

引文格式: 刘国良, 高悦娴, 商建航, 等. 基于多头注意力和整词约束的飞机维修知识图谱构建技术研究[J]. 航空制造技术, 2026, 69(7): 25010072.

LIU Guoliang, GAO Yuexian, SHANG Jianhang, et al. Research on aircraft maintenance knowledge graph construction technology based on multi-head attention and full-token masking[J]. Aeronautical Manufacturing Technology, 2026, 69(7): 25010072.

# 基于多头注意力和整词约束的飞机维修知识图谱构建技术研究

刘国良<sup>1</sup>, 高悦娴<sup>1</sup>, 商建航<sup>1</sup>, 许苏璠<sup>1</sup>, 张二虎<sup>2</sup>, 黄 准<sup>2</sup>, 杨朝栋<sup>2</sup>, 宋溪林<sup>2</sup>

(1. 山东大学, 济南 250061;

2. 中国飞行试验研究院, 西安 710089)

[摘要] 针对飞机维修手册中存在的专业术语繁多、短文本泛化能力弱、中英文混杂及数据规模庞大等问题, 本文提出一种融合多头注意力机制与整词约束策略的知识抽取与知识图谱构建方法。首先, 设计 CoBiTex-FTM (Contextual bidirectional text encoder with full-token masking) 模型进行命名实体识别, 通过多头注意力机制强化上下文建模能力, 并引入基于词边界识别的整词约束算法以解决中英文混合识别问题。其次, 构建 BiHAM-FTM (Bidirectional LSTM & multi-head attention with full-token masking) 关系抽取模型完成“实体-关系-实体”三元组提取。最后, 基于 Neo4j 平台开发飞机维修知识图谱系统, 实现维修数据的有效存储与可视化呈现。为验证方法有效性, 构建飞机维修知识抽取数据集并进行对比与消融试验。结果表明, CoBiTex-FTM 模型 F1 值达 95.16%, BiHAM-FTM 模型 F1 值达 90.74%, 验证了该方法在复杂专业领域知识抽取中的适应性, 尤其在中英文混杂和短文本场景下展现出更高准确性。关键词: 飞机智能维修; 知识图谱; 实体命名识别; 关系抽取; 注意力机制

中图分类号: V267+4

文献标志码: A

DOI: 10.16080/j.issn1671-833x.25010072

## Research on Aircraft Maintenance Knowledge Graph Construction Technology Based on Multi-Head Attention and Full-Token Masking

LIU Guoliang<sup>1</sup>, GAO Yuexian<sup>1</sup>, SHANG Jianhang<sup>1</sup>, XU Sufan<sup>1</sup>, ZHANG Erhu<sup>2</sup>, HUANG Zhun<sup>2</sup>,  
YANG Chaodong<sup>2</sup>, SONG Xilin<sup>2</sup>

(1. Shandong University, Jinan 250061, China;

2. China Flight Test Establishment, Xi'an 710089, China)

[ABSTRACT] To address the challenges posed by professional terminology, short texts, large data volumes, and mixed Chinese-English content in aircraft maintenance manuals, this paper proposes a knowledge extraction and knowledge graph construction method based on multi-head attention and full-token masking. First, we design the CoBiTex-FTM (Contextual bidirectional text encoder with full-token masking) model for named entity recognition, which enhances contextual modeling through multi-head attention and ensures label consistency via a whole-word constraint algorithm tailored for mixed-language scenarios. Second, we construct the BiHAM-FTM (Bidirectional LSTM & multi-head attention with full-token masking) model to extract “entity-relation-entity” triples. Finally, an aircraft maintenance knowledge graph system is implemented using Neo4j for structured storage and visual representation of maintenance knowledge. To validate

收稿日期: 2025-05-13; 退修日期: 2025-08-04; 录用日期: 2025-08-20

基金项目: 山东省自然科学基金重大基础研究项目(ZR2025ZD32); 中华全国总工会职工创新补助资金项目(2022270024); 山东大学仪器设备自研自制项目(ZY20250303); 山东省自然科学基金(ZR2024MF085); 山东省泰山学者工程(TSQN202211010)

通信作者: 刘国良, 教授, 博士, 研究方向为智能机器人、模式识别与图像处理、航空器外观缺陷检测、混合现实维修引导。

the approach, we build a domain-specific dataset and conduct comparative and ablation experiments. Experimental results show that CoBiTex-FTM achieves an F1 score of 95.16%, while BiHAM-FTM reaches 90.74%, demonstrating superior performance in complex, multilingual, and short-text environments.

**Keywords:** Aircraft intelligent maintenance; Knowledge graph; Named entity recognition; Relation extraction; Attention mechanism

近年来,随着我国航空产业的快速发展,飞机维修领域作为保障飞行安全与运营效率的核心环节,受到越来越多的关注<sup>[1]</sup>。当前飞机维修手册(Aircraft maintenance manual, AMM)是机务维修人员的主要参考资料,航空公司和维修单位通过针对特定机型编写维修手册,通过标准化排故和维修流程支持飞机维护工作,然而这种维护作业模式依赖人工操作,不仅流程繁琐、耗时较长,还导致工作效率显著下降。

飞机维修手册涉及的专业知识和术语较多,中英文混杂,语言生硬,查询不便<sup>[2]</sup>等问题,尽管许多航空公司和维修单位设有专业部门处理维修手册与任务工卡,但编写者与机务维修人员之间的认知偏差进一步降低了使用效率。以飞机维修操作语句“测试防冰系统 AIS-33 的压力和温度,使用压力表 PGM-100 和温度计 THM-500”为例,该语句中既包含中文字符,也包含英文字符,所需提取的多个关键实体也是以中英文混合的形式存在于飞机维修操作语句中,如设备类实体“防冰系统 AIS-33”、工具类实体“压力表 PGM-100”、“温度计 THM-500”,以及动作类实体“测试”。传统命名实体识别方法在处理这类中英文混杂、短文本、专业术语密集的语句时,往往面临以下问题:一是由于子词切分不一致导致标签分配错误;二是短文本缺乏上下文支撑,难以准确识别实体边界;三是实体间关系模糊,影响后续知识建模效果。因此,在实际应用中,飞机维修手册中信息的提取与筛选仍主要依赖人工完成,难以满足高效查阅和智能分析的需求。

知识图谱的概念最早可追溯至 2012 年谷歌推出的知识图谱体系<sup>[3]</sup>。通过构建语义网络知识库,显著提升了搜索引擎的语义理解能力,使搜索结果能更精准地匹配用户需求<sup>[4]</sup>。相较于传统关系型数据库,知识图谱的核心构成要素为:实体作为节点,语义关系作为边,能够通过将复杂文本简化为“实体-关系-实体”三元组,共同构建具有明确语义关联的网络,提升信息检索效率。

知识抽取是图谱构建过程的核心环节,当前主流的抽取方法包括隐马尔可夫模型(Hidden markov model, HMM)<sup>[5]</sup>、条件随机场(Conditional random field, CRF)<sup>[6]</sup>,以及双向长短期记忆网络(Bidirectional long short-term

memory, BiLSTM)<sup>[7]</sup>等。其中, HMM 因其高效性广泛应用于基础场景,但对复杂语义建模能力不足。CRF 在上下文依赖强的任务中表现优越,但计算复杂度随数据量增加急剧上升。BiLSTM 在语义提取上效果显著,但在短文本处理中可能因参数与训练样本不匹配而过拟合。

命名实体识别(Named entity recognition, NER)技术在自然语言处理(Natural language processing, NLP)领域有着广泛的应用,包括信息抽取、问答系统和语义理解等方面,能够帮助计算机理解文本中的实体信息,从而更好地进行后续分析与处理。近年来,深度神经网络在多个应用领域取得了显著进展。Qiu 等<sup>[8]</sup>构建了一个专用于地质 NER 的数据集,并基于 BiLSTM-CRF 模型从地质报告中高效提取地球科学实体。Liu 等<sup>[9]</sup>提出了 WC-LSTM 模型,通过将基于字符的模型与各种词编码策略结合,将词汇级信息融入模型中,从而支持多种应用。BERT(Bidirectional encoder representations from transformers)<sup>[10]</sup>和 RoBERTa<sup>[11]</sup>等预训练模型的引入进一步推动了知识抽取任务的发展。然而,中文 NER 任务的文本数据多以纯中文为主,在中英文混杂的飞机维修场景中,现有方法的优势并不显著。关系抽取(Relation extraction, RE)对知识图谱的质量和可用性起着至关重要的作用。当前研究普遍采用管道式机制,通过命名实体识别与关系分类的串行处理实现知识关联建模。如基于双向长短期记忆神经网络和条件随机场来捕捉语句中的句法和语义信息的 BiLSTM-CRF 模型在 RE 任务上彰显了一定优势,但由于存在误差累积问题,无法解决三元组嵌套的问题,且对深层次语义的理解仍有不足。

