

doi: 10.7690/bgzdh.2023.06.005

基于深度学习的小口径弹药装配设备故障诊断专家系统

李 聪¹, 石义官^{1,2}, 黄 权², 李朝将^{1,3}, 赵金库⁴, 赵玉峰⁴

(1. 北京理工大学机械与车辆学院, 北京 100081;

2. 中国兵器装备集团自动化研究所有限公司智能制造事业部, 四川 绵阳 621000;

3. 北京理工大学长三角研究院, 浙江 嘉兴 314000;

4. 黑龙江北方工具有限科技管理部, 黑龙江 牡丹江 157000)

摘要: 针对小口径弹药装配设备故障诊断智能化程度不足、诊断效率低以及误诊率高等问题, 开展小口径弹药装配设备故障诊断技术和专家系统研究。为提高复杂装备故障知识推理及判别精度, 研究基于知识图谱和故障树的故障类别知识库构建方法, 提出基于规则和案例的故障知识推理方法, 采用深度学习算法进行故障知识推理和更新, 构建故障诊断模型并用于小口径弹药装配设备故障诊断专家系统。结果表明: 该系统可实现对小口径弹药装配设备故障的智能预测和分析, 符合制造装备智能化发展要求, 为制造装备智能化、信息化的研制发展和推广应用提供参考。

关键词: 小口径弹药装配设备; 故障诊断; 专家系统; 深度学习; 知识图谱; 故障树

中图分类号: TJ410.5 **文献标志码:** A

Fault Diagnosis Expert System of Small Caliber Ammunition Assembly Equipment Based on Deep Learning

Li Cong¹, Shi Yiguan^{1,2}, Huang Quan², Li Chaojiang^{1,3}, Zhao Jinku⁴, Zhao Yufeng⁴

(1. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081, China;

2. Intelligent Manufacturing Department, Automation Research Institute Co., Ltd. of

China South Industries Group Corporation, Mianyang 621000, China; 3. Yangtze River Delta Research Institute, Beijing Institute of Technology, Jiaxing 314000, China; 4. Science and Technological Management Department,

Heilongjiang North Tool Corporation, Mudanjiang 157000, China)

Abstract: Aiming at the problems of insufficient intelligence, low diagnosis efficiency and high misdiagnosis rate in the fault diagnosis of small caliber ammunition assembly equipment, the fault diagnosis technology and expert system of small caliber ammunition assembly equipment are studied. In order to improve the fault knowledge reasoning and discrimination accuracy of complex equipment, the knowledge base construction method of fault category based on knowledge map and fault tree is studied, and the fault knowledge reasoning method based on rules and cases is put forward. The deep learning algorithm is used to reason and update the fault knowledge, and the fault diagnosis model is constructed and used in the small caliber ammunition assembly equipment fault diagnosis expert system. The results show that the system can realize the intelligent prediction and analysis of the failure of the small caliber ammunition assembly equipment, meet the requirements of intelligent development of manufacturing equipment, and provide a reference for the development and application of intelligent and information manufacturing equipment.

Keywords: small caliber ammunition assembly equipment; fault diagnosis; expert system; deep learning; knowledge map; fault tree

0 引言

小口径弹药装配制造能力和水平是军工基础能力的重要体现, 现代战争对小口径弹药的装配质量和战时保障能力提出更高要求, 迫使小口径弹药装配装备必须向着智能化方向发展。装备发生故障或停机可能造成严重后果, 传统故障诊断主要依靠维修人员经验, 容易造成诊断效率低下、误诊率高。

智能故障诊断结合了信息论、控制论、可靠性理论等, 可针对不同对象特点实现对设备的自动化诊断^[1-5]。司景萍等^[6]建立专家系统和模糊神经网络相结合的发动机智能故障诊断系统框架。何能波等^[7]采用基于 BP 神经网络专家系统设计思路提升系统实用性。随着深度学习快速发展, 基于深度学习的智能故障诊断技术有望成为机械装备故障诊断一大利器。Chen 等^[8]提出一种基于深度神经网络的风电

收稿日期: 2023-01-30; 修回日期: 2023-03-05

基金项目: 军科委基础加强项目(2019-JCJQ-ZD-313-00); 国防基础科研项目(JCKY2020209B002)

