[文章编号] 1003－4684(2026)04-0049-07

船舶装备故障知识图谱构建及智能诊断方法

宋庭新，干永明

（湖北工业大学机械工程学院，湖北 武汉 430068）

[摘 要] 针对船舶装备故障诊断中可解释性弱、过度依赖专家经验、历史数据利用率低等问题，提出一种融合知识图谱与深度学习的船舶装备故障智能诊断方法。首先，以船舶维修手册、历史故障报告为数据源，采用自顶向下策略构建故障知识图谱模式层。其次，引入 BERT-BiLSTM-CRF 模型实现故障现象、原因、部位及维修方法的实体精准抽取，结合 Jaccard 相似度算法完成实体消歧与知识融合，基于 Neo4j 图数据库存储结构化故障知识。最后，集成朴素贝叶斯分类器与马尔可夫链归因算法，开发故障智能检索与根因追溯系统。实验结果表明，所提模型实体识别 F_1 值达 83.2%，可高效挖掘船舶故障关联关系。案例验证显示，该方法能显著提升故障诊断效率与可解释性，降低对专家经验的依赖，为船舶装备智能运维提供技术支撑。

[关键词] 船舶装备；故障诊断；知识图谱；BERT-BiLSTM-CRF；知识融合；归因分析

[中图分类号] TH17；U672.7 [文献标识码] A

船舶内部模块复杂化虽然满足动力性能、安全性和舒适性的需求，但也导致故障率上升和维修难度增加[1]。开发基于知识库的智能故障诊断与管理系统，可实现船舶故障诊断与故障知识的协同管理[2]。

该系统具备将非结构化信息图形化存储的能力，并能够支持高效的数据查询。聂同攀等[3]利用 Bi-LSTM 从飞机电源系统故障排除手册中提取故障知识，进而通过知识图谱实现了智能搜索、推荐和问答功能；吴闯等[4]则运用 Bi-LSTM 结合 CRF 等深度学习技术构建故障知识图谱，实现故障诊断功能，但现有方法对多源故障知识融合与故障归因分析的研究仍相对不足；Zhang 等[5]采用 Bi-LSTM 对电池云平台的故障日志提取相关知识，进而构建了一个基于知识图谱的故障检索系统，该系统具备电池故障推理和预测的功能；Zhou 等[6]利用 BERT-BiLSTM-CRF 模型从电力系统故障信息中抽取知识，构建故障知识图谱并实现可视化分析，有效提高了维修人员的工作效率，但对故障知识关联关系分析及归因推理研究相对不足；许驹雄等[7]通过 BERT-BiLSTM-CRF 技术对发动机生产及售后维修报告中的故障知识进行识别，进而创建了发动机故障领域的知识图谱，并通过结合知识图谱与贝叶斯网络来进行故障诊断。

综上，现有研究已在航空、电力及发动机等领域验证了知识图谱在故障诊断中的应用价值，但面向船舶装备故障场景的研究仍相对有限，尤其在多源故障知识融合与故障归因分析方面仍有待进一步探索[8]。为此，本文以船舶故障数据和历史案例数据为基础，构建船舶装备故障知识图谱；采用 BERT-BiLSTM-CRF 模型进行故障知识抽取，引入基于 Jaccard 相似系数的知识融合方法，实现实体消歧与知识整合，并结合马尔可夫链开展故障归因分析。在此基础上，开发集知识检索、智能问答和故障诊断于一体的船舶装备故障智能诊断系统，提升故障诊断的可解释性和知识利用效率，降低对专家经验的依赖。

1 船舶故障诊断决策框架

本文采纳自顶向下的策略来构建船舶故障诊断的知识图谱，以应对船舶故障维修数据的专业性以及非结构化文本中蕴含的复杂信息与关系[9]。所构建的框架分为模式层和数据层（图 1）。数据层的搭建涉及两个主要阶段：知识抽取和知识图谱的集成。在知识图谱集成阶段，进行知识融合以解决实体歧义和同义词问题，包括实体消歧和共指消解等任务，最终形成全面的船舶故障诊断知识图谱。