基于深度学习的关系抽取方法已成功应用于多个领域,如法律文本<sup>[12]</sup>、地质<sup>[13]</sup>、旅游<sup>[14]</sup>和中医<sup>[15]</sup>等。例如,李涛等<sup>[16]</sup>提出了一种结合对抗主动学习的网络安全知识三元组抽取方法,在试验中表现出较高的性能。程顺航等<sup>[17]</sup>提出了一种改进自举与语义标注结合的飞机维修关系抽取算法,在小样本数据集上表现优异。尽管当前主流的关系抽取模型效果出色,然而,在面对实体种类丰富、中英文数字混杂、结构较复杂的飞机维修领域数据时,直接采用主流模型进行关系抽取任

务仍会面临语义信息利用不充分、实体边界及类型识别错误等问题,从而导致模型准确率降低。因此,亟须研究更有效的算法来提升飞机维修任务中关系抽取任务的性能。

本项目基于前期预研攻关成果,面向航空维修领域对数字化、智能化维修工具的迫切需求,提出了一种面向飞机维修手册的知识图谱构建方法。首先,针对维修手册中短文本、大数据量、中英文混杂的特点,基于BERT-BiLSTM模型进行了改进,引入了多头注意力机制并设计整词约束算法(Full-token masking, FTM),构建了CoBiTex-FTM(Contextual bidirectional text encoder with full-token masking)命名实体识别模型,用于从维修手册中提取实体信息。其次,设计基于BiLSTM的关系抽取模型BiHAM-FTM(Bidirectional LSTM & multi-head attention with full-token masking),根据命名实体识别结果,抽取“实体-关系-实体”三元组,完成知识图谱的核心数据构建。通过利用Neo4j平台实现图数据库的构建,进一步构建了面向飞机维修的知识图谱系统,有效打通维修手册数据壁垒,生成可视化的维修指导信息,后期可将其推广部署于手持显示终端与混合现实头戴设备上,实现维修过程的实时提示与步骤引导,提升维修工作的智能化水平与执行效率。

## 1 模型与方法

### 1.1 基于CoBiTex-FTM的命名实体识别算法研究

针对飞机维修手册中的非结构化、短文本、大数据量及中英文混杂等文本特点,本文提出了一种改进的命名实体识别模型CoBiTex-FTM,基于BERT-BiLSTM框架,进一步引入多头注意力机制和整词约束算法。多头注意力机制能够在不同的注意力子空间中捕获文本中

复杂的语义关联,增强模型对实体上下文的敏感性;整词约束算法通过识别实体的词边界,确保子词层级的标签一致性,从而提高识别准确率,尤其在飞机维修领域的中英文混杂场景下表现出色。该模型不仅有效缓解了短文本的过拟合问题,还显著提升了大规模数据的抽取效率。

CoBiTex-FTM模型的核心层包括BERT预训练模型层、BiLSTM层、多头注意力机制层和词边界识别的整词约束算法层,CoBiTex-FTM的模型结构如图1所示。

(1)BERT层。BERT是一种基于Transformer架构的预训练深度学习模型,由Devlin等<sup>[18]</sup>于2018年提出。依托其强大的语义表示能力和双向训练机制,BERT能够全面捕捉上下文语义信息,在多义词处理和远程依赖建模方面具有显著优势。该模型输入表示由词嵌入、段嵌入和位置嵌入组成,输入与嵌入表示如图2所示,可表示为

$$M = M^T + M^S + M^P \quad (1)$$

式中, $M^T$ 表示词嵌入; $M^S$ 表示段嵌入; $M^P$ 表示位置嵌入。输入序列以特殊标记[CLS]和[SEP]区分句子边界,编码形式为[CLS],  $token_1, token_2, \dots, token_n, [SEP]$ 。

BERT在训练中使用层归一化、残差连接和高斯误差线性单元(GELU)优化技术,提升了模型的训练稳定性和表达性能。在本模型中,BERT层利用预训练语言模型,通过多头自注意力机制为输入句子生成深层语义表示,特别适合处理飞机维修手册中的复杂术语和命名实体识别任务。

(2)BiLSTM层。双向长短期记忆网络是循环神经网络(Recurrent neural network, RNN)的扩展形式,在处理序列数据时表现优异,特别是在捕获长距离依赖关系方面具有明显优势,通过引入门控机制(Gate mechanism),有效解决了长序列中的梯度消失问题。

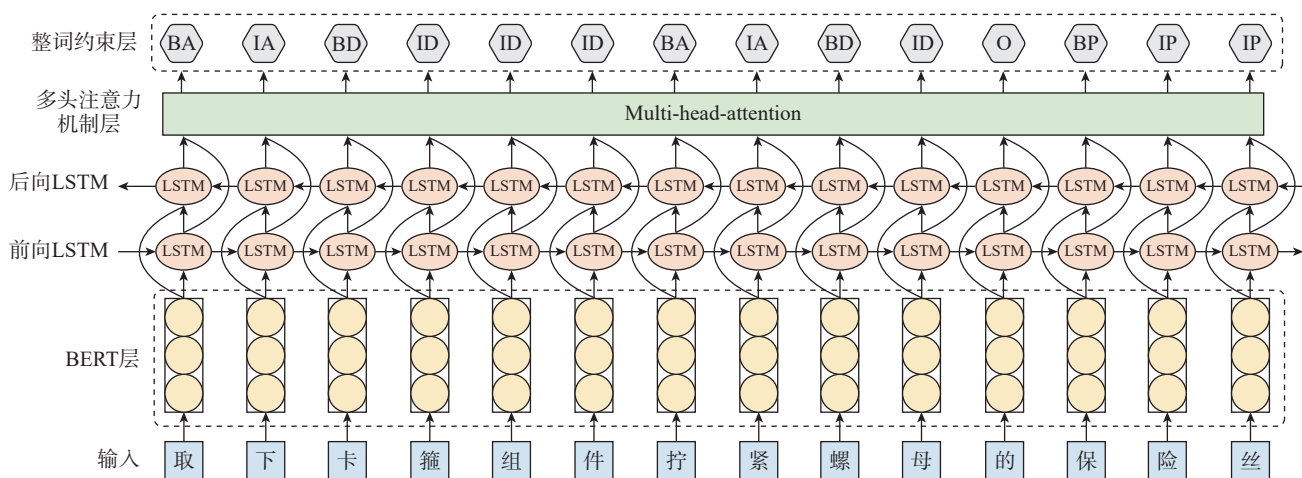


图1 CoBiTex-FTM模型结构  
Fig.1 CoBiTex-FTM model structure

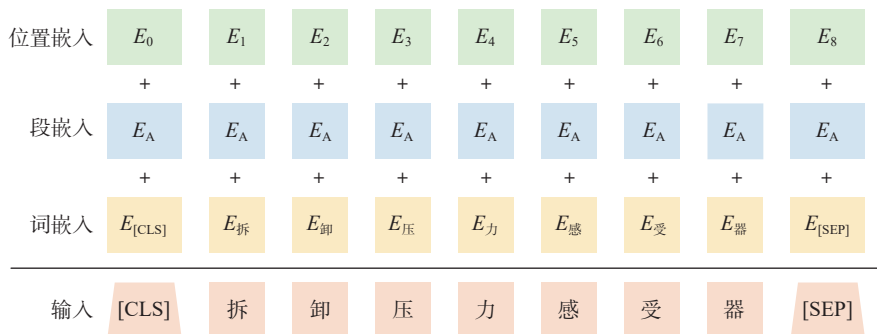


图2 BERT 模型的输入与嵌入表示示意图

Fig.2 Input and embedding representation diagram of the BERT model

BiLSTM 则通过结合两个方向的 LSTM 网络,一个用于正向序列,另一个用于反向序列,从而拥有同时提取前向和后向的上下文信息的能力。

对于输入序列  $X=(x_1, x_2, \dots, x_n)$ , BiLSTM 分别对原始序列  $X$  和其反向序列  $X'=(x_n, x_{n-1}, \dots, x_1)$  应用 LSTM 网络,其中,  $x_i$  表示第  $i$  个时间步的输入特征。正向和反向 LSTM 生成隐藏状态序列可分别表示为

$$\vec{H}=(\vec{h}_1, \vec{h}_2, \dots, \vec{h}_n) \quad (2)$$

$$\overleftarrow{H}=(\overleftarrow{h}_1, \overleftarrow{h}_2, \dots, \overleftarrow{h}_n) \quad (3)$$

在每个时间步  $t$ , BiLSTM 的输出  $h_t$  由正向隐藏状态  $\vec{h}_t$  与反向隐藏状态  $\overleftarrow{h}_t$  拼接而成,即

$$h_t=[\vec{h}_t; \overleftarrow{h}_t] \quad (4)$$

BiLSTM 层接收来自 BERT 的上下文词嵌入向量,并在此基础上进行序列化处理,生成包含全局上下文的词表示。通过双向结构, BiLSTM 能够在短文本中有效捕捉长距离依赖,增强对复杂语义和实体边界的建模能力。

(3) 多头注意力机制层。多头注意力机制能够提升模型捕捉不同位置语义和获取丰富上下文信息的能力,通过将注意力分割为多个头,多头注意力机制支持在不同的表示子空间上并行学习,从而使模型能够同时聚焦于多种位置上下文。每个头独立地执行缩放点积注意力 (Scaled dot-product attention),然后将其输出并通过拼接和线性变换进行整合,缩放点积注意力的计算公式为