作者简介: 李 聪(1998—), 男, 江苏人, 硕士, 从事机器深度学习、装备智能故障诊断研究。E-mail: 3396418915@qq.com。

机组智能故障诊断方法。靳莹等^[9]提出一种基于多层双向长短时记忆网络的装甲车辆柴油机喷油器故障诊断方法。

笔者分析小口径弹药装配设备故障现象及原因，构建相应故障树，通过深度学习算法提取装备多物理源监测数据中蕴含的多域故障信息，利用专家系统智能识别设备故障类型，以便制订维修策略保障小口径弹药装配设备健康运行。

1 小口径弹药装配设备故障分析

故障树模型是一种定性描述设备故障关系的因

果模型，每一个最小割集就是一个底事件^[10]。根据前期设计制造的小口径弹药装配试验验证机构的故障统计数据、小口径弹药装配设备结构及原理，故障主要分为 3 类：1) 停机故障，主要为设备主转子动力卡滞、控制系统、气动系统发生故障；2) 装配质量缺陷，主要为弹体划伤、结弹上顶升杆的上下位置不合适导致质量不能满足系统设计的要求等；3) 其他故障，主要为弹壳缺料、弹壳倒料、结弹吸弹等，会影响设备运行状态和效率。构建小口径弹药装配设备底火装配部分故障树如图 1 所示。

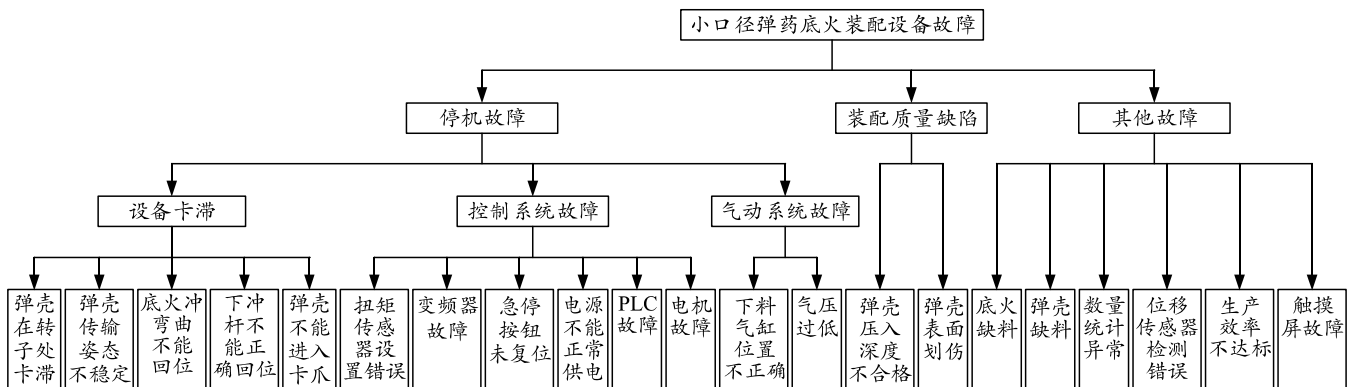


图 1 小口径弹药装配设备底火装配部分故障树

2 小口径弹药装配设备故障诊断专家系统设计

在完成小口径弹药装配设备故障树分析后，可建立故障诊断专家系统，以便操作人员通过简单操作迅速找到装备问题所在，提高故障诊断效率，减小误诊率^[11]。

2.1 专家系统故障知识库构建

2.1.1 基于知识图谱的故障知识提取

小口径弹药装配设备的故障知识来源于设计知

识、试验知识等，从各类数据源中提取与给定故障关联的故障设备、故障原因、故障影响等关键知识要素，基于知识图谱制定一套完善的标准来规范数据类型、数据格式和数据的内容描述^[12]。基于概念和关系模式设计构建装备 E-R 模型如图 2 所示。

2.1.2 基于故障树的故障知识表示

笔者基于小口径弹药装配设备故障树分析，利用产生式规则表示故障知识。产生式规则的形式为：if “条件” then “结论”。以小口径弹药装配设备底火装配部分停机故障树为例，建立规则如图 3 所示。

