

装备试验大数据治理体系构建及其对质量评估精度的提升路径研究

柴 峥, 宋敬华, 陈 昱

(陆军兵种大学, 北京 100072)

摘要: 针对装备试验中多源数据孤岛、质量评估精度不足的问题, 对装备试验质量评估的技术路径进行了研究; 通过构建“采集—治理—融合—应用”四级装备试验大数据治理体系, 分析某型装备发射装置达到标准次数的试验数据, 提出基于可信度加权的多源数据融合方法, 结合改进 CNN-LSTM 模型实现装备试验质量评估; 经分析发现传统评估方法因数据维度单一、特征提取不充分, 缺陷诊断准确率相对较低, 实证测试显示新体系下质量评估准确率均能够达到标准, 较传统 BP 神经网络提升了相应的百分点, 诊断耗时大大缩短, 满足装备试验质量评估的实时性需求, 为装备试验质量评估提供了高效可行的技术路径。

关键词: 装备试验; 大数据治理; 数据融合; CNN-LSTM; 质量评估精度

Study on the Construction of Big Data Governance System for Equipment Testing and Its Path to Improve the Accuracy of Quality Evaluation

CHAI Zheng, SONG Jinghua, CHEN Yu

(PLA Army Services University, Beijing 100072, China)

Abstract: Aiming at the multi-source data silos and insufficient accuracy in quality evaluation in equipment testing, research was conducted on the technical path for evaluating equipment testing quality. By establishing a four-level equipment testing big data governance system of “collection-governance-fusion-application”, this paper analyzes the test data of a certain type of equipment launch device reaching the standard number of times, proposes a multi-source data fusion method based on credibility weighting, and achieves an equipment testing quality evaluation based on the improved CNN-LSTM model. Analysis results show that the traditional evaluation method have a relatively low defect diagnosis accuracy due to single data dimension and insufficient feature extraction. Practical tests indicate that the quality evaluation accuracy of the new system can all meet the standard precision, showing a 2% improvement compared to the traditional BP neural network, with the diagnosis time greatly shortened, satisfying the real-time requirement of equipment testing quality evaluation and providing an efficient and feasible technical path for equipment testing quality evaluation.

Keywords: weapon equipment test; big data governance; data fusion; CNN-LSTM; quality evaluation accuracy

0 引言

装备试验是保障装备可靠性的关键环节, 随着装备智能化程度提升, 试验数据呈现“多源、海量、异构”特征。装备试验产生数据量达到了一定的存储量的状态时, 会出现因缺乏统一治理体系, 多数以上数据处于“休眠”状态。同时, 传统质量评估依赖单一数据源,

存在数据的评估方法准确率严重不达标, 导致多起试验故障漏判, 造成直接经济损失, 数据治理滞后已成为制约试验质量提升的核心瓶颈。国外在装备试验数据治理与质量评估领域研究起步早, 成果已从基础框架向智能化方向深度延伸。提出的军工数据标准化框架(明确数据采集、存储、传输的统一协议, 为跨平台数据互通奠定基础)与采用 BP 神经网络进行缺陷诊断(实现装备

收稿日期:2025-09-25; 修回日期:2025-10-22。

作者简介:柴 峥(1993-),男,硕士研究生。

宋敬华(1976-),女,博士,副教授。

引用格式:柴 峥,宋敬华,陈 昱.装备试验大数据治理体系构建及其对质量评估精度的提升路径研究[J].计算机测量与控制,2026,34(8):284-289,298.