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{soft max} \left( \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} \right) \mathbf{V} \quad (5)$$

式中,  $\mathbf{Q}$ 、 $\mathbf{K}$  和  $\mathbf{V}$  分别表示查询、键和值的矩阵,这些矩阵是通过对输入向量进行独立线性变换得到的;  $d_k$  表示键向量的维度,用于对点积进行缩放以避免值过大,从而避免 softmax 函数输出过于稀疏的梯度; softmax 函数将点积结果转化为概率分布,有效衡量各值的重要性。在多头注意力机制框架下,每个头独立地对输入数据进行线性变换,生成各自的  $\mathbf{Q}$ 、 $\mathbf{K}$  和  $\mathbf{V}$  矩阵,最终输出为所有头的拼接结果,通过线性变换整合。多头注意力

机制结构如图 3 所示。其中, FC 表示全连接层,用于对输入的内容进行线性变换; Attention 表示缩放点积注意力的计算; Concat 表示对各个注意力计算结果进行拼接。

BiLSTM 相较于传统循环神经网络,改善了长距离依赖建模,但在处理超长序列时可能遗忘早期信息,影响词边界识别。多头注意力机制部署在 BiLSTM 输出后,能够整合不同子空间的信息,增强依赖建模,从而提高实体边界和类型识别效果。在中文 NER 任务中,结合多头注意力机制能进一步提升序列特征处理能力,尤其在处理嵌套结构和复杂实体边界时,优化了局部与全局信息的平衡,提升了识别准确性。

(4) 基于整词约束的词边界识别。整词约束算法是本模型的关键组成部分,其设计旨在确保同一词内的所有子词单元具有一致的标签。这一机制通过精确识别词边界,不仅显著提高了命名实体识别的准确性,而且也减少了由于同一个词被拆分为多个同等含义的子词而带来的实体对齐困难等问题。其模型结构示意图如图 4 所示。

在预处理阶段,词边界  $B$  被识别为一组索引对,每对索引对应序列中一个词的起始和终止位置。对于词序列  $W=\{w_1, w_2, \dots, w_N\}$ ,词边界集合定义为

$$B=\{(s_1, e_1), (s_2, e_2), \dots, (s_M, e_M)\} \quad (6)$$

式中,  $s_i$  和  $e_i$  分别表示第  $i$  个词的起始和终止索引。为

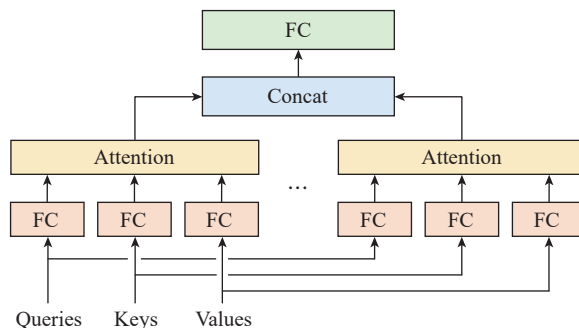


图3 多头注意力机制结构示意图

Fig.3 Diagram of multi-head attention mechanism structure

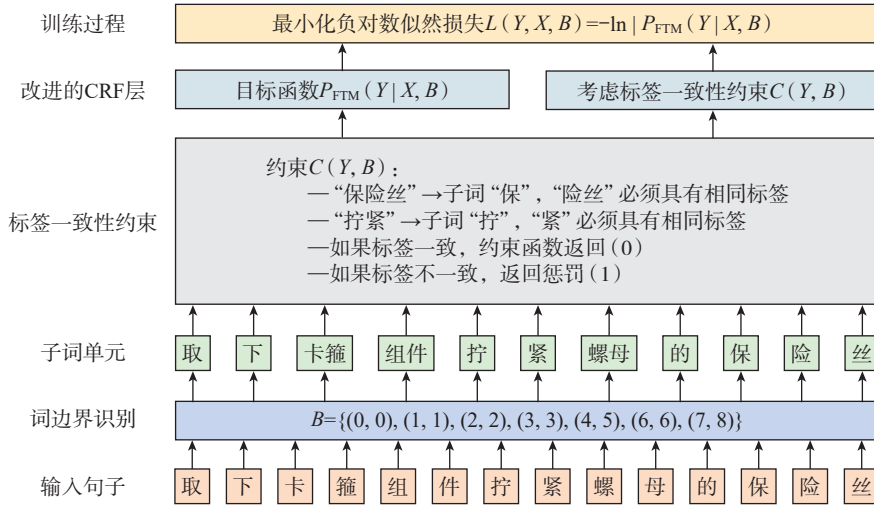


图4 基于整词约束的词边界识别结构示意图

Fig.4 Structure diagram of word boundary recognition based on full-token masking

了保证同一词内的子词标签一致性,算法在模型中引入了约束项  $C(Y, B)$ ,用以惩罚定义的词边界内标签不一致的情况。

$$C(Y, B) = -\lambda \sum_{(s,e) \in B} \mathbb{1}(\text{inconsistent tags between } s \text{ and } e) \quad (7)$$

式中,  $\lambda$  是一个可调的正惩罚系数,用于调节标签不一致的惩罚强度;  $\mathbb{1}$  是指示函数,当词内标签不一致时返回 1,否则返回 0。为了进一步明确,指示函数  $\mathbb{1}$  对任意子词段  $[s, e]$  的定义为

$$\mathbb{1}(\text{inconsistent tage between } s \text{ and } e) = \begin{cases} 0 & \text{若 } [s, e] \text{ 内所有标签一致} \\ 1 & \text{否则} \end{cases} \quad (8)$$

引入该约束后,模型的目标函数旨在最大化修正后的条件概率  $P_{\text{FTM}}(Y|X, B)$ ,该条件概率融合了标签一致性约束,其公式表示为

$$P_{\text{FTM}}(Y|X, B) = \frac{1}{Z(X, B)} \exp\left(\sum_{i=1}^N \psi(y_{i-1}, y_i, X, i) + C(Y, B)\right) \quad (9)$$

式中,  $\psi(y_{i-1}, y_i, X, i)$  表示从标签  $y_{i-1}$  转移到  $y_i$  的特征函数分数,条件是观测序列为  $X$ ,位置为  $i$ ;  $Z(X, B)$  为归一化因子,确保所有可能标签序列的概率总和为 1。

通过引入整词约束,模型能够在子词级别对标签一致性施加强制要求,从而准确识别跨越多个子词单元的实体边界。特别是在处理复杂实体和中英文混杂文本时,该机制显著提高了 NER 任务的表现,形成了一个稳健的框架来提升模型的整体识别能力。

本节所提出的 CoBiTex-FTM 模型在设计过程中充分考虑了飞机维修手册中文本特征的特殊性。其中,多头注意力机制主要用于应对短文本中上下文信息缺失的问题。由于飞机维修操作描述通常较为简练,缺乏完整

的句法结构,传统的序列标注模型难以准确判断实体边界。而多头注意力机制能够在不同表示空间中并行建模,有效捕捉长距离语义依赖,从而提高模型对短文本中实体边界的识别能力。整词约束算法则是针对中英文混杂场景下子词切分不一致的问题而设计。BERT 等预训练模型通常采用子词分词方式,容易导致同一完整词汇被切分为多个子词单元,进而造成标签分配错误。通过引入基于词边界识别的整词约束策略,确保词汇内所有子词标签一致,显著提升了实体识别的准确性与稳定性。

综上, CoBiTex-FTM 模型通过上述两种技术手段的协同作用,有效解决了飞机维修手册中短文本、中英文混杂所带来的关键挑战,提高了知识抽取的整体性能。

### 1.2 基于 BiHAM-FTM 的关系抽取算法研究

作为构建知识图谱的关键步骤之一,关系提取对构建的知识图谱的质量和可用性有着重要的影响,现有方法基于模式匹配完成关系提取。然而,现有的关系提取方法增加了计算成本和传播误差,导致通用性差。基于上述问题,本节提出 BiHAM-FTM 模型,核心层包括 BiLSTM 层、多头注意力机制层和整词约束层,结构如图 5 所示。

(1) BiLSTM 编码层。在关系抽取任务中,输入文本序列  $X = (x_1, x_2, \dots, x_n)$  首先被映射为词嵌入序列  $E = (e_1, e_2, \dots, e_n)$ ,其中  $e_i$  表示第  $i$  个词的嵌入表示。为捕获文本的上下文信息,本文采用 BiLSTM 对输入序列进行编码。BiLSTM 结合正向和反向 LSTM,能够同时关注序列中每个词的上下文信息,生成包含全局语义的词级表示。BiLSTM 的双向处理机制有效捕获长距离依赖关系,解决了单向模型中的语义信息丢失问题。在处理复杂语法结构时能够关注词语之间的远程依赖和紧邻关系,生成适合关系抽取任务的表示。