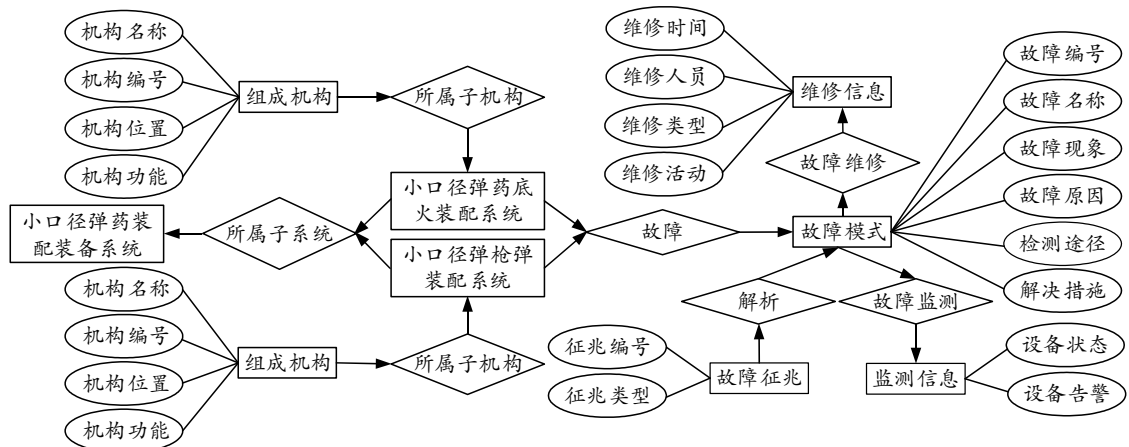


图 2 小口径弹药装配设备 E-R 模型

规则1	if 设备卡滞	then 停机故障
规则2	if 控制系统故障	then 停机故障
规则3	if 气动系统故障	then 停机故障
规则4	if 弹壳在转子处卡滞	then 设备卡滞
规则5	if 弹壳传输姿态不稳定	then 设备卡滞
规则6	if 底火冲弯曲不能回位	then 设备卡滞
规则7	if 下冲杆不能正确回位	then 设备卡滞
规则8	if 弹壳不能进入卡爪	then 设备卡滞
规则9	if 扭矩传感器设置错误	then 控制系统故障
规则10	if 变频器故障	then 控制系统故障
规则11	if 急停按钮未复位	then 控制系统故障
规则12	if 电源不能正常供电	then 控制系统故障
规则13	if PLC故障	then 控制系统故障
规则14	if 电机故障	then 控制系统故障
规则15	if 下料气缸位置不正确	then 气动系统故障
规则16	if 气压过低	then 气动系统故障

图 3 停机故障树故障规则

2.1.3 小口径弹药装配设备故障知识存储

基于 MySQL 数据库、Navicat 软件、故障树和 E-R 模型，建立故障树分类表、故障模式表，如表 1—2 所示，实现小口径弹药装配设备故障知识的管理、整合以及再利用。知识库设计中表的具体定义为：故障树节点与规则条件对应，故障树父节点与规则结论对应，2 类表间以外键建立联系。

表 1 故障树分类

字段名称	数据类型	长度	是否非空	注释
故障类型 ID	Int	11	是	主键
故障树节点	varchar	30	是	-
故障树父节点	varchar	30	是	-
故障装备类型	varchar	30	是	-

表 2 故障模式

字段名称	数据类型	长度	是否非空	注释
故障树节点	varchar	30	是	主键
故障类型 ID	varchar	30	是	外键
故障原因	varchar	200	是	-
故障现象	varchar	200	是	-
检测途径	varchar	200	是	-
解决措施	varchar	200	是	-
监测记录	varchar	200	是	-
维修记录	varchar	200	是	-

历史故障案例中也存在着重要的故障知识，可通过一些统计分析手段获得更加宏观的故障规律^[12]。

2.2 专家系统深度学习算法设计与实验

卷积神经网络(convolutional neural networks, CNN)是一种典型的多层前馈神经网络，其隐含层主要分为卷积层、池化层与全连接层。卷积层通过卷积核对信号进行卷积实现特征提取，池化层主要通过下采样对卷积得到的特征进行降维，卷积层和池化层通常交替组合逐层进行深度特征提取与降维，然后将提取的特征输入全连接层，完成特征表达。CNN 具有稀疏交互、参数共享等特点，可减小网络规模、提高运算效率^[13]。CNN 输入端为原始故

