

基于多源试验大数据融合的装备质量缺陷诊断与溯源研究

宋敬华, 柴 峥, 夏 鑫

(陆军兵种大学, 北京 100072)

摘要: 针对装备试验中多源数据孤岛、质量缺陷诊断准确率低、溯源定位模糊等问题, 提出一套“融合—诊断—溯源”全链条技术方案: 构建多源试验数据采集体系, 采用改进加权融合算法实现异构数据集成, 设计 CNN-LSTM 融合模型提取时空特征并识别缺陷类型, 基于贝叶斯网络建立溯源模型定位根因等方法达到了试验数据融合准确率、缺陷诊断准确率、溯源平均误差等指标均明显向目标指数变化, 较传统方法综合性能明显提升, 为装备试验质量管控提供技术支持。

关键词: 装备试验; 多源大数据融合; 质量缺陷诊断; 缺陷溯源; CNN-LSTM 模型

Study on Equipment Quality Defect Diagnosis and Traceability Based on Multi-source Test Big Data Fusion

SONG Jinghua, CHAI Zheng, XIA Xin

(PLA Army Services University, Beijing 100072, China)

Abstract: To address issues such as multi-source data silos, low accuracy in quality defect diagnosis, and unclear traceability positioning in equipment testing, a full-chain technical solution of “Fusion-Diagnosis-Traceability” is proposed. Construct a multi-source test data collection system, adopt an improved weighted fusion algorithm to integrate with heterogeneous data, design a CNN-LSTM fusion model to extract spatiotemporal features and identify defect types, establish a traceability model based on Bayesian networks for root cause localization, and significantly improve the indicators of test data fusion accuracy, defect diagnosis accuracy, and average traceability error toward the target values. Compared with traditional methods, the proposed solution remarkably enhances its comprehensive performance, and provides a technical support for quality control in equipment testing.

Keywords: weapon equipment test; multi-source big data fusion; quality defect diagnosis; defect traceability; CNN-LSTM Model

0 引言

在国防现代化建设进程中, 装备正朝着智能化、集成化、复杂化方向快速升级, 其技术含量与系统复杂度大幅提升, 这直接导致装备试验过程中数据生成量呈指数级增长。据行业统计数据显示, 当前单套复杂装备(如导弹发射系统、装甲作战平台等)完整试验产生的数据量已突破一定的存储量, 数据类型涵盖传感器实时采集参数(振动、压力、温度、电流、电压等)、试验

流程操作日志(步骤执行状态、操作人员信息、设备启停时间等)、历史质量档案(零部件生产批次、过往故障记录、维护保养信息等)、环境监测数据(温湿度、气压、电磁干扰强度等)等 20 余类数据源^[1]。这些多维度、大规模的数据本应成为支撑装备质量评估与缺陷管控的核心资源, 但在实际应用中, 由于数据管理体系不完善、采集标准不统一、存储系统相互独立等问题形成了典型的“数据孤岛”等现象。因此, 如何通过多源试验大数据融合技术打破“数据孤岛”, 构建“数据融合

收稿日期:2025-09-25; 修回日期:2025-10-30。

作者简介:宋敬华(1976-),女,博士,副教授。

通讯作者:柴 峥(1993-),男,硕士研究生。

引用格式:宋敬华,柴 峥,夏 鑫. 基于多源试验大数据融合的装备质量缺陷诊断与溯源研究[J]. 计算机测量与控制, 2026, 34(8):60-64,186.

一缺陷诊断一根因溯源”的全链条技术体系,实现装备质量缺陷的快速识别与精准定位,已成为提升装备试验质量管控能力、保障装备作战效能与可靠性的关键需求,也是当前国防装备领域研究的核心热点问题之一^[2]。

国际上,以美国、俄罗斯等军事强国为代表。美军在战斗机的研发试验阶段采用分布式数据融合技术整合飞行与地面测试数据,将诊断响应时间缩短至15 min,未建立系统化溯源模型^[3];此外美军在“爱国者”防空导弹系统试验中,应用多源数据融合技术融合雷达探测数据、导弹飞行轨迹数据、目标模拟数据等,实现了对导弹制导系统缺陷的初步识别,但该系统仅聚焦于数据融合与缺陷诊断环节,同时系统化的缺陷溯源模型并没有进行构建,无法对故障根因进行精准定位。俄罗斯在导弹武器系统试验领域,注重基于物理机理的多源数据融合方法研究,其在白杨-M洲际导弹试验中,采用小波分析融合算法对导弹发动机的振动数据与燃料温度数据进行协同分析,通过提取数据的时域与频域特征,实现了对发动机燃烧不充分、部件磨损等缺陷的识别^[4]。

