词向量从而提高实体识别的性能。BERT 模型首先对文本进行处理形成单个字符及词向量的形式,然后将词向量输入到双向 Transform 中;最后输出具有语义特征的向量。Transformer 编码器主要任务是获得序列内部的关系权重,解决长距离依赖和并行计算的问题。

2.2 BiLSTM 模型

LSTM 是一种特殊的循环神经网络(RNN),与 RNN 相比 LSTM 采用了巧妙的门设计,避免了梯度爆炸和解决了长期依赖问题,LSTM 的结构如图 3 所示。




图 3 LSTM 结构

LSTM 包含了输入门、输出门以及遗忘门,输入门决定保留何种信息并更新到单元状态,遗忘门决定遗忘何种信息,输出门决定输出何种信息。记忆单元通过学习 3 个门的参数来管理和保存信息,使有用信息不至于在长序列中被遗忘。遗忘门信息 f_t 如式(1)所示。

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (1)$$

式中: σ 为激活 sigmoid 函数; W_f 为遗忘门权重系数矩阵; h_{t-1} 为 $t-1$ 时刻的输出; x_t 为 t 时刻的输入; b_f 为遗忘门的偏置向量。

输入门及其状态如式(2)和式(3)所示。

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (2)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (3)$$

式中: i_t 为输入门; W_i 为输入门权重系数矩阵; b_i 为输入门的偏置向量; $\tilde{C}_t$ 为 t 时刻的状态; W_c 为记忆单元的权重系数矩阵; b_c 为记忆单元的偏置向量。

记忆单元状态 C_t 的计算公式如式(4)所示。

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$

式中 $*$ 为向量元素的乘积。

输出门 O_t 和 t 时刻隐藏层状态公式如式(5)和式(6)所示。

$$O_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = O_t * \tanh(C_t) \quad (6)$$

式中: W_o 为输出门的权重矩阵; b_o 为输出门的偏置向量。

BiLSTM 模型是由两个独立的长短期记忆网络(LSTM)模型组合而成,一个去正向处理序列,

一个去反向处理。通过 BiLSTM 模型对每个句子采用顺序和逆序计算得到两套不同的隐层表示,然后通过向量拼接得到最终的隐层表示,如式(7)所示。序列处理完后,两个 LSTM 的输出拼接起来形成的词向量作为该词的最终特征表达, BiLSTM 神经网络模型用于解决序列无法联系上下文问题。

$$h_t = [\vec{h}_t, \overleftarrow{h}_t] \quad (7)$$

式中左、右箭头为两个方向的隐层状态。

2.3 注意力机制 (Attention)

文本信息经 BiLSTM 层之后,虽然获取了深层的上下文特征,提高了模型对序列语义结构的理解,但是缺乏实体关键信息,且编码成的隐向量具有相同的权重,因此进一步区分特征,提取关键信息很有必要。本文引入注意力机制,来弥补模型的准确性损失,注意力机制只在序列内部完成注意力计算,寻找序列内部联系。

对于给定的 T 作为 BiLSTM 的特征输出序列,注意力机制首先将 T 通过线性变换投影至 3 组向量矩阵 Q 、 K 和 V :

$$Q = W_Q T \quad (8)$$

$$K = W_K T \quad (9)$$

$$V = W_V T \quad (10)$$

式中 W_Q 、 W_K 、 W_V 为模型训练随机初始化的权重矩阵。

注意力机制的计算如下:

$$s_{\text{self-att}}(Q, K, V) = \text{SoftMax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (11)$$

式中 d_k 为键向量维度。

2.4 CRF 模型

经 BERT、BiLSTM、Attention 可以确定最终的结果,由于 Attention 的输出不能有效地预测前后两个标签之间的关系,即特征之间的相关性,输出结果相互之间没有被约束,其预测结果可能是无效的。CRF 层通过相邻标签之间的依赖关系获得全局最优标签序列,并对最终预测的标签添加如下约束,确保输出结果的合理性。

3 实体识别实验

本文所建立的航空发动机故障实体数据集来源于某厂维修手册、部分文献、航空发动机故障相关书籍以及航空发动机系统运行参考书等。实体识别领域的衡量采用精确率(P)、召回率(R)和 $F_1(F_{1-\text{Score}})$ 作为评估指标其计算方法如下:

$$P = \frac{T_p}{T_p + F_p} \times 100\% \quad (12)$$

$$R = \frac{T_p}{T_p + F_N} \times 100\% \quad (13)$$

$$F_1 = \frac{2P \times R}{P + R} \times 100\% \quad (14)$$

式中: T_p 表示正确个数; F_p 表示假的个数; F_N 表示未识别到相关正确实体的个数。

本节将所提出 BERT-BiLSTM-Attention-CRF 实体识别模型在航空发动机故障数据集上的实验结果与近些年的实体识别方法作为比较, 比较结果如表 1 所示。

表 1 不同实体识别模型实验结果

模型	精确率	召回率	F_1
IDCNN-CRF	0.825 0	0.833 8	0.829 4
LatticeLSTM	0.863 3	0.852 2	0.857 7
LRCNN-CRF	0.878 8	0.859 3	0.869 1
BERT-BiLSTM-Attention-CRF	0.893 2	0.873 1	0.883 0

结合表 1 可以看出: 相对于其他模型本文所使用的 BERT-BiLSTM-Attention-CRF 模型性能

有了大幅度的提高, F_1 高达 0.883 0。其中, Lattice LSTM 通过 Lattice 增加输入信息引入词、字符、词序信息的模型, 同时利用过门控单元, 将与当前字符匹配的所有词汇信息融入到原 LSTM 模型。LRCNN 模型采用卷积神经网络提升了模型的运行速度, 虽然使用注意力机制和 rethink 机制降低了潜在词权重, 但错误的潜在词权重累积也会影响识别效果。