障信号，可实现端到端的故障诊断；因此，笔者采用 1 维卷积神经网络(1D-CNN)对小口径弹药装配设备原始 1 维信号进行特征提取，再结合支持向量机(support vector machine, SVM)进行故障类型分类。

2.2.1 模型训练流程

基于 1D-CNN 和 SVM 神经网络故障诊断主要流程为小口径弹药装配设备故障数据的采集、数据预处理、划分训练集和测试集、模型框架的构建、模型训练与模型性能验证，如图 4 所示。

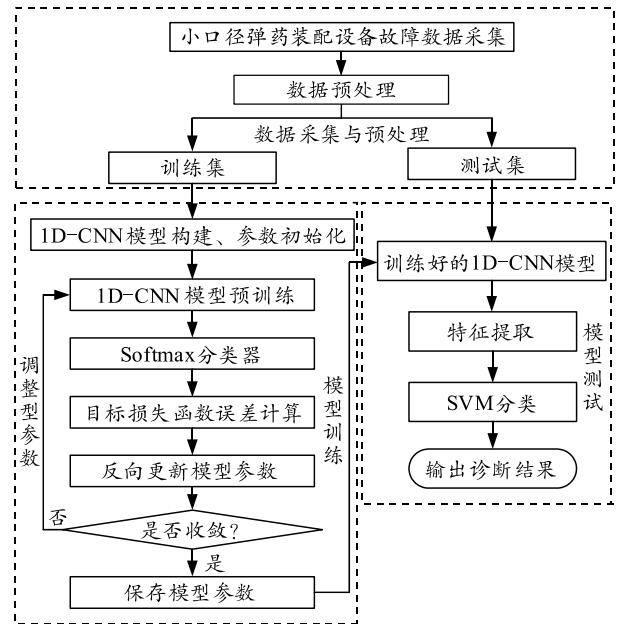


图 4 基于 1D-CNN 和 SVM 的故障诊断流程

2.2.2 数据集构建

为验证笔者所提方法的有效性，采集小口径弹药装配设备故障数据进行实验。布置在小口径弹药装配设备多个工位的振动传感器型号为单轴圆柱形 IEPE 电压输出型 CT020LC，采集卡型号为多功能智能采集系统 HF-AE11E4P3-TR，IEPE 加速度输入接口通道数为 4 路 BNC 接口，AD 转换分辨率为 16 bit，测量精度为±0.5%F.S.，采样速率为 500 kSPS，激励电压为+22~+26 VDC，激励电流为 4 mA，截止频率为 10 kHz。将数据集按照故障类型分类并贴上标签，训练集与测试集按照 4:1 随机划分，如表 3 所示。

2.2.3 1D-CNN 网络结构设计

输入层输出维度为 1 024×1×1，下接 3 组卷积-批量归一化-线性整流函数-池化层。全连接层使用 Dropout 防止过拟合问题，Dropout 比率设置为 0.5，

具体诊断网络结构如表 4 所示。

表 3 故障类型及其对应标签

故障类型	标签	样本数/样本长度	训练集	测试集
上弹壳不到位	1	400/1 024	320	80
弹壳堵料	2	400/1 024	320	80
结弹吸弹	3	400/1 024	320	80
结弹缺弹头	4	400/1 024	320	80
全形吸弹	5	400/1 024	320	80
上料通道缺料	6	400/1 024	320	80
下料卡滞	7	400/1 024	320	80
点胶触发位故障	8	400/1 024	320	80
转子转速异常	9	400/1 024	320	80
正常	0	400/1 024	320	80

表 4 1D-CNN 诊断网络结构

层号	层类别	卷积核大小/步长/个数	输出尺寸
1	输入层	-	1 024×1×1
2	卷积层 1	16×1/4/32	256×1×32
3	批量归一化层	-	256×1×32
4	线性整流函数层	-	256×1×32
5	最大池化层 1	2×1/2/32	128×1×32
6	卷积层 2	4×1/2/64	64×1×64
7	批量归一化层	-	64×1×64
8	线性整流函数层	-	64×1×64
9	最大池化层 2	2×1/2/64	32×1×64
10	卷积层 3	2×1/2/256	16×1×256
11	批量归一化层	-	16×1×256
12	线性整流函数层	-	16×1×256
13	平均池化层 3	2×1/2/256	8×1×256
14	全连接层	-	1×1×128
15	Dropout 丢弃层	-	1×1×128
16	全连接层	-	1×1×10
17	归一化指数函数层	-	1×1×10
18	分类输出层	-	-