(2)多头注意力机制层。在关系抽取任务中,为了捕捉复杂的词间依赖关系,尤其是长句中的远距离语义关联,在模型中引入多头注意力机制。通过并行化多个注意力头,从不同角度捕捉序列中关键语义单元的依赖关系,增强了模型对输入序列的建模能力。每个注意力头独立学习一个特定的注意力分布,使模型能够关注不同的语义子空间,从而提升捕捉复杂语义关系的能力。多头注意力机制能够有效处理长距离依赖,尤其在处理如飞机维修手册等领域文本时至关重要。在这些文本中,实体关系往往隐含在远距离的词语之间,机制通过并行建模输入序列的不同部分,有效挖掘深层次语义关联。

(3)整词约束层。在关系抽取任务中,整词约束用于确保同一词的字词单元共享一致的表示,从而避免因子词切分带来的信息分散问题。这种约束对于提升关系抽取模型的准确性和鲁棒性至关重要,尤其是在处理包含复杂词汇和长词的文本时,能够有效地保持词级别语义的一致性。同时,该约束也避免了由于子词切分带来的同一关系具有多种表述的问题,有利于关系融合。给定词边界信息  $B=\{(s_1, e_1), (s_2, e_2), \dots, (s_m, e_m)\}$ ,其中,  $s_i$  和  $e_i$  分别表示第  $i$  个词的起始和结束位置。基于这些词边界信息,可以对多头注意力机制的输出表示  $\tilde{H}=(\tilde{h}_1, \tilde{h}_2, \dots, \tilde{h}_n)$  进行处理,确保每个词的字词表示能够合并为一致的词级表示。对于每个词  $w_i$  (其对应的索引范围为  $s_i$  和  $e_i$ ),通过平均或求和的方式对其子词表示进行融合,从而得到该词的最终表示  $\hat{h}_i$ 。

$$\hat{h}_i = \frac{1}{e_i - s_i + 1} \sum_{t=s_i}^{e_i} \tilde{h}_t \quad (10)$$

通过上述操作,词  $w_i$  的子词单元表示被统一为  $\hat{h}_i$ ,从而保证了同一词的表示一致性,避免了因子词分割带来的语义偏差。在得到词级别的表示  $\hat{H}=(\hat{h}_1, \hat{h}_2, \dots, \hat{h}_m)$  后,将其输入到关系分类器中进行实体对之间关系的预测。对于每对实体  $(w_i, w_j)$ ,通过将其表示组合成一个

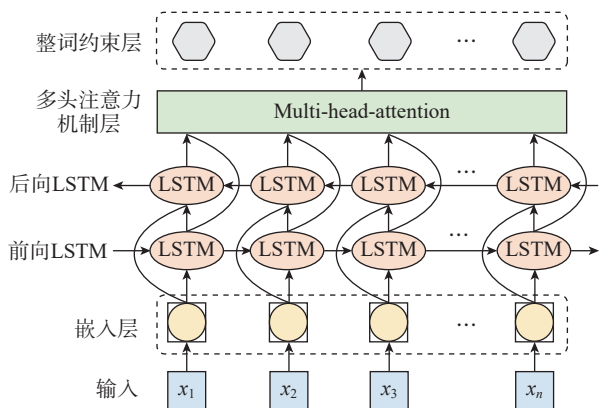


图5 BiHAM-FTM关系抽取模型结构  
Fig.5 BiHAM-FTM relation extraction model structure

新的特征向量  $r_{ij}$  作为分类器的输入,即

$$r_{ij}=[\hat{h}_i; \hat{h}_j; \hat{h}_i \odot \hat{h}_j; |\hat{h}_i - \hat{h}_j|] \quad (11)$$

式中,  $\odot$  表示元素乘积;  $|\cdot|$  表示元素绝对值。通过这种方式,算法不仅考虑了每个实体的单独表示,还引入了实体间交互信息和距离信息。

### 1.3 飞机维修知识图谱构建流程

知识图谱的架构通常从逻辑架构和技术架构两个视角进行划分。逻辑架构包括模式层和数据层,前者通过定义约束规则和关联逻辑实现知识的高度凝练,是知识图谱构建的核心,如图6所示;后者基于模式层框架将多源异构数据实例化为标准化的三元组形式存储,形成结构化的知识网络。针对飞机维修领域,知识图谱设计了本体层、数据层和存储层,结合飞机维修中的实际需求,在维修任务中给出相关的知识检索内容与具体操作步骤的提示,构建流程如图7所示。

图数据库作为知识图谱的主要存储平台,因其基于图论的技术特性,相较于关系型数据库具有显著优势。图数据库通过节点和关系的连接实现高效查询,其性能与目标节点的连接数量相关,而不依赖整体规模。此外,图数据库天然契合“实体-关系-实体”的三元组模型,支持直观的可视化展示,并提供灵活的数据操作能力。Neo4j<sup>[19]</sup> 作为主流图数据库,凭借其扩展性强、性能优越及成熟的生态,被选为本文飞机维修知识图谱的存储平台,用于实例化存储与可视化展示。

## 2 数据处理与评估指标

### 2.1 数据收集与处理

为了验证知识抽取模型在飞机维修任务手册中的

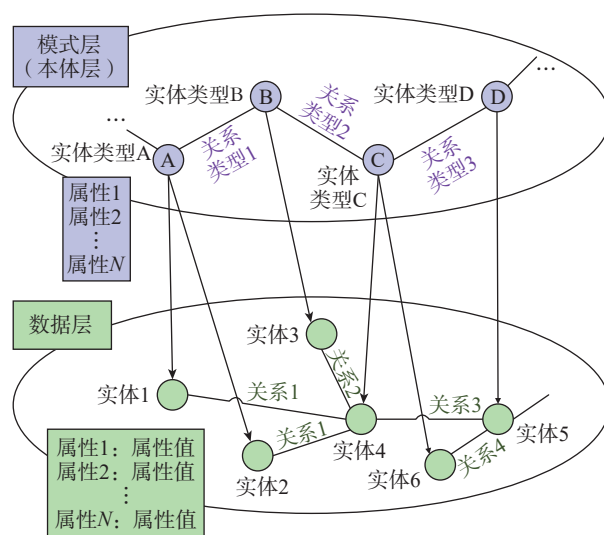


图6 基于逻辑的知识图谱架构示意图  
Fig.6 Schematic diagram of logic based knowledge graph architecture

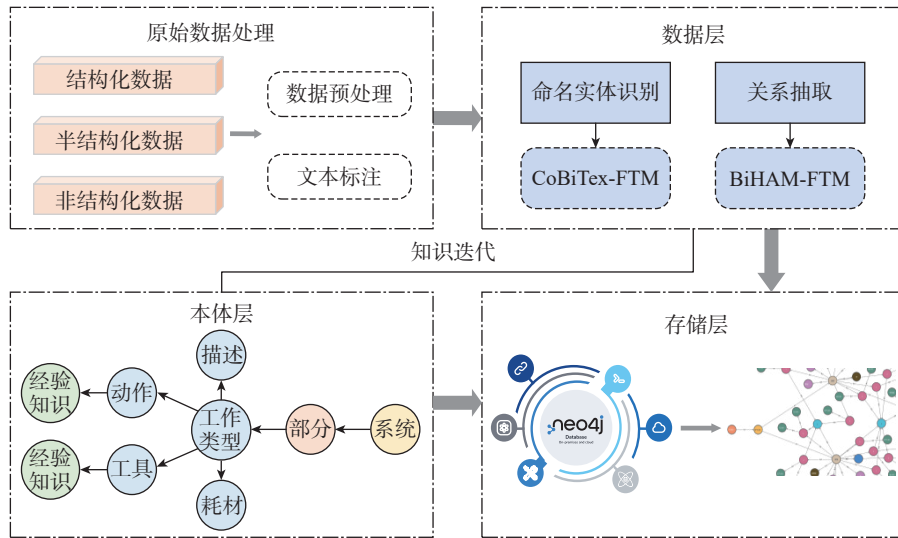


图7 飞机维修任务知识图谱构建流程图

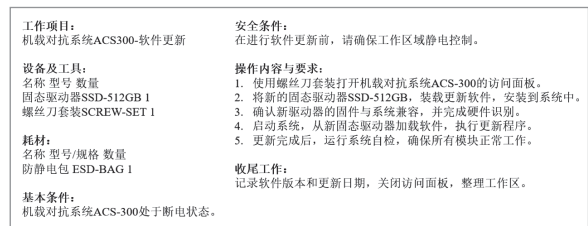
Fig.7 Flowchart of aircraft maintenance task knowledge graph construction

实际效果,本文使用的数据来源于国内某航空单位的一款特定机型维修操作手册,涵盖机械系统、动力装置系统、环境控制系统和热管理系统中“操作内容”与“要求”字段。共整理出4015条文本数据,约15万中英文字符,如图8(a)所示。这些数据具有非结构化、短文本、领域专用词汇多及中英文混杂等特点。例如,操作描述缺乏统一格式,可能以自由文本形式呈现;文本通常由简短语句构成,信息集中但上下文有限;包含大量航空专业术语(如“发动机引气管路”);且中英文标识混用(如“检查前设备舱座口盖 Abc012 的安装状态”)。