4 知识图谱构建及可视化应用

第 2 节的实体识别模型, 经实验验证可以对航空发动机故障领域中的实体进行识别, 得到的实体需要匹配实体关系。本文对故障事件语料进行分析, 发现故障语料句法格式较为固定, 针对不同的故障和对应的诊断模式, 固定的句式结构和关键词等可以辅助关系匹配, 从而构成知识三元组。对于航空发动机故障领域知识三元组, 本文采用 Neo4j 图数据库存储航空发动机的故障知识, 初步建立了故障知识图谱。图 4 显示了知识图谱的一部分, 相同类型实体对应的节点颜色一致(本刊黑白印刷, 如有疑问请咨询作者)。




图 4 航空发动机故障诊断知识图谱可视化

基于航空发动机故障诊断知识图谱, 构建航空发动机智能问答系统, 当航空发动机发生故障时, 用户根据故障信息利用实体识别对故障信息进行识别, 帮助用户快速查询, 并辅助维修人员决策从而高效定制维修计划。

5 结语

航空发动机故障诊断知识图谱能够可视化航空发动机故障的经验知识, 能改变现有故障诊断

方法无法利用过去积累的航空发动机故障诊断专家知识的现象。本文基于航空发动机故障诊断事件描述文本, 提出了 BERT-BiLSTM-Attention-CRF 的实体识别模型, 基于此实体识别模型提出了一种航空发动机故障诊断知识图谱的构建方法, 并通过构建智能问答系统实现航空发动机故障智能处理。

1) 构建航空发动机故障诊断知识本体, 并根据本体定义实体和关系类别, 形成实体标记数据集。

2) 提出航空发动机故障诊断实体识别模型, 利用 BiLSTM 获取文本深层上下文特征, 引入自注意力机制获取文本关键信息。实验表明, 该模型与近些年模型相比可以提高实体识别效果。

3) 根据识别的实体类别匹配关系, 形成知识三元组, 建立了故障诊断知识图谱, 实现知识结构化储存、查询等, 构建航空发动机故障诊断智能问答系统, 并能够快速响应问题, 为智能诊断提供知识支持。

参考文献:

- [1] 李少尘, 陈敏, 胡金涛, 等. 航空燃气涡轮发动机气路故障诊断进展[J]. 航空发动机, 2022, 48(2): 33-49.
- [2] 李续博, 王文庆, 王凯, 等. 人工智能技术在航空发动机孔探检测中的应用进展[J]. 航空工程进展, 2023, 14(2): 12-23.
- [3] 王启航, 黄金泉, 鲁峰. 基于变分贝叶斯粒子滤波的航空发动机气路故障诊断方法[J]. 机械制造与自动化, 2022, 51(2): 181-185.
- [4] 高龙, 卫青延, 陶剑, 等. 事理图谱赋能的航空数据智能技术研究[J]. 航空工程进展, 2023, 14(2): 178-190.
- [5] 侯中妮, 靳小龙, 陈剑赟, 等. 知识图谱可解释推理研究综述[J]. 软件学报, 2022, 33(12): 4644-4667.
- [6] 周杰. 基于仿射变换的知识图谱嵌入技术研究与应用[D]. 上海: 华东师范大学, 2022.
- [7] 韩涛, 黄海松, 姚立国. 面向航空发动机故障知识图谱构建的实体抽取[J]. 组合机床与自动化加工技术, 2021(10): 69-73, 78.
- [8] 吴闯, 张亮, 唐希浪, 等. 航空发动机润滑系统故障知识图谱构建及应用[J]. 北京航空航天大学学报, 2024, 50(4): 1336-1346.
- [9] 全威, 马志柔, 刘杰, 等. 基于医疗知识图谱的交互式智能导诊系统[J]. 计算机系统应用, 2021, 30(12): 55-62.
- [10] 高仰, 刘渊. 融合社交关系和知识图谱的推荐算法[J]. 计算机科学与探索, 2023, 17(1): 238-250.
- [11] 许智宏, 于子琪, 董永峰, 等. 影评情感分析知识图谱构建研究[J]. 计算机仿真, 2020, 37(8): 424-430.
- [12] 胡杰, 李源洁, 耿骥, 等. 基于深度学习的汽车故障知识图谱构建[J]. 汽车工程, 2023, 45(1): 52-60, 85.
- [13] MENG F Q, YANG S S, WANG J D, et al. Creating knowledge graph of electric power equipment faults based on BERT-BiLSTM-CRF model[J]. Journal of Electrical Engineering & Technology, 2022, 17(4): 2507-2516.
- [14] WANG X, GAN Z R, XU Y X, et al. Extracting domain-specific Chinese named entities for aviation safety reports: a case study[J]. Applied Sciences, 2023, 13(19): 11003.
- [15] STRUBELL E, VERGA P, BELANGER D, et al. Fast and accurate entity recognition with iterated dilated convolutions[C]//Proceedings of the 2017 Conference on Empirical Methods in Natural Language Processing. Copenhagen, Denmark. Stroudsburg, PA: USAACL, 2017: 2670-2680.
- [16] 韩涛. 面向航空发动机设计的知识图谱关键构建技术研究[D]. 贵阳: 贵州大学, 2021.
- [17] GUI T, MA R T, ZHANG Q, et al. CNN-based Chinese NER with lexicon rethinking[C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. Macao, China: International Joint Conferences on Artificial Intelligence Organization, 2019: 4982-4988.

收稿日期: 2023-11-17