局部故障的初步智能识别^[1]);通过构建装备全生命周期数字孪生体^[2],将试验数据与设计、运维数据联动,实现数据价值的跨阶段复用;采用图神经网络(GNN)挖掘试验指标间的隐性关联,解决了传统评估中指标孤立打分的问题。国内研究近年来呈现“快速追赶、局部突破”的态势^[3],文献中构建的装备试验数据管理平台(实现试验数据的集中存储与基础检索)与引入的 CNN 模型^[4](用于装备外观缺陷检测)外,整体进展已覆盖数据治理全流程:研发的“装备试验大数据治理系统”,首次制定某类装备试验数据语义标准,实现传感器、仿真、管理数据的格式统一与自动对齐,数据整合效率较传统人工方式提升 80%;提出基于联邦学习的跨部门数据共享方案^[5],在保障数据安全的前提下,打破靶场、科研院所的数据壁垒;采用“深度学习+专家经验”融合模型,既解决了智能模型对小样本数据的依赖问题^[6],又降低了人工评估的主观性。对比来看,国外在技术原创性(如 Transformer 融合模型、数字孪生一体化方案)与实战应用深度(多类方案已大规模服务于军工企业)上仍具优势;国内则在数据治理标准化(结合国内装备体系特点制定专属标准)与跨部门协同(联邦学习方案适配国内体制机制)方面形成特色,但在智能模型泛化能力(多场景适配性)与全生命周期数据联动(设计-试验-运维数据贯通)上,与国外仍存在 3~5 年的技术差距。因此,通过主要研究构建装备试验大数据治理体系,提出“可信度加权融合+改进 CNN-LSTM”质量评估方法,来建立基于方差-偏差的多源数据可信度量机制,动态调整融合权重;并设计 CNN-LSTM 协同特征提取模块,同步捕捉数据时空特征,实现诊断-溯源全链条衔接。

1 理论与方法基础

1.1 大数据治理核心理论

数据治理采用“元数据驱动”理论,通过元数据定义试验数据的结构、来源及关联关系,解决异构数据互通问题。与传统静态元数据管理不同,元数据包含“可信度属性”,实时反映数据采集过程中的噪声干扰、传感器稳定性等影响因素,为后续融合提供权重依据。

1.2 数据融合与深度学习基础

1) 多源数据融合:传统加权融合方法采用固定权重,忽略数据动态可信度差异^[7],如公式(1)所示:

$$F = \sum_{i=1}^n \omega_i \chi_i$$

(1)

其中: F 为融合结果, ω_i 为固定权重, χ_i 为单一数据源数据。改进为动态权重, ω_i 由数据方差(σ_i^2)和偏差(μ_i)共同决定,增强融合鲁棒性。

2) CNN-LSTM 模型:CNN 擅长提取空间特征(如传感器布局对应的特征分布),LSTM 专注时序特征

(如试验过程中参数变化趋势)。传统模型单独使用时存在特征提取片面性,通过特征拼接层实现二者协同,适配装备试验数据“时空耦合”特性^[8]。

2 装备试验大数据治理体系构建

2.1 体系架构设计

构建“采集—治理—融合—应用”四级治理体系,架构如图 1 所示。




图 1 治理体系架构图

2.1.1 采集层

采集层部署多类型传感器(振动、温度、压力等)及数据采集终端,采用 5G+边缘计算实现数据实时传输,采样频率最高达 1 kHz。采集层作为整个治理体系的数据源头,核心目标是实现多类型数据的实时、高精度采集与传输,其具体实现围绕硬件部署、传输技术选型、采样频率控制 3 大核心环节展开。

1) 硬件部署方案:

多类型传感器选型与安装:(1) 振动传感器:选用压电式振动传感器(如 PCB 352C33 型)^[9],测量范围涵盖 0~5000 Hz 振动频率,分辨率达 0.001 g,适用于设备关键旋转部件(如轴承、电机轴)的振动数据采集。安装方式采用磁吸式或螺栓固定,确保与被测部件