2.2.4 模型训练与结果分析

模型误差反向传播算法为 SGDM，算法学习率调度为分段，初始学习率为 0.2，每隔 5 个 Epoch 学习率减小为原来的 0.1 倍。训练轮次共 10 轮，每轮迭代 25 次，最大迭代次数 250 次，验证频率设为每 10 次迭代验证一次。模型在训练集上的损失值与准确率如图 5 所示，在测试集上的损失值与准确率如图 6 所示。




图 5 训练过程的损失值和准确率




图 6 测试过程的损失值和准确率

由上图可知，随着迭代次数的增加，准确率呈上升趋势，损失值呈下降趋势，模型性能越来越好。经过多轮迭代之后，模型在训练集和测试集上的损失最终趋近于 0，识别准确率也趋近于 100%。

CNN 各层都能够提取信号特征，实现深层次的特征表达。t-SNE 工具是基于主元分析的方法对 CNN 各层提取的信号特征进行降维，通过 t-SNE 可实现 CNN 各层特征 2 维或 3 维的直观展示，有利于研究人员对所构建的 CNN 网络性能分析和特征选择^[9]。分别在训练集和测试集上选取笔者所构建的 CNN 网络第 16 层特征进行 2 维展示，训练集特征如图 7 所示，测试集特征如图 8 所示。将上面提取的特征输入到 SVM 中进行分类，测试结果混淆矩阵如图 9 所示，可用来可视化分类结果，从图中可看出仅有少量的样本分类错误，例如有 1 个真实类别为 1 的样本被错分到 9 类别。总体来说，每类样本分类准确率 100%或接近 100%，该模型具有较高的故障诊断率。




图 7 训练集特征可视化




图 8 测试集特征可视化




图 9 测试结果混淆矩阵

2.2.5 模型对比实验

为了比较本文中 1D-CNN+SVM 模型与其他深度学习模型的诊断效果, 分别采用 SVM、BP、1D-CNN、BP+SVM 进行对比实验。考虑到训练过程的偶然性, 在每一轮训练或验证开始之前将训练数据打乱, 每种模型进行 10 次试验, 不同模型训练结果如图 10 所示。分别计算每种模型的平均准确率和标准差, 如表 5 所示, 可知本文中模型较其他模型具有最高的识别率; 同时, 模型的稳定性也优于其他模型, 进一步验证了该模型的有效性。

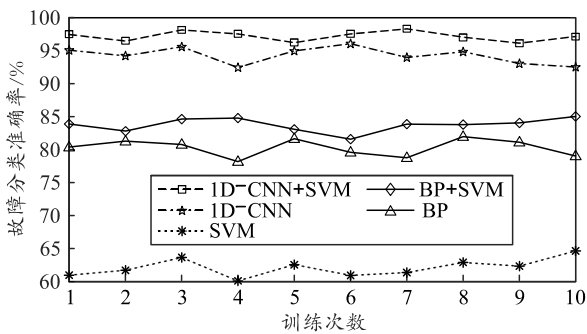


图 10 不同模型分类准确度

2.3 专家系统人机交互界面设计

MATLAB 的 App Designer 模块可通过成熟的 UI 组件快速调用专家系统的底层函数; 因此, 采用该模块进行小口径弹药装配装备故障诊断专家系统

的人机交互和数据交互开发。系统登录界面如图 11 所示。

表 5 不同模型性能对比

深度学习模型	平均准确率/%	标准差
SVM	62.119	1.377
BP	80.276	1.308
1D-CNN	94.275	1.261
BP+SVM	83.752	1.036
1D-CNN+SVM	97.196	0.749



图 11 系统登录界面

根据专家系统故障诊断的需求分析, 对专家系统的功能模块进行划分, 主要包括知识库管理、数据库管理、诊断推理、知识更新、系统设置和退出系统 6 个一级功能模块, 设计专家系统主界面如图 12 所示。