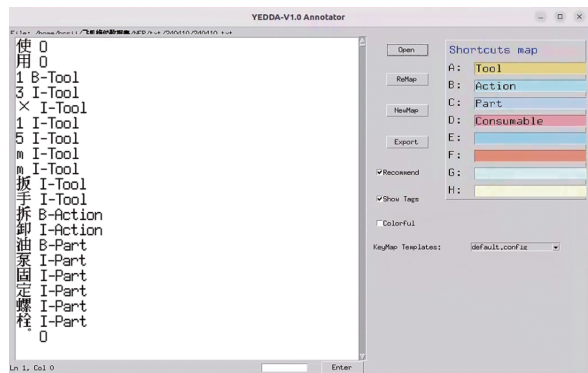
为提高数据质量并满足模型训练需求,本文对数据进行了以下处理:首先,进行文本清洗与停用词过滤,去除特殊符号、多余空格及无意义高频词,统一标点符号;其次,将分类整理的文本整合为统一集合以便后续分析;最后,对数据集进行随机化排序,避免模型训练过程中出现过拟合或泛化能力不足的问题。通过上述处理,清洗后的文本数据更为规范,减少了冗余信息,并提升了模型在不同类型数据上的适应性。

### 2.2 数据标注

通过数据预处理,本文借助标注工具 YEDDA 整理出包含 100527 字的高质量文本数据,如图 8(b)所示,并按照 8:1:1 的比例划分为训练集、验证集和测试集,以确保模型训练效果和评估可靠性。在此基础上,对所有数据进行人工标注,构建了包括 Action(动作)、Consumable(耗材)、Part(零件)、Tool(工具)4种实体类型的知识本体。标注采用 BIO(Begin-inside-outside)序列标记方法,明确实体在文本中的位置。其中,B表示实体起始位置;I表示中间部分;O表示非实体部分。标注形式如图9所示。



(a) 文本数据片段示例



(b) 标注工具 YEDDA 示例

图8 文本数据片段与标注工具 YEDDA 示例

Fig.8 Example of text data fragments and YEDDA labeling tools




图9 维修任务文本 BIO 标注示例

Fig.9 Example of BIO annotation maintenance task text

为挖掘实体间的内在联系,本文定义了9种关系类型,涵盖工作项目与设备、耗材、条件及操作步骤之间的交互关系。例如,USES\_TOOL(使用工具)、USES\_

CONSUMABLE (使用耗材)、HAS\_CONDITION (基本条件)、HAS\_SAFETY\_CONDITION (安全条件)、STEP\_USES\_TOOL (步骤使用工具)、STEP\_USES\_CONSUMABLE (步骤使用耗材)、STEP\_INVOLVES\_PART (操作涉及零件)、PERFORMS\_ACTION (步骤执行动作)、HAS\_FINAL\_STEP (最终操作步骤)。这些关系全面表征了工作项目中实体的依赖与关联,为知识图谱的构建奠定基础。标注采用 BRAT 标准格式,通过  $T<$ 实体 ID $>$  标注实体,  $R<$ 关系 ID $>$  标注关系,结构化且便于后续自动化处理与可视化分析。

### 2.3 评估指标

知识抽取模型的效果通常通过精确率 (Precision)、召回率 (Recall) 和 F1 分数 (F1-score) 进行评估。在知识抽取任务中, FP (False positive) 表示模型预测为某实体或某关系,但实际上不属于该类别的情况; FN (False negative) 表示模型未能识别出实际存在的实体或关系。这两个指标用于衡量模型的误检与漏检情况,是评估模型性能的重要依据。精确率衡量模型预测为正类样本中实际为正类的比例,反映识别的准确性,定义为真正例 (TP) 与预测正类样本总数 (TP+FP) 之比;召回率衡量模型检测出所有实际正类样本的能力,定义为真正例 (TP) 与实际正类样本总数 (TP+FN) 之比,越高则漏检越少。

F1 分数是精确率与召回率的调和平均值,综合两者表现,避免单一指标可能带来的偏差。这些指标的数学表达式为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \times 100\% \quad (12)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \times 100\% \quad (13)$$

$$\text{F1-score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \times 100\% \quad (14)$$

## 3 试验与分析

### 3.1 命名实体识别模型

试验平台的硬件配置如下: CPU 采用 Intel Core i7-12700K,运行内存 64 GB, GPU 为 NVIDIA GeForce RTX 3090 Ti (24 GB 显存),操作系统为 Ubuntu 22.04。试验使用的 BERT 模型网络层数为 12 层,隐藏层维度为 768,采用多头注意力机制,头的数量为 12,双向长短时记忆网络 (Bi-LSTM) 的隐藏层维度为 128。本试验所使用的数据集,是依据飞机维护手册的结构特点自主构建而成的。该数据集完整保留了飞机维修任务手册文本中英文混杂的固有特征。

为了验证 CoBiTex-FTM 命名实体识别模型在数据

集中抽取的效果,选取了以下命名实体识别模型进行对比试验。

(1) 大语言模型 GLM4-API。GLM-4 是一个大型预训练语言模型,具备强大的语言理解和生成能力。它通过大规模的文本数据进行训练,能够处理多种语言任务,如文本生成、摘要、翻译等。其 API 提供了对自然语言的高度理解和生成能力,能够在各种 NLP 应用中提供强有力的支持。

(2) 大语言模型 ChatGLM2-6B 的微调训练。ChatGLM2-6B 是一个中文对话大语言模型,采用了 6 B (60 亿) 参数,专注于中文文本的生成和理解。根据官方教程将本文构建的飞机维修命名实体识别数据集修改为对应 JSON 格式并进行 Fine Tuning 微调训练 (ChatGLM2-6B-FT)。

(3) HMM。隐马尔可夫模型是一种用于时间序列数据建模的统计模型,常用于序列标注任务,如词性标注或命名实体识别。HMM 假设系统的状态是隐含的,通过观察序列中的观测值来推断状态的转移。

(4) CRF。条件随机场是一种用于序列标注的概率模型,可以有效地建模序列中的依赖关系。与 HMM 不同,CRF 通过显式建模条件概率来学习标签之间的依赖关系,避免了 HMM 中的条件独立假设。

(5) BiLSTM-CRF。结合了双向长短期记忆网络和条件随机场, BiLSTM 通过双向递归神经网络捕捉输入序列的上下文信息,而 CRF 通过考虑标签之间的全局依赖关系,优化标签预测的准确性。

(6) BERT-BiLSTM-CRF。结合了 BERT 预训练模型和 BiLSTM-CRF。BERT 层通过预训练的上下文表示学习捕捉词汇的上下文信息,而 BiLSTM-CRF 层则负责序列标注和标签解码。BERT 的预训练表示提供了更为丰富的上下文信息,使得 BiLSTM-CRF 能够更好地理解词语之间的关系。

(7) CoBiTex-FTM。本文提出的模型,整合了 BERT 的上下文表示、BiLSTM 用于局部上下文建模、多头注意力机制用于全局关系建模,并结合整词约束进行标签解码。

将以上 7 种模型进行训练对比,通过调整 batch size、最大序列长度、丢弃单元 dropout 等超参数,进行大量试验,得到上述模型最好的 F1 分数,整理得到试验结果如图 10 所示,模型微调/训练时长对比如表 1 所示。

飞机维修任务手册文本具有的中英文混杂的特点会显著影响命名实体识别的准确性。从试验结果中能够看出, CoBiTex-FTM 模型在精确度、召回率和 F1 分数等评估指标上都显著超过了其他模型。特别是与 BERT-BiLSTM-CRF 模型相比, CoBiTex-FTM 模型的

F1 分数提升了 4.13 百分点。多头注意力机制通过在多个子空间中并行计算注意力,增强了模型对文本中复杂语义的敏感性,从而提高了命名实体识别的准确性。在面对中英文混合、短文本及大量领域专业术语时,CoBiTex-FTM 能够更好地捕捉语境信息和实体的边界。而整词约束算法则通过确保同一词内所有子词单元具有一致的标签,进一步减少了边界错误,从而提升了识别的精度,有效地解决了飞机维修数据集中中英文混合内容的词汇和句法差异问题。从试验结果中也反映出了本文所提出的命名实体提取方法更适用于对中英文混杂的短文本进行处理。