[收稿日期] 2024－10－08

[第一作者] 宋庭新（1972－），男，湖北宜都人，湖北工业大学教授，研究方向为智能制造信息化、工业工程。

[通信作者] 干永明（2000－），男，湖北武穴人，湖北工业大学硕士研究生，研究方向为装备智能运维、知识图谱。

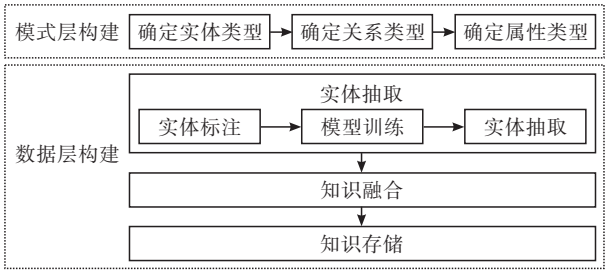

图 1 船舶装备故障诊断知识图谱构建框架

2 诊断决策模型

2.1 知识抽取

在船舶系统故障分析领域,故障数据集通常由故障维修报告和船舶装备故障记录构成,涵盖了维修详情、故障描述等多维度信息,其格式涵盖结构化和非结构化数据。对于结构化数据,直接将其转化为"实体-关系-实体/属性"形式的三元组表示,以便于后续处理。

鉴于船舶故障数据训练集规模的限制以及领域内专业术语的多义性,本文采用 BERT-BiLSTM-CRF 模型来抽取非结构化船舶故障维修案例数据。该模型能够有效处理小规模数据集和解决术语多义性问题[10]。

船舶故障实体识别模型如图 2 所示。

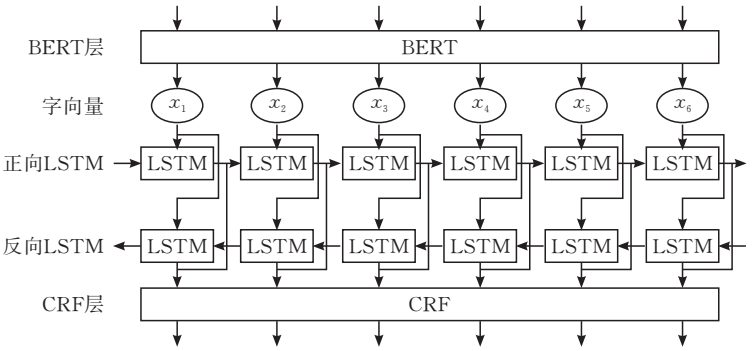

图 2 BERT-BiLSTM-CRF 模型

BERT 模块:可有效捕捉文本语义关联特征,通过式(1)计算输入的故障文本中的每个元素对其他元素的注意力权重。这些权重被用来加权值向量,从而得到加权的输出。

$$\text{Attention}(\boldsymbol{G},\boldsymbol{M},\boldsymbol{N})=\text{softmax}\left(\frac{\boldsymbol{G}\boldsymbol{M}^{\mathrm{T}}}{\sqrt{d_k}}\right)N \tag{1}$$

式中:$\boldsymbol{G}$、$\boldsymbol{M}$、$\boldsymbol{N}$ 分别代表查询、键和值矩阵;d_k 是 $\boldsymbol{K}$ 向量的维度。

Bi-LSTM 模块:通过前向和后向两个 LSTM 网络分别学习文本序列的正向和反向信息并将其合并,获取更全面的序列特征。Bi-LSTM 接收前文 BERT 处理的空间向量,进一步捕捉船舶故障领域数据集文本的上下文关系,为后续 CRF 层序列标注提供了有效的输入。计算公式如下:

$$\begin{cases} f_t=\sigma_g(\boldsymbol{W}_f x_t+U_f h_{t-1}+b_f) \\ i_t=\sigma_g(\boldsymbol{W}_i x_t+U_i h_{t-1}+b_i) \\ o_t=\sigma_g(\boldsymbol{W}_o x_t+U_o h_{t-1}+b_o) \\ \tilde{c}_t=\sigma_g(\boldsymbol{W}_c x_t+U_c h_{t-1}+b_c) \\ c_t=f_t\odot c_{t-1}+i_t\odot\tilde{c}_t \\ h_t=o_t\odot\sigma_h(c_t) \end{cases} \tag{2}$$

式中:$\boldsymbol{W}_f$、$\boldsymbol{W}_i$、$\boldsymbol{W}_o$、$\boldsymbol{W}_c$ 分别代表各自对应的权重矩阵;b_f、b_i、b_o、b_c 分别代表各自 LSTM 的偏差;i_t、o_t、f_t、c_t 分别代表 t 时刻的输入门、输出门、遗忘门以及记忆细胞的信息状态;o 代表 sigmoid 激活函数;h_t 为 t 时刻隐藏层的状态。