图 12 专家系统主界面

按照诊断分析研究过程, 将一级功能模块进行划分, 比如为建立专家系统的知识库, 根据建立的装备故障知识 E-R 模型, 选取合适的知识表示方式, 按照一定的规则结构将知识库管理模块划分为故障规则库和故障案例库 2 个二级功能模块。具体专家系统功能模块划分如图 13 所示。

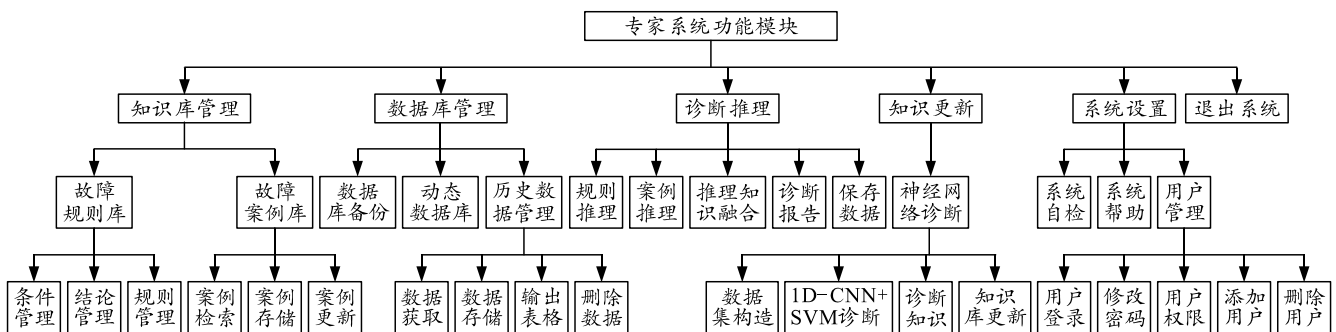


图 13 专家系统功能模块划分

小口径弹药装配设备故障诊断专家系统可通过人机交互界面调用 MySQL 语句进行数据库和知识库的管理操作，其中最常用的 SQL 命令语句如表 6 所示。

表 6 SQL 数据库命令

功能	命令	语句使用形式
查找表中数据	SELECT	SELECT 列名 FROM 表名 WHERE 条件表达式
修改表中数据	UPDATE	UPDATE 表名 SET 列名=新值 WHERE 条件表达式
表中插入数据	INSERT	INSERT INTO 表名 VALUES
删除表中数据	DELETE	DELETE FROM 表名 WHERE 条件表达式

2.4 专家系统综合诊断流程

小口径弹药装配设备故障诊断专家系统接收现场操作人员输入故障信息，信息录入动态数据库中并与故障知识库进行故障特征提取与比较，若不存在匹配，则将小口径弹药装配设备运行采样并预处理后的实时数据通过 1D-CNN+SVM 神经网络自学习机制学习，将得到的知识结果存储于故障知识库中，同时将形成的新规则表达为故障树所对应的树干。若存在匹配，则由推理机利用故障规则库中的规则及故障案例库中的案例分别进行规则推理与案例推理，然后将推理结果融合，得出故障事件类型，通过解释器解释后输出相关故障信息及报警信号，综合处理流程如图 14 所示。其中，规则推理流程如图 15 所示，案例推理流程如图 16 所示。