同时针对 CoBiTex-FTM 模型进行消融试验,与下述模型进行对比。

(1) BiLSTM-MHA-CRF。在 BiLSTM-CRF 的基础上进一步扩展,引入了多头注意力机制。

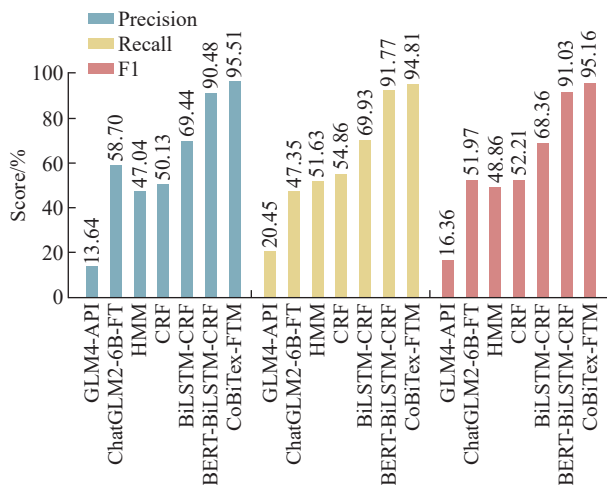


图 10 不同命名实体识别模型的分数比较

Fig.10 Comparison of scores for different name entity recognition models

表 1 模型微调/训练时长对比

Table 1 Comparison of model fine-tuning/training duration

模型名称	参数量 (Approx.)	训练轮次/轮	微调/训练时长/min
GLM4-API (API 调用)	N/A	0	0
ChatGLM2-6B	6B	300	2,973
HMM	无参数	20	175
CRF	无参数	20	204
BiLSTM-CRF	无显著参数	20	409
BERT-BiLSTM-CRF	1.1B	20	1,047
CoBiTex-FTM (本研究)	1.1B	20	1,108

(2) BiLSTM-MHA-FTM。在上述模型的基础上改进,添加本文提出的基于整词约束的词边界识别。

(3) BERT-BiLSTM-MHA-CRF。在BERT-BiLSTM-CRF 的基础上引入了多头注意力机制。

通过整理得到消融试验对比结果,如表 2 所示。其中,前 3 组是基于 BiLSTM 模型进行的改进,未使用预训练语言模型;后 3 组是基于 BERT-BiLSTM 模型进行的改进,使用了预训练语言模型 BERT。

表 2 的试验结果显示,添加多头注意力机制和整词约束后,模型性能得到了显著的提高。例如, BiLSTM-MHA-FTM 相比 BiLSTM-CRF,在 F1 分数上提升了约 10.11 个百分点,而 BERT-BiLSTM-CRF 到 CoBiTex-FTM 的改进也带来了 F1 分数的进一步提升。改进的关键在于多头注意力机制和整词约束算法的结合。多头注意力机制能够强化模型在长距离依赖上的建模能力,尤其是在处理复杂句法结构时,有效捕捉了跨越多个单词的语义关联。整词约束算法则确保了词边界的一致性,尤其在短文本和复杂专业词汇的处理上,大幅度减少了识别误差。

模型训练过程涉及迭代参数更新,通过分析训练轮次(最多 20 轮)与 6 个命名实体识别模型的 F1 分数之间的关系(图 11),可以看出,未使用 BERT 预训练组件的模型在初始阶段 F1 分数较低,但随着训练轮次的增加, F1 分数逐渐提升。相比之下,使用 BERT 预训练组件的模型在初始阶段 F1 分数较高,并且在较少的训练轮次内即可达到最佳性能。值得注意的是, CoBiTex-FTM 模型能够有效结合局部信息和全局信息,较其他模型表现出更快的收敛速度和更优的性能。

基于 CoBiTex-FTM 模型对飞机维修数据集进行命名实体识别,本文还对模型在各个实体类别的识别效果进行对比和分析,绘制了模型混淆矩阵图,如图 12 所示。

从混淆矩阵的分析结果来看,模型在“动作”实体类别上的表现最为优异,“B-动作”和“I-动作”的准确率

表 2 命名实体识别消融试验结果

Table 2 Ablation experiment results for named entity recognition

模型		精确率/%	召回率/%	F1 分数/%
未使用预训练模型	BiLSTM-CRF	69.44	69.93	68.36
	BiLSTM-MHA-CRF	74.81	75.69	74.91
	BiLSTM-MHA-FTM	88.91	78.21	78.47
使用预训练模型	BERT-BiLSTM-CRF	90.48	91.77	91.03
	BERT-BiLSTM-MHA-CRF	93.52	93.05	93.27
	CoBiTex-FTM	95.51	94.81	95.16

分别达到 90.21% 和 94.17%，这得益于动作类实体特征明显且数据量充足。相比之下，“耗材”类实体的表现较差，“B-耗材”和“I-耗材”的准确率分别为 80.22% 和 76.97%，主要原因是耗材类实体在数据集中出现频次最低，导致模型未能充分学习其特征。此外，“B-耗材”和“B-零件”之间存在一定的混淆，这一现象主要源于两类实体在实际维修任务中的使用场景重叠，增加了区分难度。在工具类实体的预测中，模型的表现也存在一定问题。“I-工具”和“B-工具”的准确率分别为 91.47% 和

90.07%，差距较小，但“I-工具”常被误分类为“B-工具”或无关实体。这表明模型在区分工具类实体的首字符（B/I 标签）时存在困难，可能与工具类实体的上下文特征不够显著有关。

综合来看，命名实体识别 CoBiTex-FTM 模型在一定程度上优化了数据集中的词向量表示，有效提高了各类别实体的识别准确性。

### 3.2 关系抽取模型

验证 BiLSTM-MHA 关系抽取模型在数据集中抽

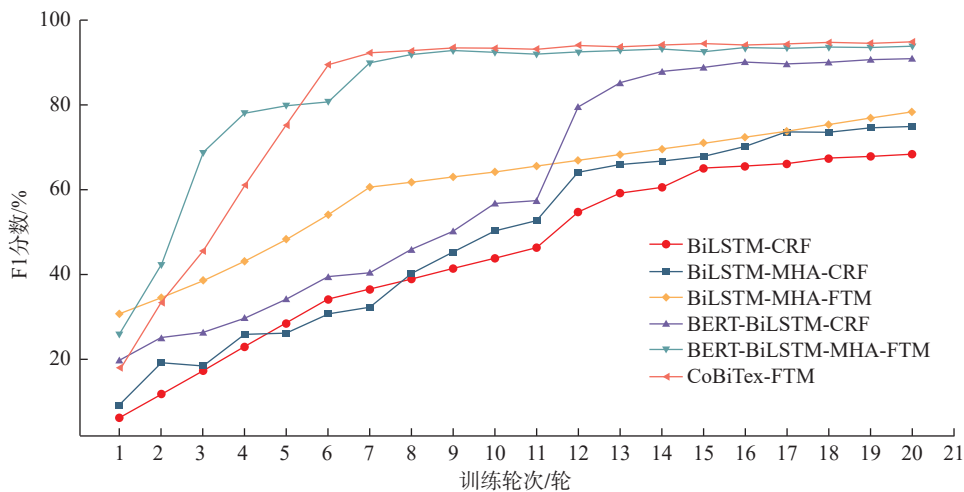


图 11 训练轮次对命名实体识别模型 F1 分数的影响

Fig.11 Impact of training epochs on the F1 score of the name entity recognition model




图 12 CoBiTex-FTM 混淆矩阵

Fig.12 Confusion matrix of CoBiTex-FTM

取的效果,选取了以下关系抽取模型进行对比试验,通过调整超参数,得到上述模型最好的 F1 分数,试验结果如图 13 所示。

(1)大语言模型 GLM4-API。GLM4 是一个大型预训练语言模型,具备强大的语言理解和生成能力。该模型通过大规模的文本数据训练后,能够处理多种语言任务,如文本生成、摘要、翻译等。

(2)大语言模型 ChatGLM2-6B 的微调训练。ChatGLM2-6B 是一款中文对话大语言模型,采用了 6B 参数,专注于中文文本的生成与理解。根据官方教程,本研究将飞机维修关系抽取数据集转换为适配的 JSON 格式,并对其进行 Fine-Tuning 微调训练,以提升模型在特定领域的性能。

(3) BiLSTM。BiLSTM 是一种基于长短期记忆网

络的双向扩展结构,能够同时捕捉序列数据中的前向和反向上下文信息。通过双向结构, BiLSTM 能更好地理解序列中的语境依赖关系,对处理自然语言中的上下文具有显著优势。

(4) BiGRU。双向门控循环单元 (BiGRU) 是门控循环单元 (Gated recurrent unit, GRU) 的改进版,相较于 BiLSTM, BiGRU 具有更高的计算效率。该模型在保留长期依赖关系的同时,通过减少计算量可以提高处理速度,将其应用于关系抽取任务中性能表现较好。

(5) BiHAM-FTM。BiHAM-FTM 是本文提出的创新模型,结合了 BiLSTM 用于局部上下文建模和多头注意力机制用于全局关系建模,并通过整词约束机制进行标签解码。该模型通过多角度的上下文建模,显著提升了关系抽取的准确性和鲁棒性。

通过对比试验结果可以看出,本文提出的 BiHAM-FTM 关系抽取模型在准确率、召回率和 F1 分数上分别比效果较好的 BiGRU 提高了 3.22、4.01 和 3.66 个百分点。这些提升表明, BiHAM-FTM 通过结合 BiLSTM 的上下文建模、多头注意力机制的全局依赖捕捉和整词约束的语义一致性,有效提升了关系抽取的精度和覆盖率。相比之下, BiGRU 尽管计算效率较高,但在捕捉长距离依赖和复杂关系方面略显不足。BiHAM-FTM 的多角度建模和一致性约束显著增强了对复杂语义关系的识别能力,尤其在处理长句和复合词时表现更为出色。因此, BiHAM-FTM 的各项指标均优于其他模型,验证了其在关系抽取任务中的优势。