CRF 模块:在实体抽取任务中,CRF 能够考虑到标签序列中的依赖关系,通过全局最优化输出最合理的标签序列,适合于序列数据的标注任务。它通过学习标签之间的转移概率,确保输出的实体标签在局上最优,从而提高实体识别的准确性。其计算公式如下:

$$P(y\mid x)=\frac{1}{Z(x)}\exp\Big(\sum_{i,k}\lambda_k t_k(y_{i-1},y_i,x,i)+\sum_{i,l}u_l s_l(y_i,x,i)\Big) \tag{3}$$

式中

$$Z(x)=\sum_{y}\exp\Big(\sum_{i,k}\lambda_k t_k(y_{i-1},y_i,x,i)+\sum_{i,l}u_l s_l(y_i,x,i)\Big) \tag{4}$$

其中:t 为转移特征;s 为状态特征;x_i 为观察变量;y_i 为隐含变量;y_k 和 u_l 为 t 和 s 所对应的权值。

在训练模型前需要标注一定量的数据。本文采用 BIO 标记方案,其中"B"表示实体起始字符,"I"表示实体内部字符,而"O"表示非目标实体字符。在标注数据集中,主要实体类型有故障现象、故障原因、故障部位和维修方法等 4 种,标注示例如表 1 所示。

2.2 知识融合

通过知识抽取技术可以获取实体及其关系,但由于抽取数据在来源与质量上存在差异,需进一步

采用知识融合策略对数据进行统一与优化。知识融合依赖于实体消歧和共指消解技术[11]。

表 1　标注实例

原始文本	实体类别	对应实体
船舶甲板颤动，此时马达转速逐渐降低，原因为主油泵发生堵塞，维修方法更换主油泵	故障现象	船舶甲板颤动，此时马达转速逐渐降低
	故障原因	主油泵发生堵塞
	故障部位	主油泵
	维修方法	更换主油泵

实体消歧主要解决不同文本表述指向同一实体，或同一表述指向不同实体的问题。“舵机”在某些文本中可能指“主舵机”，而在其他场合则可能指“应急舵机”。共指消解技术则处理不同表达方式指向同一实体的情况。比如，“船舶推进系统”“主推进装置”“推进设备”可能都指向同一个系统。特别是在故障报告和维护记录中，用词经常不一致，因此需要对实体名称进行统一规范化处理。本文采用 Jaccard 相似系数匹配船舶故障实体，实现知识融合。计算公式为：

$$\boldsymbol{D}(a_1,a_2)=\frac{|\boldsymbol{A}(a_1)\cap\boldsymbol{A}(a_2)|}{|\boldsymbol{A}(a_1)\cup\boldsymbol{A}(a_2)|} \tag{5}$$

式中：a_1、a_2 指船舶的故障实体，$\boldsymbol{A}(a)$ 表示对应故障实体的字符串，$\boldsymbol{D}$ 值越大，代表两个实体相似度越高。参考已有知识融合研究中的相似度判定方法，并结合船舶故障数据特点设定 Jaccard 相似系数阈值。当 $\boldsymbol{D}$ 值高于该阈值时，判定两个实体为同一实体并进行融合处理。Jaccard 相似度的计算流程见图 3。

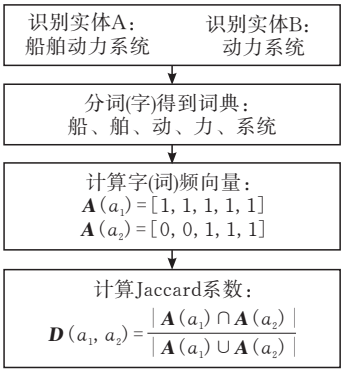

图 3　知识融合相似度计算流程

2.3　知识存储

经过知识抽取与知识融合处理后，不同来源的船舶故障数据被转换为结构化知识。为实现图数据的统一管理与高效存储，采用三元组形式对知识进行表示与存储，其组织模式为“实体-关系-实体/属性”。

在众多图数据库和图谱构建工具（Apache Jena、GraphDB、Gephi 及 Neo4j）中，Neo4j 以其高性能、灵活设计和直观结构脱颖而出[12]。它是一个开源图数据库系统，采用图模型存储和管理数据，内置 Cypher 查询语言，能有效处理复杂的关系数据。Neo4j 的主要优势在于其原生图存储结构，通过节点间的关系快速连接，即使在大规模数据环境中也能维持高查询效率。结合船舶故障案例的特点及应用需求，选用 Neo4j 作为知识库构建平台。