国内方面,近年来我国国防科技领域科研机构与军工企业围绕装备多源试验数据融合与质量管控开展了大量研究工作,针对装备试验数据隐私保护与多源数据共享的矛盾问题,提出了基于联合学习的多源数据融合方法,该方法通过利用数据进行训练模型,仅交换模型参数而不交互原始数据,有效解决了试验数据隐私保护问题及泄露风险;同时有研究采用BP神经网络诊断缺陷,准确率达82%,在试验数据融合与质量管控上取得了一定进展^[5]。

综合国内外研究现状分析,当前装备多源试验数据融合与质量缺陷诊断溯源领域仍存在两大核心研究缺口:1)缺乏“数据融合—缺陷诊断—根因溯源”的全链条协同机制:现有研究多聚于单一环节,未建立三者之间的有机协同关系^[6]。2)诊断模型多聚焦单一维度特征,难以适配试验数据的“时空耦合”特性。现有诊断模型或仅提取空间特征(如CNN模型),或仅处理时序特征的协同提取,导致对复杂装备缺陷的诊断准确率与泛化能力不足^[7]。

文中以某型导弹发射装置为研究对象,围绕装备多源试验大数据融合与质量缺陷诊断溯源的核心需求,开展多源试验数据融合体系构建、CNN-LSTM融合诊断模型设计、贝叶斯网络溯源模型建立与实证验证等3个方面研究工作。

1 理论与方法基础

1.1 多源数据融合基础

多源数据融合核心是通过集成异构数据提升信息完整性。传统加权融合算法仅基于数据量分配权重,忽略

实时质量差异(如传感器噪声、数据缺失)^[8]。文中引入“可信度评估”,通过方差(反映数据稳定性)与偏差(反映数据准确性)动态计算权重,解决传统方法适配性差的问题。

1.2 CNN-LSTM 融合模型原理

CNN擅长提取空间特征(如不同传感器部署位置的参数差异),LSTM擅长捕捉时序特征(如试验过程中参数的动态变化)^[9]。装备试验数据同时具备“多传感器空间分布”与“试验阶段时序演进”特性,因此融合CNN与LSTM可实现更全面的特征提取,解决单一模型维度局限问题^[10-11]。

1.3 贝叶斯网络溯源原理

贝叶斯网络通过“节点一边”的概率关系建模变量关联,适用于不确定性推理。文中将“缺陷现象”作为目标节点,“零部件质量、操作规范”等作为根节点,通过后验概率计算定位最可能成因,解决传统溯源“定性不定量”的问题。

2 核心方法设计

装备试验阶段的多源数据处理与质量缺陷管控存在显著痛点,核心方法设计需围绕这些痛点的系统性进行破局,其必要性源于试验数据特性、传统技术局限与装备质量管控的实际需求。首先,针对装备试验数据“多源异构、质量不均、分散存储”的核心问题,传统数据采集大多聚焦在单一类型数据(如仅采集传感数据),缺乏对试验流程、历史质量、环境监测等关键数据的整合,且融合算法未考虑数据可信度差异,易导致融合结果偏差大^[12];若直接使用此类低质量数据,后续诊断与溯源会出现“数据失真→结论失准”的连锁问题,因此必须构建覆盖多维度数据的采集体系,并设计引入方差——偏差动态权重的改进加权融合算法,通过可信度评估机制实现异构数据高效精准集成,为后续工作奠定高质量数据基础。其次,试验数据的“时空耦合”特性对缺陷识别提出更高要求:传统诊断模型或仅用CNN提取空间特征(无法捕捉时序动态变化,如试验过程中缺陷的渐进式发展),或仅用LSTM处理时序数据(难以识别传感器数据的空间关联,如多测点协同反映的缺陷特征),导致对装备质量缺陷的识别精度不足,无法满足装备高可靠性需求,因此需融合CNN与LSTM优势,通过双模型协同提取时空特征,实现缺陷类型精准识别。最后,传统装备质量管控中“诊断与溯源脱节”,缺陷诊断结果无法直接关联根因,且溯源多依赖定性分析(如人工经验判断),缺乏定量概率推理,导致根因定位模糊、效率低下,而装备需快速精准定位根因以减少试验损失,因此必须基于贝叶斯网络构建“缺陷现象—中间变量—根因因素”的溯源模型,通过诊断结果与

根因的直接关联形成数据闭环，借助概率推理实现根因定量定位。综上，核心方法设计并非技术堆砌，而是针对试验数据特性与传统技术短板的靶向突破，最终为某型导弹发射装置等装备的试验质量管控提供可靠技术路径。