同样的,对关系抽取模型在 20 轮训练轮次中, BiLSTM、BiGRU、BiHAM-FTM 3 个模型训练轮次与 F1 分数之间的关系进行分析,试验结果如图 14 所示。




图 13 不同关系抽取模型的分数比较

Fig.13 Comparison of scores for different relation extraction models

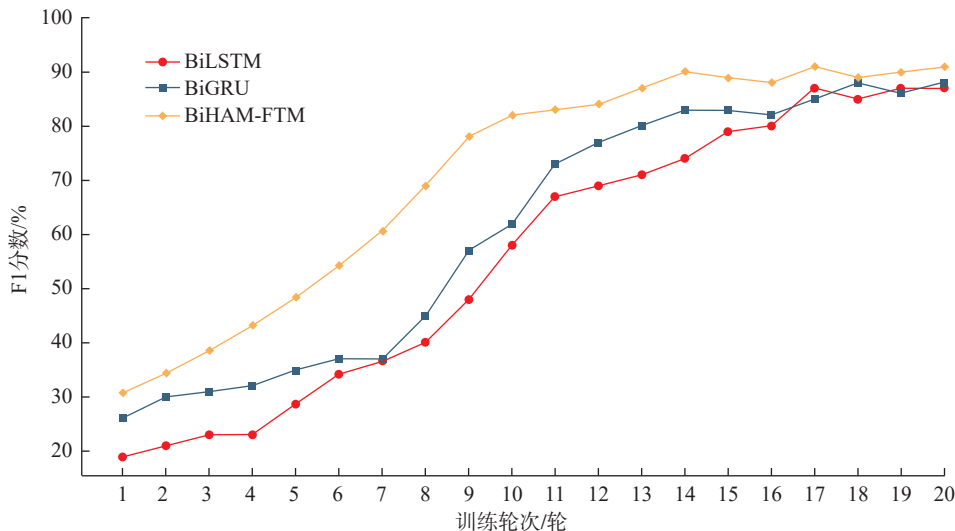


图 14 训练轮次对关系抽取模型中 F1 分数的影响

Fig.14 Impact of training epochs on F1 score in relation extraction models

可以看出,本文提出的 BiHAM-FTM 模型在初始训练轮次便表现出优于另外两个模型的效果,并在后续轮次中一直领先于另外两个模型。

### 3.3 知识图谱构建

飞机维修任务手册文本具有独特的文本结构与行文特点,其内容较为专业,一般包括大量领域内的专业术语。本文构建的飞机维修任务知识图谱主要包括 6 类实体节点,即机号、专业系统、任务名称/工卡编号、一级步骤、二级步骤、关联知识。

在 Neo4j 中,标签可以用来标识节点集合,允许用

户在节点集合中设置索引、定义约束和查询操作。本文定义的飞机维修任务文本所包括的各类实体的类别、实例及实体数量如表 3 所示。

Neo4j 具有独特的数据存储结构,主要分为 3 种形式:节点、关系及节点或关系的属性。在 Neo4j 中,实体和关系是构建知识图谱的核心要素。数据库中的节点和边分别代表实体和关系,并且实体和关系通常会带有相关的属性。通过上文中提到的关系三元组数据,利用 Python 程序将其保存为 JSON 文件,如图 15 所示。

采用自顶向下和自底向上混合的知识图谱构建方

表 3 飞机维修任务实体类型及定义

Table 3 Entity types and definitions of aircraft maintenance task

实体类别	实例	数量
机号	飞机维修领域,每一架次飞机都有一一对应的维修手册,称为“工卡”,工卡与飞机编号是一一对应的,如“2020”“2025”	1
专业系统	为确保飞机安全、高效完成飞行任务,在航空领域中依据特定专业功能划分,由一系列相互关联、相互协作且具备独特专业特性的部件、设备、流程及人员等要素所构成的有机整体。如“动力装置系统”“环境控制系统”“热管理系统”	4
任务名称/编号	每一份飞机维修任务手册有唯一的任务名称和编号,简明地概括了手册的主要任务,如机械专业必检/JXXT-JXBJGK-2020	50
一级步骤	飞机维修任务手册中的主要步骤,从宏观层面将整个维修流程进行了大致的划分,呈现出维修工作的主要阶段或关键环节,如“检查区域 24 左机翼‘表面’”	961
二级步骤	二级步骤则是在一级步骤的基础上,进一步深入到每个主要阶段的具体操作细节当中,如“(1)升降副翼及其上封严板无损伤、裂纹;(2)前缘襟翼及其上封严板无损伤、裂纹”	11532
关联知识	具体维修任务中,涉及的工具、动作、耗材、零件等实体类型,如“测量尺”“发动机进口支板”	47675

```
{
  "机号": "2025",
  "专业系统": "机械系统",
  "工卡名称": "机械必检工卡",
  "工卡编号": "JXXT-JXBJGK-2020",
  "步骤": [
    {
      "步骤编号": 1,
      "步骤标题": "燃油取样检查",
      "备注": "区域7:右主武器舱",
      "二级步骤": [
        {
          "步骤": 1,
          "使用工具": [""],
          "耗材": ["堵盖"],
          "操作对象": ["主武器舱内1号油箱放油口开关", "1号油箱放油口堵盖"],
          "操作类型": "关闭/拧上",
          "原文内容": "关闭主武器舱内1号油箱放油口开关,拧上堵盖"
        },
        {
          "步骤": 2,
          "使用工具": [""],
          "耗材": ["堵盖"],
          "操作对象": ["5号油箱放油接口", "5号油箱放油接口堵盖"],
          "操作类型": "拆卸/堵上",
          "原文内容": "拆卸5号油箱放油接口,堵上堵盖,打好保险"
        }
      ]
    }
  ]
}
```

(a) JSON文本实体示例

```
{
  "triplets": [
    {
      "subject": "机械必检工卡",
      "predicate": "HAS_CONDITION",
      "object": "机械系统"
    },
    {
      "subject": "机械必检工卡",
      "predicate": "HAS_FINAL_STEP",
      "object": "燃油取样检查"
    },
    {
      "subject": "燃油取样检查",
      "predicate": "STEP_USES_CONSUMABLE",
      "object": "堵盖"
    },
    {
      "subject": "燃油取样检查",
      "predicate": "STEP_INVOLVES_PART",
      "object": "主武器舱内1号油箱放油口开关"
    },
    {
      "subject": "燃油取样检查",
      "predicate": "STEP_INVOLVES_PART",
      "object": "1号油箱放油口堵盖"
    },
    {
      "subject": "步骤1",
      "predicate": "STEP_USES_CONSUMABLE",
      "object": "堵盖"
    },
    {
      "subject": "步骤1",
      "predicate": "STEP_INVOLVES_PART",
      "object": "主武器舱内1号油箱放油口开关"
    }
  ]
}
```

(b) JSON文本关系示例

图 15 飞机维修任务知识抽取结果 JSON 文本示例

Fig.15 JSON text examples of aircraft maintenance task knowledge extraction results

法,经迭代更新后得到“实体-关系-实体”三元组,并将其存储在 Neo4j 图数据库中,飞机维修任务知识图谱的部分示意图如图 16 所示。

本文构建的知识图谱系统已在某型飞机维修任务中完成初步验证,知识图谱中的实体与关系被封装为轻量化接口模块,集成于手持显示终端或项目使用的国产化混合现实头戴式设备中,如图 17 所示。维修人员通过语音指令或触控界面调用相关维修步骤,系统可自动匹配对应的维修流程,并以图文结合的方式进行步骤引导,同时高亮关键的工具、零件及注意事项,显著提升了维修任务的准确性与响应速度。

#### 4 结论

(1) 提出飞机维修手册命名实体识别算法 CoBiTex-FTM,通过结合 BERT-BiLSTM 框架、多头注意力机制及整词约束算法,有效应对了维修手册中复杂语义、词

汇歧义及短文本的挑战。在飞机维修手册数据集上的 F1 分数达到了 95.16%,显著提高了实体识别的准确性,特别是在中英文混杂、短文本和专业术语处理方面表现优异。通过消融试验等手段,证明本文的改进方法在复杂语义建模和边界一致性处理中的有效性。

(2) 提出飞机维修手册关系抽取算法 BiHAM-FTM,在准确率、召回率和 F1 分数上分别比效果较好的 BiGRU 模型提高了 3.22、4.01 和 3.66 个百分点,表明其在捕捉长距离依赖和复杂语义关系方面的优势。

(3) 结合知识图谱的三元组结构,构建了“实体-关系-实体”的全面知识体系,为维修手册的数据结构化存储和语义理解奠定了基础。通过引入图数据库 Neo4j 作为知识图谱的存储和可视化平台,提升了维修手册中实体与关系的查询效率,为飞机维修任务中的知识检索与步骤引导提供了有力支持。