2.4　故障诊断决策方法

基于前述研究步骤，可构建对应的船舶装备故障知识图谱。该图谱存储于 Neo4j 图数据库中，并通过 Cypher 查询语言实现故障诊断知识的高效检索。然而，在实际应用中直接使用知识图谱存在一定局限。为了进一步提升故障诊断的效率和准确性，开发一个能够理解用户诊断意图的知识图谱问答系统（knowledge graph-based question answering，KBQA）显得尤为关键[13]。KBQA 的关键是识别用户的意图，朴素贝叶斯分类器是一种常见且有效的分类算法，目前广泛应用于各行业的智能问答系统中。它通过提取用户输入的关键词进行问题分类，然后在知识库中查找模板生成答案。本文采用朴素贝叶斯分类器，对经过 HanLP 分词处理后的关键词和问题类别进行建模，以实现高效的问题分类。将船舶故障问题抽象为类别集合 $\boldsymbol{Y}=\{y_1,y_2,\cdots,y_n\}$ 和特征集合 $\boldsymbol{X}=\{x_1,x_2,\cdots,x_m\}$。例如，“船舶主发动机冷却水温度异常上升”可以抽象归类为船舶故障现象类别样本。贝叶斯公式：

$$P(y_i\mid X)=\frac{P(X\mid y_i)P(y_i)}{\sum_{i=1}^{n}P(X\mid y_i)P(y_i)} \tag{6}$$

朴素贝叶斯分类器基于贝叶斯定理和特征条件独立假设。该方法通过将关键词转换为特征向量 $\boldsymbol{X}$，计算最大后验概率 $P(y_i\mid X)$，从而确定问题的分类。在实际应用中，贝叶斯公式的分母被视为常数。朴素贝叶斯公式：

$$\max(P(y_i\mid X))=$$
$$\max(P(y_i))\prod_{i}^{m}P(x_i\mid y_i)\ ,i=1,2,\cdots,m \tag{7}$$

因涉及的船舶部件种类繁多，故障类型极为复杂，扩展 KBQA 的功能，以提供给维修人员更全面的故障诊断辅助工具，对于准确识别船舶部件故障的根本原因具有重要意义。以图 4 所示的故障图为例，依据马尔可夫链的原理，故障成因仅与直接前导因素相关，而与非直接因果链上的其他因素无关，其公式如下：

$$P(C_j\mid C_i)=\frac{n_{C_iC_j}}{n_{C_i}} \tag{8}$$

式中：C_i 表示特定的故障现象；C_j 表示导致 C_i 发生

的故障原因；n_{C_i} 代表故障现象 C_i 出现的总次数；而 $n_{C_iC_j}$ 表示由故障原因 C_j 引起的故障现象 C_i 发生的次数。

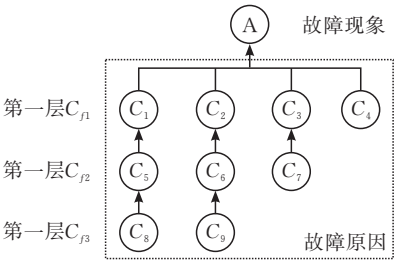

图 4 基于马尔可夫链的船舶装备故障例图

基于马尔可夫链链式法则，可以从特定故障现象 A 推导出导致底层故障根因 C_n 的概率，计算公式如下：

$$P(C_n \mid A) = P(C_n \mid C_{n-1}), \cdots, P(C_2 \mid C_1)P(C_1 \mid A) \tag{9}$$

式中，C_n 为第 n 层故障原因集合 C_{fn} 中的故障原因。以图 4 中第三层 C_{f3} 中的故障根因 C_8 为例：由故障现象 A 推测出故障根因 C_8 的发生概率 $P(C_8 \mid A) = P(C_8 \mid C_5)P(C_5 \mid C_1)P(C_1 \mid A)$。因此，可基于式(9)计算各故障根因对特定故障现象的概率贡献，以评估故障根因与故障现象之间的关联程度，并为故障排查优先级的确定提供参考。

3 案例分析

3.1 实验数据及模式层构建

本文以某型船舶为研究对象，基于该船 2018—2022 年系统排故手册及 300 余条历史故障案例构建语料库，并整理形成案例数据集。数据集涵盖 9 个船舶系统和 195 个装备实体，记录了装备对应的故障现象、故障原因及维修方案等信息。