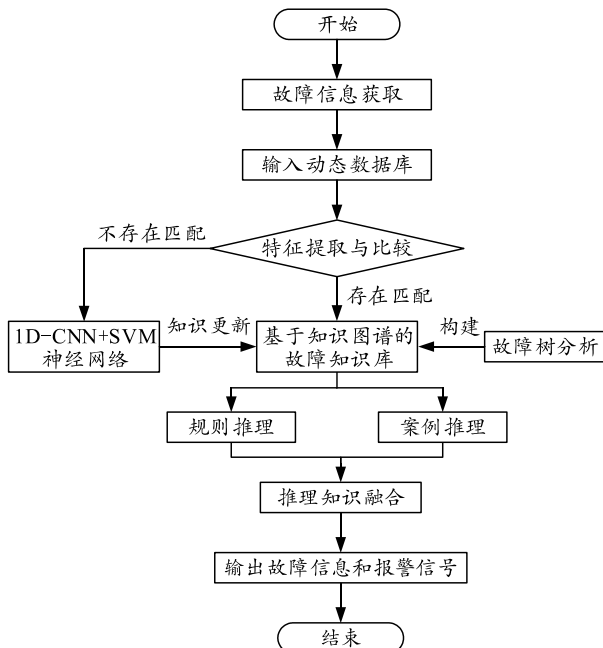


图 14 小口径弹药装配设备故障诊断专家系统综合诊断流程

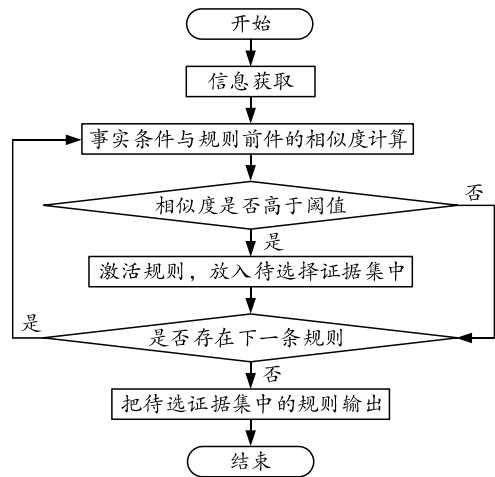


图 15 规则推理流程

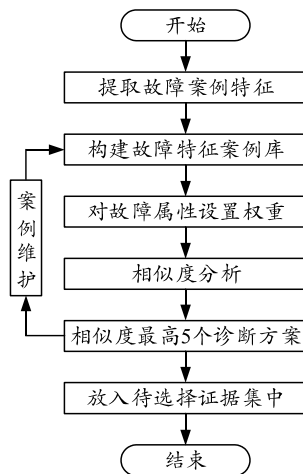


图 16 案例推理流程

3 结束语

1) 针对小口径弹药装配设备结构复杂、故障现象和原因之间层次结构交错的问题，开展装备故障类型分类研究，基于故障树分析法建立了装备的故障树模型，利于故障知识库的构建。

2) 针对小口径弹药装配设备运行过程中识别不同故障类型的精度问题，开展深度学习算法研究，构建了基于 1D-CNN 特征提取和 SVM 故障分类诊断模型，在装备故障数据上进行试验，平均故障识别率可达 97.196%，标准差为 0.749，通过对比 SVM, BP, 1D-CNN, BP+SVM 这 4 种模型，验证了该模型故障识别精度高、稳定性优。将该诊断模型装配在专家系统中用于深层挖掘故障数据潜在特征，有利于故障知识的不断累积和更新，为装备的故障诊断提供一定的技术支持。

3) 针对小口径弹药装配设备运行维护过程中涉及到的故障信息众多且零散的问题，开展专家系统研究，提出基于知识图谱进行故障知识提取和基

于故障树进行故障知识表达的方法, 利用 MySQL 数据库对具有复杂关系的故障知识进行系统性的管理和应用, 并利用 MATLAB 的 App Designer 模块进行人机交互界面设计, 提高装备故障诊断效率。

参考文献:

[1] LEI Y G, YANG B, JIANG X W, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap[J]. Mechanical Systems and Signal Processing, 2020, 138: 106587.

[2] 李泓江, 孙吉伟, 朱庆谭. 便携式小口径弹药拔弹机设计技术[J]. 兵工自动化, 2022, 41(7): 82-85.

[3] 张伟, 徐争涛, 李红梅, 等. 自动化控制技术在火帽柔性自动装配机中的应用[J]. 兵工自动化, 2022, 41(8): 31-35.

[4] 梁海洋, 张瀚铭, 孙科星. 基于工业互联网的高危产品装配生产线智能管控平台设计[J]. 兵工自动化, 2021, 40(12): 24-28.

[5] 庄金良, 高欣宝, 武洪文. 弹药装备在役考核安全风险探析[J]. 兵工自动化, 2021, 40(12): 92-96.

[6] 司景萍, 马继昌, 牛家骅, 等. 基于模糊神经网络的智能故障诊断专家系统[J]. 振动与冲击, 2017, 36(4):

164-171.