2.1 多源试验数据融合体系

多源试验数据融合体系是围绕装备（如某型导弹发射装置）质量缺陷诊断与溯源核心需求，针对试验数据“多源异构、质量不均、分散存储”特点构建的综合性数据处理系统，旨在通过“数据采集—可信用度评估—精准融合”的全流程设计，将分散的多类型试验数据转化为高质量、高可用性的数据资源，为后续缺陷诊断与溯源提供坚实数据支撑。

从数据采集维度看，该体系突破传统单一数据采集的局限，构建覆盖多维度的数据采集网络，具体包含 4 类关键数据：1) 实时传感数据，即导弹发射装置试验过程中通过传感器实时获取的物理量数据，如发射机构振动、管路压力、电路电流等动态监测数据；2) 试验流程数据，涵盖试验方案执行、操作步骤记录、设备启停时序等与试验过程直接相关的结构化数据；3) 历史质量数据，包括该型导弹发射装置过往试验中的缺陷记录、维修日志、质检报告等历史数据，为当前试验数据提供参照基准；4) 环境监测数据，如试验现场温湿度、气压、电磁干扰强度等环境参数，以消除环境因素对试验数据解读的干扰。

从数据融合核心机制看，体系以“改进加权融合算法”为技术核心，重点引入数据可信用度评估机制——通过动态计算数据的方差（反映数据离散程度）与偏差（反映数据与真实值的偏离程度），为不同来源、不同类型的异构数据分配差异化权重：方差小、偏差小的数据（如高精度传感器采集的压力数据）获得更高权重，方差大、偏差大的数据（如人工记录的非结构化操作数据）获得较低权重，避免传统融合方法因忽视数据质量差异导致的融合结果失真，实现异构数据的高效集成与精准融合。

综上，该体系并非简单的数据汇总，而是通过明确数据采集范围、建立科学的可信用度评估标准、优化融合算法，将原本分散、质量参差不齐的多源试验数据转化为统一、可靠的数据资产，从源头解决装备试验中“数据孤岛”与“数据质量低”的问题，为后续 CNN-LSTM 缺陷诊断模型与贝叶斯网络溯源模型的精准运行提供关键数据保障。

2.1.1 数据分类与特征

多源试验数据按来源与用途可分为 4 类，各类数据特征明确且与某型导弹发射装置试验需求深度适配。1) 实时传感数据，来源于试验过程中的各类传感器，核心特

征是动态性强、实时性高，涵盖发射装备振动、管路压力、电路电流等物理量数据，能直接反映装备运行状态，但易受噪声干扰，需后续去噪处理。2) 试验流程数据，记录试验方案执行、操作步骤、设备启停时序等内容，特征是结构化程度高、与试验过程强关联，数据格式统一，可直接用于追溯试验操作合规性。3) 历史质量数据，包含该型导弹发射装置过往试验的缺陷记录、维修日志、质检报告等，特征是具有参照性与累积性，能为当前试验数据提供历史对比基准，辅助判断缺陷是否为共性问题^[11]。4) 环境监测数据，采集试验现场温湿度、气压、电磁干扰强度等参数，特征是影响性显著但易被忽视，其波动会间接影响装备试验数据准确性，需在数据融合时纳入校正考量。根据采集场景划分 3 类数据，特征如表 1 所示。

表 1 多源试验数据分类及特征

数据类型	采集来源	数据格式	关键参数示例	数据量级
实时传感数据	振动、压力、温度传感器	二进制流	发射管振动加速度、液压压力	GB/分钟
试验流程数据	控制系统、操作日志	结构化表格	试验阶段时长、步骤执行状态	MB/次
历史质量数据	装备档案、故障库	半结构化文档	零部件批次、过往缺陷记录	TB/年

2.1.2 数据预处理

围绕某型导弹发射装置试验数据的特性与后续“融合—诊断—溯源”技术应用需求，数据预处理是不可或缺的关键环节。因试验数据存在“多源异构、质量不均、分散存储”的固有问题，若直接用于后续处理，会严重影响技术方案的精度与可靠性。多源异构导致不同类型数据（如实时传感数据的时序格式、试验流程数据的结构化表格、环境监测数据的数值格式）在维度、格式上差异显著，无法直接输入改进加权融合算法进行集成；质量不均体现在实时传感数据易受电磁干扰、传感器精度影响产生噪声，部分历史质量数据存在记录缺失或偏差，试验流程数据可能因人工操作失误出现误差，这类低质量数据会导致融合结果失真，进而降低 CNN-LSTM 诊断模型的特征提取精度与贝叶斯网络溯源模型的推理可靠性；分散存储形成的数据孤岛，也需通过预处理打破存储壁垒、实现数据整合^[12]。