在领域专家参与下，对船舶故障文本数据开展分析与整理，并构建了如图 5 所示的船舶装备故障知识图谱模式层。该模式层以“船舶-船舶系统-船舶设备”为主线，构建船舶装备层级结构，其中船舶实体包含船名、制造日期、生产厂家等属性信息。在故障诊断层面，模式层进一步定义了故障现象、故障类型、故障部位、故障原因及维修方法等核心实体。故障现象用于描述设备运行过程中表现出的异常状态或外部特征，故障类型用于表示具体故障类别或失效形式。与此同时，模式层通过“发生故障”“故障类型”“故障原因”“维修方法”等关系构建实体间的语义关联，从而形成较为完整的船舶故障知识组织结构，为后续知识存储、知识推理及智能诊断提供基础支撑。

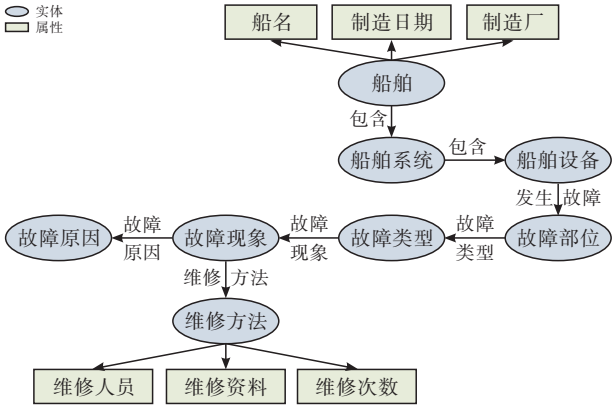

图 5 船舶装备故障知识图谱模式层结构

3.2 知识抽取结果

本文基于前述语料库构建实体识别数据集，并采用 BERT-BiLSTM-CRF 模型进行船舶装备故障实体抽取。对 300 余条历史故障案例进行人工标注，形成包含故障现象、故障原因、故障部位及维修方法等实体类型的标注数据集。随后按照 60%、20%、20%的比例划分训练集、验证集和测试集。部分标注结果如图 6 所示。

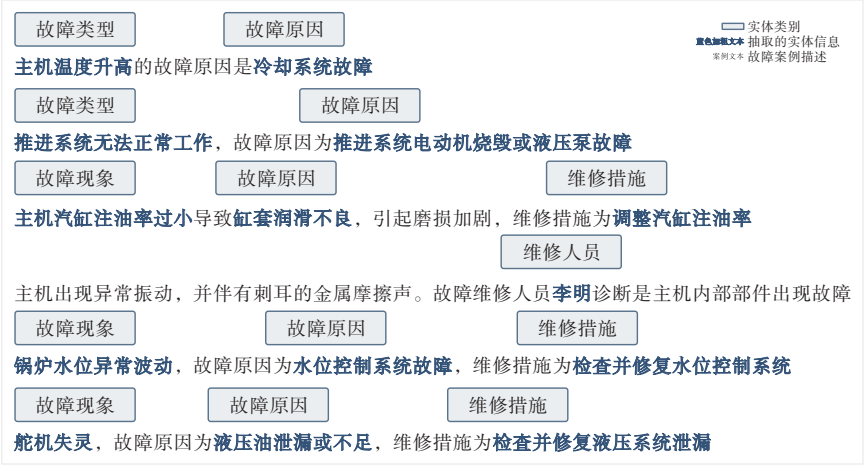

图 6 部分船舶装备故障文本标注

实验环境为 Windows 10 操作系统，Python 3.8 及 PyTorch 1.8 深度学习框架。模型参数如表 2 所示。

表 2　知识抽取模型参数

参数	数值
学习率	0.005
dropout	0.5
Bi-LSTM 隐层状态的维数	300
d	256
epoch	100
batch size	8
Bi-LSTM 层数	1

本文使用深度学习领域常用的评价指标对实体抽取的 BERT-BiLSTM-CRF 模型进行评估，评价指标为精确率 P、召回率 R 和综合指标 F_1。计算公式如下：

$$\begin{cases} P = \dfrac{P_T}{P_T + P_F} \\ R = \dfrac{P_T}{P_T + N_F} \\ F_1 = \dfrac{2PR}{P + R} \end{cases} \tag{10}$$