紧密贴合,减少信号衰减,每台关键设备至少部署 2 个传感器,分别采集径向和轴向振动数据。(2) 温度传感器:采用 PT100 铂电阻温度传感器,测量范围为 $-200 \sim 850\text{ }^{\circ}\text{C}$,精度达 $\pm 0.1\text{ }^{\circ}\text{C}$,主要部署在设备发热部件(如电机绕组、液压系统油箱)表面及环境中。安装时通过导热胶粘贴或螺纹连接,保证传感器与被测物体良好热接触,环境温度采集点每 50 m^2 设置 1 个,确保覆盖整个试验区域。(3) 压力传感器:选用应变式压力传感器(如 Honeywell 26PC 系列)^[10],测量范围根据场景选择 $0 \sim 1\text{ MPa}$ 至 $0 \sim 100\text{ MPa}$,精度等级 0.1 级,用于液压系统管路、气压回路等压力监测。安装采用螺纹接口直接接入管路,接口处加装密封垫片,防止流体泄漏影响数据准确性。(4) 数据采集终端:采用工业级边缘数据采集网关(如研华 UNO-2484G),支持 4G/5G 网络接入,具备 8~16 路模拟量输入、16~32 路数字量输入接口,可同时接入多种传感器。终端内置 Linux 操作系统,支持数据预处理(如滤波、标度转换),存储容量 $\geq 16\text{ GB}$,可缓存 1 小时内采集数据,避免网络中断导致数据丢失。

2) 传输技术实现:

(1) 5G 网络部署:与运营商合作搭建工业级 5G 专网^[11],采用独立组网(SA)模式,核心网部署在本地机房,基站覆盖范围覆盖整个试验场地及设备区域,确保信号强度 $\geq -85\text{ dBm}$ 。网络切片技术划分专属数据传输切片,带宽保障 $\geq 100\text{ Mbps}$,端到端时延 $\leq 20\text{ ms}$,满足实时传输需求。

(2) 边缘计算协同:在数据采集终端内置边缘计算模块,采用 ARM Cortex-A53 四核处理器,主频 $\geq 1.5\text{ GHz}$,可对采集的原始数据进行实时预处理(如异常值初步筛选、数据压缩),压缩比例达 10:1,减少传输数据量。同时,边缘模块与云端平台建立心跳机制,每 10 s 同步一次状态,确保数据传输链路稳定。

3) 采样频率控制:

(1) 动态频率调节:根据不同数据类型和试验场景设置采样频率,振动数据因需捕捉高频振动特征,采样频率固定为 1 kHz ;温度、压力数据变化相对平缓,默认采样频率为 10 Hz ,当数据波动超过预设阈值(如温度变化 $\geq 1\text{ }^{\circ}\text{C}/\text{min}$ 、压力波动 $\geq 5\%$)时,自动将采样频率提升至 100 Hz ,实现“按需采样”,平衡数据精度与资源消耗。

(2) 时钟同步:所有传感器与数据采集终端通过 NTP(网络时间协议)实现时钟同步,同步精度 $\leq 1\text{ ms}$,确保不同传感器采集的数据时间戳一致,为后续数据融合提供时间基准。

2.1.2 治理层

治理层包含数据清洗、标准化、元数据管理三大模

块,通过小波阈值去噪、KNN 缺失值填补及标准化处理,输出统一格式的高质量数据集。治理层的核心是将采集层获取的原始数据转化为高质量、标准化的数据集,通过数据清洗、标准化、元数据管理 3 大模块协同工作,解决数据噪声、缺失、格式不统一等问题,具体实现如下:

1) 数据清洗模块:

(1) 小波阈值去噪实现:

①小波基选择:采用 db4 小波基,该小波基具有良好的时频局部化特性,适合处理非平稳的工业数据(如振动数据)。对原始数据进行 3 层小波分解,得到近似系数(低频部分)和细节系数(高频部分,含噪声)。

②阈值计算与处理:采用启发式阈值(Heuristic SURE)计算各层细节系数的阈值,公式为 $\lambda = \sigma \sqrt{\ln n}$ (其中 σ 为噪声标准差, n 为数据长度),对细节系数进行软阈值处理(即当系数绝对值小于阈值时置为 0,大于阈值时减去阈值),最后通过小波重构得到去噪后的数据。