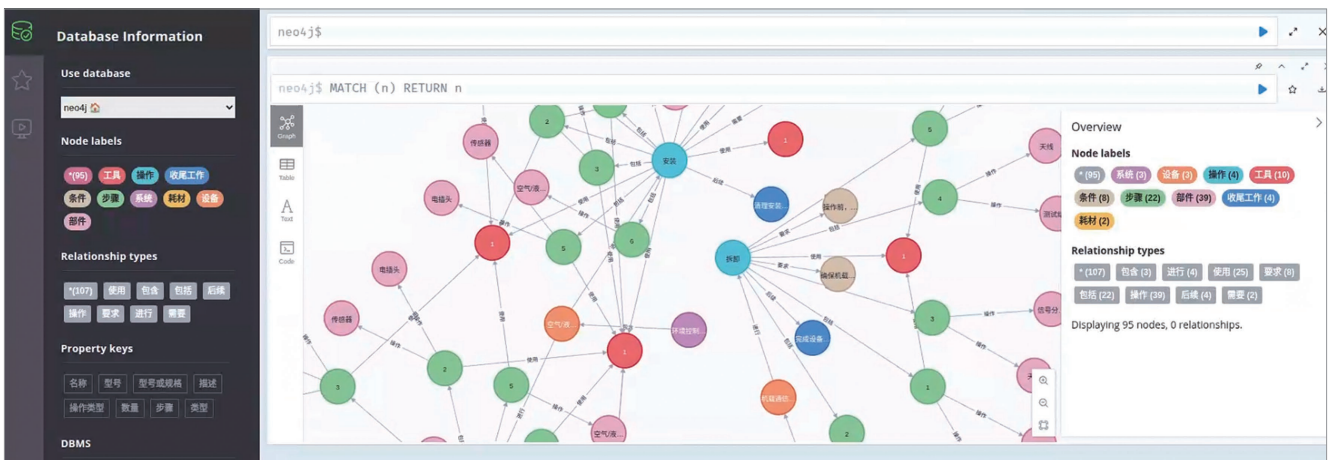
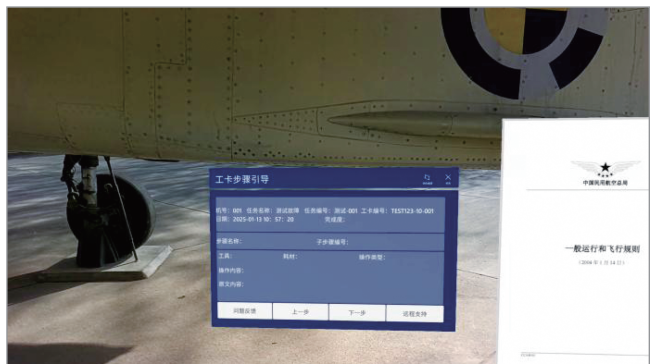


图 16 Neo4j 中飞机维修任务知识图谱的部分示意图

Fig.16 Partial schematic diagram of aircraft maintenance task knowledge graph in Neo4j



(a) 混合现实头戴式显示设备佩戴示例



(b) 混合现实工卡步骤引导页面

图 17 混合现实头戴式显示设备维护引导

Fig.17 Mixed reality headset maintenance guide

## 参考文献

- [1] 刘春, 陈宇, 杨冬, 等. 飞机大部件对接系统数字孪生技术应用研究[J]. 航空制造技术, 2025, 68(1/2): 130–136.
- LIU Chun, CHEN Yu, YANG Dong, et al. Research on application of digital twin technology in aircraft large component alignment system[J]. *Aeronautical Manufacturing Technology*, 2025, 68(1/2): 130–136.
- [2] 陈勇刚, 刘康妮, 王帅. 基于BiGRU-Attention改进的航空设备故障知识图谱构建[J]. 航空学报, 2024, 45(18): 163–176.
- CHEN Yonggang, LIU Kangni, WANG Shuai. Fault knowledge graph construction for aviation equipment based on BiGRU-Attention improvement[J]. *Acta Aeronautica et Astronautica Sinica*, 2024, 45(18): 163–176.
- [3] 王佐旭, 王鑫, 孟爽, 等. 知识-用户行为驱动的飞机工装设计知识推送方法[J]. 航空学报, 2025, 46(9): 294–312.
- WANG Zuoxu, WANG Xin, MENG Shuang, et al. A knowledge-user behavior-driven aircraft assembly tooling design knowledge recommendation approach[J]. *Acta Aeronautica et Astronautica Sinica*, 2025, 46(9): 294–312.
- [4] 肖彪, 徐宝德, 彭仕鑫, 等. 基于知识图谱的复杂薄壁零件机械加工工艺知识建模研究[J]. 航空制造技术, 2024, 67(11): 76–86.
- XIAO Biao, XU Baode, PENG Shixin, et al. Study on machining knowledge modeling of complex thin-walled parts based on knowledge graph[J]. *Aeronautical Manufacturing Technology*, 2024, 67(11): 76–86.
- [5] IMAMURA Y, NAKAMURA N, YAO T, et al. A device identification method based on combination of multiple information[C]// NOMS 2020–2020 IEEE/IFIP Network Operations and Management Symposium. Budapest, 2020.
- [6] HUANG Z H, XU W, YU K. Bidirectional LSTM-CRF models for sequence tagging[EB/OL]. [2015–08–09]. <https://doi.org/10.48550/arXiv.1508.01991>.
- [7] LUO L, YANG Z H, YANG P, et al. An attention-based BiLSTM-CRF approach to document-level chemical named entity recognition[J]. *Bioinformatics*, 2018, 34(8): 1381–1388.
- [8] QIU Q J, XIE Z, WU L, et al. BiLSTM-CRF for geological named entity recognition from the geoscience literature[J]. *Earth Science Informatics*, 2019, 12(4): 565–579.
- [9] LIU W, XU T G, XU Q H, et al. An encoding strategy based word-character LSTM for Chinese NER[C]//Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 1 (Long and Short Papers). Minneapolis, 2019.
- [10] Koroteev M. BERT: A review of applications in natural language processing and understanding[EB/OL]. [2021–04–22]. <https://doi.org/10.48550/arXiv.2103.11943>.
- [11] LIU Y H, OTT M, GOYAL N, et al. RoBERTa: A robustly optimized BERT pretraining approach[EB/OL]. [2019–07–26]. <https://doi.org/10.48550/arXiv:1907.11692>.
- [12] 高丹, 彭敦陆, 刘丛. 海量法律文书中基于CNN的实体关系抽取技术[J]. 小型微型计算机系统, 2018, 39(5): 1021–1026.
- GAO Dan, PENG Dunlu, LIU Cong. Entity relation extraction based on CNN in large-scale text data[J]. *Journal of Chinese Computer Systems*, 2018, 39(5): 1021–1026.
- [13] 王智广, 文红英, 鲁强, 等. 地质领域开放式实体关系联合抽取[J]. 计算机工程与设计, 2021(4): 996–1005.
- WANG Zhiguang, WEN Hongying, LU Qiang, et al. Joint extraction of open entity relation in geological field[J]. *Computer Engineering and Design*, 2021(4): 996–1005.
- [14] 陈赟, 古丽拉·阿东别克, 马雅静. 旅游领域嵌套实体和重叠关系联合抽取模型BPNRel[J]. 东北师大学报(自然科学版), 2023, 55(3): 64–74.
- CHEN Yun, GULILA·Adongbieke, MA Yajing. BPNRel: A joint extraction model for nesting entities and overlapping relations in the tourism domain[J]. *Journal of Northeast Normal University (Natural Science Edition)*, 2023, 55(3): 64–74.
- [15] 董美, 常志军. 一种面向中医领域科技文献的实体关系抽取方法[J]. 图书情报工作, 2022, 66(18): 105–113.
- DONG Mei, CHANG Zhijun. An entity relation extraction method for scientific and technological documents in the field of traditional Chinese medicine[J]. *Library and Information Service*, 2022, 66(18): 105–113.
- [16] 李涛, 郭渊博, 琚安康. 融合对抗主动学习的网络安全知识三元组抽取[J]. 通信学报, 2020, 41(10): 80–91.
- LI Tao, GUO Yuanbo, JU Ankang. Knowledge triple extraction in cybersecurity with adversarial active learning[J]. *Journal on Communications*, 2020, 41(10): 80–91.
- [17] 程顺航, 李志华, 魏涛. 融合自举与语义角色标注的威胁情报实体关系抽取方法[J]. 计算机应用, 2023, 43(5): 1445–1453.
- CHENG Shunhang, LI Zhihua, WEI Tao. Threat intelligence entity relation extraction method integrating bootstrapping and semantic role labeling[J]. *Journal of Computer Applications*, 2023, 43(5): 1445–1453.
- [18] DEVLIN J, CHANG M W, LEE K, et al. BERT: Pre-training of deep bidirectional transformers for language understanding[EB/OL]. [2018–05–24]. <https://doi.org/10.48550/arXiv.1810.04805>.
- [19] MILLER J J. Graph database applications and concepts with Neo4j[C]//Proceedings of the Southern Association for Information Systems Conference. Atlanta, 2013: 141–147.

(责编 阳光)