[7] 何能波, 吴红朴, 孙金, 等. 基于人工智能装备故障诊断应用研究[J]. 装备制造技术, 2022(4): 266-269.

[8] CHEN L T, XU G H, ZHANG Q, et al. Learning deep representation of imbalanced SCADA data for fault detection of wind turbines[J]. Measurement, 2019, 139: 370-379.

[9] 靳莹, 乔新勇. 基于多层双向长短时记忆网络的装甲车辆柴油机喷油器故障诊断[J]. 兵工自动化, 2022, 41(1): 34-38.

[10] 韩光, 赵春雪, 宋晨. 一种基于最小割集的故障树分析模型研究和算法实现[J]. 中国管理信息化, 2021, 24(20): 180-183.

[11] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.

[12] 巩宇, 李碧薇, 李德华, 等. 基于知识图谱的电力设备故障知识库构建方法[J]. 计算机科学与技术, 2021, 39(4): 72-77.

[13] 吴定海, 任国全, 王怀光, 等. 基于卷积神经网络的机械故障诊断方法综述[J]. 机械强度, 2020, 42(5): 1024-1032.

(上接第 7 页)

至此整个推演过程结束, 完成了对某岛夺取与控制的全流程推演, 验证了体系结构模型的一致性及完整性。

4 结束语

笔者梳理了 DoDAF 体系建模的主要流程, 分析了核心的视图及视点, 并通过某岛夺取与控制任务进行了仿真推演, 推演了作战要素及其之间的运行策略, 整个推演过程能够更清晰地描述作战场景下的需求, 为后续装备需求提供决策参考。

参考文献:

[1] 陈奎兆, 王江云. 飞行仿真器自动飞行系统研究[J]. 系统仿真学报, 2006, 18(z2): 706-709.

[2] 宋友凯, 严建钢, 曾家有. 护航编队中防空舰艇反导作战队形的研究[J]. 舰船电子工程, 2010, 30(3): 27-29.

[3] 陆敏, 王国刚, 黄湘鹏, 等. 解读北约体系结构框架 NAF [J]. 指挥控制与仿真, 2010, 32(5): 117-122.

[4] 黄文化, 罗强一, 张新强, 等. 国防部体系结构框架 2.0 新发展研究[J]. 计算机光盘软件与应用, 2012(4): 187-188.

[5] 李龙跃, 刘付显. DoDAF 视图下的反导作战军事概念模与仿真系统设计[J]. 指挥控制与仿真, 2012, 34(5): 76-80.

[6] 李雪超, 张金成, 陈欢欢, 等. 基于 DoDAF 的多层弹道导弹防御系统模型研究[J]. 指挥控制与仿真, 2010, 32(5): 45-48.

[7] 朱刚, 谭贤四, 王红, 等. 军事体系结构框架元模型发展趋势[J]. 飞航导弹, 2014(6): 62-67.

[8] 周菁, 杨鸣坤, 王磊, 等. 基于 DoDAF 的有/无人协同特战系统总体结构设计[J]. 兵工自动化, 2021, 40(1): 3-7.

[9] 吴昊, 王宇. 基于 STK 的 MEO 卫星通信系统的仿真与覆盖分析[J]. 电子设计工程, 2017, 25(22): 120-123.

(上接第 11 页)

[15] 赵建忠, 李海军, 方轶, 等. 航母航空弹药作战保障能力建设[J]. 国防科技, 2016, 37(4): 104-108.

[16] 岳奎志, 韩维, 陈小卫, 等. 载机军舰航空弹药储运系统建模与仿真分析[J]. 计算机应用, 2011, 31(12): 3425-3428, 3433.

[17] 吕开东, 朱齐丹, 李新飞. 舰载机航空保障需求及排队网络模型研究[J]. 飞行力学, 2014, 32(1): 88-92.

[18] 吕晓峰, 李保刚, 周玉柱. 基于遗传算法的航空弹药保障人员优化配置[J]. 计算机与现代化, 2011(10): 11-14.

[19] 邱国斌. 航空弹药供应保障研究—基于 AHP 和 DEA 方法[J]. 郑州航空工业管理学院学报, 2015, 33(6): 28-32.