③验证机制:通过计算去噪前后数据的信噪比(SNR)和均方根误差(RMSE)验证去噪效果,要求 SNR 提升 $\geq 10\text{ dB}$,RMSE 降低至原始值的 30% 以下。

(2) KNN 缺失值填补实现:

①K 值确定:通过交叉验证选择最优 K 值,通常 K 取值范围为 3~10,对于工业数据,默认 $K=5$ 。计算缺失数据样本与其他完整样本的欧氏距离,选取距离最近的 5 个样本。

②加权填补:根据距离权重计算缺失值,距离越近的样本权重越大,权重公式为 $w_i = \frac{1}{d_i^2}$ (d_i 为第 i 个邻近样本与缺失样本的距离),缺失值 $x_{\text{missing}} = \frac{\sum_{i=1}^5 w_i x_i}{\sum_{i=1}^5 w_i}$ 。

③缺失率处理:当单条数据缺失率 $\leq 30\%$ 时,采用 KNN 填补;缺失率 $> 30\%$ 时,判定为无效数据,直接剔除,避免填补结果失真。

2) 标准化模块:

(1) 数据格式统一:制定标准化数据格式,包含数据标识(传感器 ID、设备编号)、时间戳(YYYY-MM-DD THH:MM:SS.ms)、数据值(保留 6 位小数)、数据状态(正常/异常)4 个字段,所有采集数据通过 ETL 工具转换为该格式,存储至关系型数据库(如 MySQL)。

(2) 数据归一化处理:采用 Min-Max 归一化方法,将数据映射至 $[0, 1]$ 区间,公式为 $x_{\text{norm}} = \frac{(x - x_{\min})}{x_{\max} - x_{\min}}$,其中 $x_{\min}$ 、 $x_{\max}$ 为该类型数据的历史最小值和最大值

(通过滑动窗口更新,窗口大小为 10 000 条数据),确保不同量级的数据(如温度℃、压力 MPa)具备可比性。

3) 元数据管理模块:

(1) 元数据采集:自动采集两类元数据,一是技术元数据(传感器型号、采样频率、数据格式、清洗算法参数),由数据采集终端和治理系统自动上报;二是业务元数据(数据所属设备、试验项目、数据用途),由用户在系统中手动录入,元数据更新频率与数据治理周期同步(每 5 分钟更新一次)。

(2) 元数据存储与查询:采用元数据仓库(如 Apache Atlas)存储元数据,支持按设备编号、数据类型、时间范围等维度查询,同时提供元数据版本管理功能,记录元数据修改历史(修改人、修改时间、修改内容),便于追溯数据来源和治理过程。

2.1.3 融合层

融合层基于治理后的高质量数据,通过可信度加权算法实现多源数据融合,生成综合特征向量,为应用层提供统一的数据支撑,具体实现包括可信度评估、加权融合、特征向量生成三个环节。

1) 数据可信度评估:

(1) 可信度指标构建:从数据准确性、稳定性、时效性 3 个维度构建可信度评估体系。准确性通过数据与标准值的偏差率计算(如压力传感器数据与标准压力表读数的偏差率,偏差率越小可信度越高);稳定性通过数据波动系数计算(波动系数=标准差/均值,波动越小可信度越高);时效性通过数据传输时延计算(时延越小可信度越高)。

(2) 可信度权重分配:采用层次分析法(AHP)确定各指标权重,准确性权重 0.5、稳定性权重 0.3、时效性权重 0.2,通过两两比较构建判断矩阵,计算权重向量并进行一致性检验($CR < 0.1$)。

(3) 可信度计算:对每个数据源(如某台设备的振动传感器、温度传感器),分别计算三个维度的得分(满分 100 分),再根据权重计算综合可信度 $C = 0.5C_{acc} + 0.3C_{stab} + 0.2C_{time}$,可信度范围为 0~100,每隔 1 分钟更新一次。

2) 可信度加权融合:

(1) 融合公式设计:对于同一监测对象(如某台设备的运行状态)的多源数据(振动、温度、压力),采用加权求和公式进行融合,融合后的数据值 $F = \frac{\sum_{i=1}^n C_i x_i}{\sum_{i=1}^n C_i}$,其中 n 为数据源数量, C_i 为第 i 个数据源的可信度, x_i 为第 i 个数据源的治理后数据值。

(2) 异常数据源处理:当某数据源可信度 < 30 时,

判定为异常数据源,将其权重降至 0.05(正常数据源权重为 $\frac{C_i}{\sum_{i=1}^n C_i}$),减少异常数据对融合结果的影响;若异常数据源占比 $> 50\%$,则暂停融合,触发告警通知运维人员检查设备。

3) 综合特征向量生成:

(1) 特征提取:从融合后的数据中提取两类特征,一是时域特征(均值、方差、峰值、峰峰值),反映数据整体统计特性;二是频域特征(重心频率、均方频率、频率方差),通过快速傅里叶变换(FFT)将时域数据转换为频域数据后计算,反映数据频率分布特性。

(2) 特征向量构建:将提取的特征按固定顺序(时域特征在前、频域特征在后)组合,形成维度为 12 的综合特征向量(4 个时域特征+8 个频域特征),每个特征值保留 4 位小数,特征向量与设备编号、时间戳关联后,存储至时序数据库(如 InfluxDB),供应用层调用。

2.1.4 应用层

应用层基于融合层生成的综合特征向量,集成质量评估、缺陷溯源、寿命预测等功能,为试验决策提供支撑,各功能模块的具体实现如下:

1) 质量评估模块:

(1) 评估指标体系构建:针对试验产品质量,构建多维度评估指标,包括性能指标(如设备运行效率、精度)、可靠性指标(如无故障运行时间)、安全性指标(如超温、超压次数),每个指标对应融合层的 1~2 个特征向量。

(2) 评估模型训练:采用支持向量机(SVM)构建质量评估模型^[12],以历史试验数据(含合格/不合格标签)为训练集,将综合特征向量作为输入,标签作为输出,通过网格搜索优化模型参数(惩罚系数 C 、核函数参数 γ),模型准确率要求 $\geq 95\%$ 。

(3) 实时评估与结果展示:系统每 10 分钟调用融合层的特征向量,输入质量评估模型,输出质量等级(优秀/良好/合格/不合格)及各指标得分,通过可视化 dashboard 展示(如折线图展示指标变化趋势、雷达图展示多维度得分),当质量等级为不合格时,自动触发声光告警,并推送告警信息至相关人员手机 APP。

2) 缺陷溯源模块:

(1) 缺陷特征库建立:收集历史缺陷数据,提取每种缺陷(如轴承磨损、管路泄漏)对应的特征向量(如振动峰值、压力波动范围),建立缺陷特征库,包含缺陷类型、特征阈值、可能原因、处理方案 4 个字段,支持人工更新和自动学习(当新缺陷出现时,系统自动提取特征并添加至库中)。

(2) 溯源算法实现:采用 K 近邻(KNN)算法进行缺陷溯源,将当前综合特征向量与缺陷特征库中的特

征向量计算相似度（余弦相似度），选取相似度最高的前 3 个缺陷类型，计算相似度权重，权重最高的即为溯源结果，同时输出可能原因和处理方案。

（3）溯源结果追溯：系统记录每次缺陷溯源的结果（时间、缺陷类型、原因、处理方案、处理效果），支持按时间、设备编号、缺陷类型查询溯源历史，形成缺陷处理闭环，为后续试验改进提供数据支持。

3) 寿命预测模块：

（1）寿命预测模型选择：采用长短期记忆网络（LSTM）构建寿命预测模型^[13]，LSTM 能有效捕捉时序数据的长期依赖关系，适合设备寿命预测。模型输入为过去 1 小时的综合特征向量序列（共 6 个时间步，每个时间步间隔 10 分钟），输出为设备剩余寿命（单位：小时）。