式中，P_T、P_F 和 N_F 分别代表正确识别的正样本数、识别不正确的实体数和未识别的实体数。

完成实体标注后，以训练集语料及其标签作为输入训练 BERT-BiLSTM-CRF 模型，并利用验证集对模型实体抽取效果进行验证。随后，采用训练后的模型对原始语料进行实体识别，并结合规则抽取结果进行融合，以提高实体抽取的完整性和准确性。为验证该模型在小样本、强领域性船舶故障文本中的实体抽取性能，选取 BiLSTM、BiLSTM-CRF 及 BERT-BiLSTM-CRF 模型进行对比实验，并采用相关评价指标对模型性能进行评估，实验结果如表 3 所示。

表 3　模型对比　　%

模型	P	R	F_1
CRF	76.5	80.3	78.4
BERT-CRF	78.2	83.5	80.7
BERT-BiLSTM-CRF	80.4	86.2	83.2

模型性能评估结果表明，BERT-BiLSTM-CRF 模型在各项评价指标上均取得最优结果，F_1 值达到 83.2%，较 CRF 模型和 BERT-CRF 模型分别提高 4.8%和 2.5%。结果表明，将预训练语言模型、双向长短期记忆网络与条件随机场相结合，能够有效提升船舶故障文本实体识别性能。其中，BERT 增强了文本语义特征表达能力，BiLSTM 强化了上下文依赖信息建模能力，CRF 进一步优化了标签序列预测结果，因此在准确率、召回率及综合评价指标方面均表现出较好的性能。本文采用的抽取技术成功提取了船舶故障相关的实体，包括故障类型、故障原因及维修方法等，具体结果详见表 4。

表 4　船舶装备故障知识图谱实体数量

故障类型	21	系统	9
故障原因	311	设备	195
故障现象	264	故障案例	253
维修方法	284		

本文将船舶装备故障数据划分为结构化数据和非结构化数据两类，并统一存储于 Neo4j 图数据库中。对于结构化数据，利用 pandas 和 py2neo 工具从 MySQL 数据库及 Excel 文件中提取并导入图数据库；对于故障报告等非结构化数据，则采用前述知识抽取模型进行实体与关系抽取，经人工校验后以三元组形式存储。