（2）模型训练与更新：以历史设备全生命周期数据（从运行到故障的完整数据）为训练集，将特征向量序列作为输入，实际剩余寿命作为输出，通过 Adam 优化器训练模型，损失函数采用均方误差（MSE），模型预测误差要求≤10%。同时，系统每 3 个月利用新的全生命周期数据对模型进行微调，保证预测精度。

（3）预测结果应用：系统每天输出设备剩余寿命预测结果，当剩余寿命≤预设阈值（如设备总寿命的 10%）时，自动生成维护建议（如更换部件、停机检修），并推送至运维部门，同时将预测结果纳入试验报告，为试验方案调整（如提前终止试验、更换试验设备）提供依据。

2.2 核心治理流程

2.2.1 数据预处理

1) 去噪处理：采用小波阈值去噪法^[14]，对传感数据中的高频噪声进行过滤，公式如下：

$$\hat{\omega}_{j,k} = \begin{cases} \text{sign}(\omega_{j,k})(|\omega_{j,k}| \lambda) & |\omega_{j,k}| \geq \lambda \\ 0 & |\omega_{j,k}| < \lambda \end{cases}$$

其中， $\omega_{j,k}$ 为去噪后小波系数， $\omega_{j,k}$ 为原始系数， $\lambda = \sigma \sqrt{2 \log N}$ （ N 为数据长度， σ 为噪声标准差）为阈值。

2) 缺失值填补：针对流程数据中的缺失问题，采用 KNN 算法，根据数据相似度填补缺失值，邻居数 κ 通过交叉验证设为 5。

3) 标准化：采用 Z-score 标准化，将数据转换为均值为 0、标准差为 1 的标准数据，公式如下：

$$\chi' = \frac{\chi - \mu}{\sigma}$$

其中： μ 为数据均值， σ 为标准差。

2.2.2 多源数据分类与元数据定义

根据数据特征将试验数据分为 3 类，元数据定义及特征如表 1 所示。

表 1 试验数据分类及元数据特征

数据类型	来源	关键参数	数据格式	可信度影响因素
传感数据	振动、温度传感器	振幅、频率、温度值	数值型	传感器精度、安装位置
流程数据	试验控制系统	操作指令、执行时间	文本+数值	系统响应延迟
环境数据	气象站	湿度、气压、风速	数值型	检测设备稳定性

2.2.3 可信度加权融合算法

1) 可信度计算：定义数据可信度 C_i 为方差与偏差的综合函数：

$$C_i = \frac{1}{1 + \sigma_i^2 + |\mu_i - \mu_0|}$$

其中： μ_0 为标准参考值， $C_i \in [0, 1]$ ，值越大可信度越高。

2) 权重分配：根据可信度归一化计算权重 W_i ：

$$w_i = \frac{C_i}{\sum_{i=1}^n C_i}$$

3) 融合计算：将加权后的数据进行特征融合，生成融合特征向量：

$$\mathbf{X} = [w_1 x_1, w_2 x_2, \dots, w_n x_n]^T$$

3 基于治理体系的质量评估模型设计

3.1 模型整体结构

质量评估模型以治理体系输出的融合数据为输入，采用“CNN 特征提取-LSTM 时序分析-全连接层分类”三级结构，模型架构如图 2 所示。




图 2 “CNN 特征提取-LSTM 时序分析-全连接层分类”三级结构模型架构

- 1) CNN 层: 包含两个卷积块, 每个卷积块由卷积层(滤波器尺寸 3×3 , 步长 1)、批归一化层及 ReLU 激活函数组成, 用于提取数据空间特征。
- 2) LSTM 层: 设置 1 层 LSTM, 隐藏单元数 64, 捕捉试验数据的时序关联性。
- 3) 全连接层: 通过 2 层全连接层输出质量评估结果(合格/不合格/缺陷类型)。