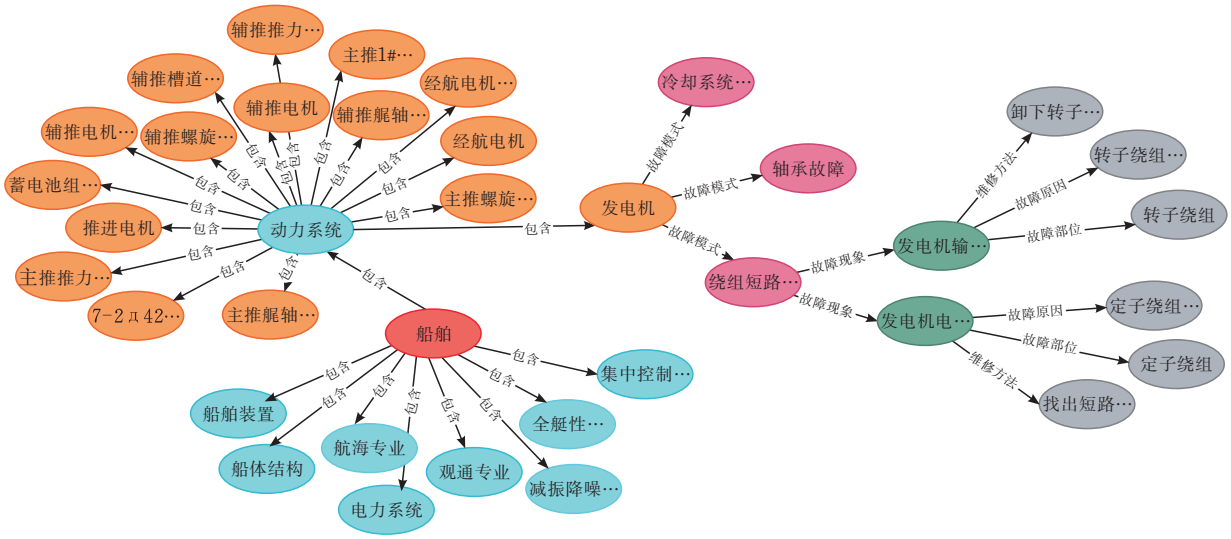

图 7　船舶装备故障知识图谱部分节点

基于模式层设计和知识抽取结果，构建了船舶装备故障知识图谱，其部分节点如图 7 所示。图谱以“船舶”实体为核心，建立船舶、系统与装备之间的层级关系，并关联动力系统下的推进电机、蓄电池组及主推进器等装备实体。以“发电机”装备为例，进一步构建故障现象、故障部位、故障原因及维修方法之间的关联关系。其中，“绕组短路”等故障类型可关联至发电机轴、转子绕组和定子绕组等故障部位，并对应冷却系统故障、定子绕组故障等故障原因，从而形成完整的故障关联链路。该图谱实现了船舶装备信息、故障知识及维修经验的结构化组织，为故障知识检索、根因分析和智能诊断提供了数据支撑。

3.3 基于知识图谱的故障诊断

本文基于船舶装备故障知识图谱，开发一个综合决策支持系统，若不采用基于知识图谱的故障诊断方法，维修人员需人工梳理、归纳海量故障知识，诊断流程不仅耗时，而且效率低下。系统通过智能信息检索，利用关键字快速定位维修措施，优化传统人工查询的低效流程。此外，知识图谱支持建立一个多方协同的故障处置平台，实现资源的统一调配和快速协调，提高了信息交互的效率和准确性。

船舶装备故障诊断系统整体架构如图 8 所示。诊断流程主要包括以下步骤：1）用户输入故障描述文本；2）通过实体识别提取故障现象、故障部位等关键实体信息；3）利用朴素贝叶斯分类器完成故障类型分类；4）根据实体识别与分类结果生成 Cypher 查询语句，并在 Neo4j 图数据库中检索相关故障知识、节点关系及维修方案；5）对检索结果进行整合与分析，输出最终故障诊断结果。

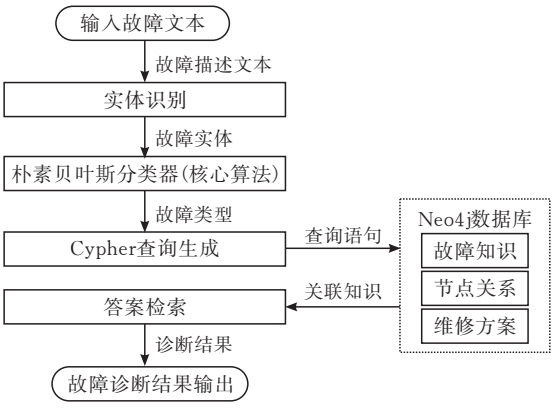

图 8 船舶装备故障诊断流程

用户交互界面如图 9 所示。用户提交推进电机的故障类别查询时，系统将通过知识图谱检索并呈现四种潜在故障类别。系统还提供案例文件追溯功能，以增强答案的解释力度。此外，系统具备更新故障知识的能力，能够通过分析新上传的故障文本，识别新的故障类型和处理策略，进而更新图谱，为其他单位提供故障诊断和处理的参考，确保知识的持续更新和传承。当用户提交查询“船舶主发动机冷却水温度异常上升”时，为了深入探究故障的成因，系统将分析故障发生的时间、原因的频次，并综合考虑故障的严重程度，对潜在原因进行优先级排序。用户提交特定故障描述后，系统将解析可能原因，并依据历史案例中原因出现的频次，计算出 5 种最可能的原因的概率并进行排序。现场排查可以进一步补充故障信息，从而提升特定原因的置信度，辅助用户进行故障排查（图 9）。

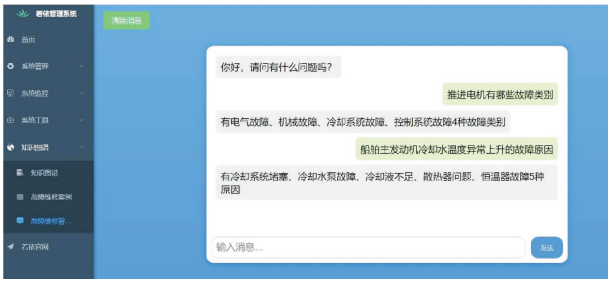

图 9 船舶装备故障知识图谱用户交互界面

4 结论

1）面向船舶装备故障知识分散、历史数据利用率低等问题，构建船舶装备故障知识图谱，实现故障知识的结构化组织与关联表达；针对多源数据实体异构问题，引入基于 Jaccard 相似系数的知识融合方法，实现实体消歧与融合，提升了知识图谱质量。