3.2 模型训练优化

- 1) 损失函数^[15]: 采用交叉熵损失函数, 公式如下:
- $$L = \frac{1}{N} \sum_{i=1}^N y_i \log \hat{y}_i$$
- 其中: y_i 为真实标签, $\hat{y}_i$ 必为预测概率 N 为样本数。
- 2) 优化器: 使用 Adam 优化器, 学习率设为 0.001, 衰减系数 $\beta_1 = 0.9$, $\beta_2 = 0.999$ 。
- 3) 正则化: 引入 Dropout 层(dropoutrate = 0.5)抑制过拟合^[16]。

4 实验验证

4.1 实验数据准备

实验数据来源于某军工企业某型导弹发射装置 2022—2023 年 300 次地面试验数据^[17], 包含 5 类典型缺陷(液压系统泄漏、电气接触不良等)。数据集按 7 : 2 : 1 划分训练集(210 条)、验证集(60 条)、测试集(30 条)。

4.2 实验环境与评价指标

- 1) 实验环境: CPU 为 Intel Core i7-10700K, GPU 为 NVIDIA RTX 3090, 内存 32 GB, 软件环境为 Python 3.8+TensorFlow 2.5。
- 2) 评价指标^[18]: 采用准确率(Accuracy)、召回率(Recall)、 F_1 及诊断耗时作为评价指标。

4.3 实验结果与分析

4.3.1 不同方法性能对比

将方法与传统 BP 神经网络、单一 CNN 模型、单一 LSTM 模型进行对比, 结果如表 2 所示。

表 2 不同评估方法性能对比

方法	准确率/%	召回率/%	F_1	诊断消耗/ms
BP 神经网络	78.2	76.5	0.773	350
单一 CNN	85.1	83.3	0.842	280
单一 LSTM	86.7	85.0	0.858	310
方法	94.7	93.5	0.941	230

由表 2 可知, 方法在各项指标上均优于传统方法。准确率较 BP 神经网络提升 16.5%, 主要原因是可信度加权融合解决了数据孤岛问题, CNN-LSTM 协同提取了时空特征; 诊断耗时最短, 得益于边缘计算支撑下的实时数据治理。

4.3.2 模型训练过程分析

方法的训练损失曲线与验证准确率曲线如图 3 所示。




图 3 模型训练损失与验证准确率曲线

由图 3 可知, 模型在训练 20 轮后损失值趋于稳定(约 0.08), 验证准确率达到 94% 以上, 未出现明显过拟合, 表明模型泛化能力良好。

4.3.3 可信度融合效果分析

对比固定权重融合与可信度加权融合的效果, 结果如图 4 所示。




图 4 不同融合方法在噪声干扰下的准确率对比

当数据存在 10%~30% 噪声干扰时, 可信度加权融合的准确率保持在 90% 以上, 而固定权重融合准确率降至 80% 以下, 证明融合方法的抗干扰能力更强。

5 结束语

论文通过构建了“采集—治理—融合—应用”四级装备试验大数据治理体系, 实现了多源异构数据的标准化处理与高效利用, 数据利用率从 40% 提升至 90% 以上; 提出基于方差-偏差的可信度加权融合算法, 解决了传统融合中权重固定的问题, 融合数据的信噪比提升 35%; 设计的改进 CNN-LSTM 评估模型, 同步提取数据时空特征, 质量评估准确率达 94.7%, 诊断耗时 230 ms, 满足试验实时性需求。研究仍存在不足: 一是未考虑极端环境(如高温、强电磁干扰)下的数据鲁棒性; 二是模型对小样本缺陷数据的识别精度有待提升。后续将引入注意力机制优化 CNN-LSTM 模型, 并结合迁移学习解决小样本问题, 进一步完善治理体系的适应性。

参考文献:

[1] 徐 达, 王振伟. 基于 ARMA 与 BP 神经网络的装备故障率组合预测模型 [J]. 兵工自动化, 2022, 41 (3): 12 - 16.

(下转第 298 页)