2）采用 BERT-BiLSTM-CRF 模型进行船舶故障实体识别，实现故障现象、故障原因、故障部位及维修方法等实体的精准抽取，实体识别 F_1 值达到 83.2%，为知识图谱构建提供了可靠的数据基础。

3）基于知识图谱构建船舶装备故障智能诊断系统，并结合朴素贝叶斯分类器与马尔可夫链归因算法，实现故障检索与根因追溯，提高了故障诊断的可解释性，降低了对专家经验的依赖。

未来研究将进一步融合振动信号、图像及传感器监测数据等多模态信息，提升复杂故障场景下的诊断能力；开展跨船型故障知识迁移研究，增强知识图谱的泛化能力；结合实时监测数据与动态知识更新机制，提升船舶故障预警与在线诊断水平。

[参 考 文 献]

[1] Hocek H，Yazır D，Aygün C，et al.The effect of failure on energy efficiency in maritime vessels autopilot systems[J]. Ocean and Coastal Management，2024，259：107451.

[2] 文怡.基于知识图谱与大模型的船舶问答系统研究与应用[D].成都：电子科技大学，2025：56.

[3] 聂同攀，曾继炎，程玉杰，等.面向飞机电源系统故障诊断的知识图谱构建技术及应用[J].航空学报，2022，43(08)：46-62.

[4] 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(04)：1336-1346.

[5] Zhang Z J，Sun Y F，Zhang L S，et al. Enabling online search and fault inference for batteries based on knowledge graph [J]. BATTERIES-BASEL，2023，9(02)：124.

[6] Zhou B X，Gao D Q，Yan L C，et al.Research on key technologies for fault knowledge acquisition of power communication equipment[J]. Procedia Computer Science，2021，183：479-485.

[7] 许驹雄，李敏波，刘孟珂，等.发动机故障领域知识图谱构建与应用[J].计算机系统应用，2022，31(07)：66-76.

[8] 刘建湘，陈晓慧，刘海砚，等.船舶活动知识图谱可视分析方法[J].计算机辅助设计与图形学学报，2024，36(08)：1194-1204.

[9] 司聿宣.基于电子知识库的船舶故障诊断技术及应用[J].舰船科学技术，2024，46(16)：153-157.

[10] 邱凌，张安思，张羽，等.面向无人机故障诊断的知识图谱构建应用方法[J].计算机工程与应用，2023，59(09)：280-288.

[11] 张栋梁，周伟，马刚，等.面向水利防汛抢险的知识图谱构建与应用[J].水利学报，2025，56(03)：341-353.

[12] Chen J，Zhuang C，Shi J，et al.Risk factors extraction and analysis of Chinese ship collision accidents based on knowledge graph[J].Ocean Engineering，2025，322：120536.

[13] 涂芳，周华涛.基于人工智能的船舶故障检测结果智能推荐系统[J].舰船科学技术，2024，46(11)：173-176.

Construction of a Ship Equipment Fault Knowledge Graph and Intelligent Diagnosis Method

SONG Tingxin，GAN Yongming

(*School of Mechanical Engineering，Hubei Univ. of Tech.，Wuhan* 430068，*China*)

Abstract：To overcome the limitations of poor interpretability，strong dependence on expert experience，and insufficient utilization of historical data in ship equipment fault diagnosis，an intelligent diagnosis method integrating knowledge graphs and deep learning is proposed. Ship maintenance manuals and historical fault reports are first used as data sources to construct the schema layer of a fault knowledge graph using a top-down approach. A BERT-BiLSTM-CRF model is then employed to extract entities related to fault phenomena，causes，locations，and maintenance methods. To improve data consistency and quality，entity disambiguation and knowledge fusion are performed based on the Jaccard similarity algorithm，and the resulting structured fault knowledge is stored in the Neo4j graph database. Furthermore，an intelligent fault retrieval and root cause analysis system is developed by integrating a Naive Bayes classifier with a Markov chain attribution algorithm. Experimental results demonstrate that the proposed model achieves an F 1 score of 83.2% for entity recognition and effectively captures the associations among ship faults. Case studies further verify that the proposed method enhances both the efficiency and interpretability of fault diagnosis while reducing reliance on expert experience，providing effective support for the intelligent operation and maintenance of ship equipment.

Keywords：ship equipment；fault diagnosis；knowledge graph；BERT BiLSTM CRF；knowledge fusion；root-cause analysis

[责任编校：张　众]