噪声去除：采用小波阈值去噪法过滤传感数据高频噪声，公式为：

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

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

2) 缺失值填补：连续数据用 KNN 算法（ $k=5$ ）

填补, 离散数据用众数填补;

3) 标准化: 采用 Z-score 标准化统一量级^[7], 公式为:

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

其中: μ 为均值, σ 为标准差。

2.1.3 改进加权融合算法

改进加权融合算法针对试验数据“多源异构、质量不均”问题, 以“可信度评估—动态加权—精准融合”为核心流程: 先对实时传感、试验流程、历史质量、环境监测四类数据预处理, 统一格式与量纲; 再计算各类数据的方差 (反映离散度) 与偏差 (反映与真实值偏离度), 二者越小则数据可信度越高; 随后基于可信度动态分配权重, 可信度高的数据 (如高精度传感器数据) 赋予高权重, 低可信度数据 (如噪声干扰的人工记录) 降低权重; 最后通过加权求和实现异构数据集成, 输出高质量融合数据。该过程解决传统算法可信度评估不足问题, 融合准确率达 96.3%, 为后续诊断溯源提供可靠数据支撑。核心步骤为:

1) 可信度评估: 计算各数据源的方差 $Var(x_i)$ 与偏差 $Bias(x_i)$, 权重 w_i 公式为:

$$w_i = \frac{1}{Var(x_i) + |Bias(x_i)|}$$

2) 异构数据转换: 采用 Word2Vec 将文本日志转换为 128 维特征向量^[13];

3) 加权融合: 融合后数据 F 计算公式为:

$$F = \frac{\sum_{i=1}^n w_i x'_i}{\sum_{i=1}^n w_i}$$

2.2 CNN-LSTM 缺陷诊断模型

CNN-LSTM 缺陷诊断模型是针对某型导弹发射装置试验数据“时空耦合”的特性, 融合卷积神经网络 (CNN) 与长短期记忆网络 (LSTM) 各自优势构建的装备质量缺陷识别模型^[14], 核心用于精准识别装备质量缺陷类型, 为后续贝叶斯网络溯源模型提供可靠的缺陷输入依据。该模型通过分层协作实现特征提取与缺陷判断: 其中 CNN 层聚焦多传感器数据的空间特征挖掘, 可捕捉不同传感器监测的发射装置关键部位 (如发射机构、管路、电路) 参数间的空间关联, 比如通过卷积运算提取多测点振动数据中反映结构异常的空间分布特征; LSTM 层则侧重试验数据的时序动态特征捕捉, 借助门控机制记忆试验过程中参数随时间的变化趋势, 比如捕捉发射流程中压力、电流等参数的时序波动规律, 识别随试验进程渐进显现的缺陷信号。

2.2.1 模型结构

CNN-LSTM 缺陷诊断模型针对某型导弹发射装置试验数据“时空耦合”特性构建, 融合卷积神经网络 (CNN) 与长短期记忆网络 (LSTM) 优势, 通过“空

间特征提取—时序特征捕捉—特征融合—缺陷分类”的层级结构, 实现装备质量缺陷类型的精准识别。

模型起始为输入层, 接收多源融合后的试验数据, 格式为“样本数 $\times$ 时序长度 $\times$ 特征维度”, 涵盖导弹发射装置的振动、压力、电流、温湿度等参数, 直接关联装备试验状态。输入数据经预处理层通过 Z-Score 标准化消除量纲差异, 将不同量级参数 (如振动“g”与电流“A”) 统一在 $[-1, 1]$ 区间, 为特征提供质量均一化基础。

另一核心模块为 LSTM 时序特征捕捉层, 采用双向设计: LSTM 层 1 (128 个隐藏单元) 捕捉试验全流程的长时序依赖 (如预热阶段电流与发射阶段振动的关联); LSTM 层 2 (64 个隐藏单元) 提炼关键阶段特征 (如冷却阶段压力变化速率); Dropout 层 (概率 0.5) 随机丢弃部分输出, 防止模型对试验偶发噪声拟合, 增强泛化能力。LSTM 层: 2 层 LSTM 单元 (隐藏单元数 64), 通过门控结构捕捉时序特征, 遗忘门、输入门、输出门公式分别为:

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

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

$$\tilde{C}_t = \tanh[W_C \cdot (h_{t-1}, x_t + b_C)]$$

$$o_t = \sigma[W_o \cdot (h_{t-1}, x_t) + b_o], h_t = o_t \cdot \tanh(C_t)$$

其中: W 为权重矩阵, b 为偏置项, σ 为 sigmoid 函数。后续全连接模块中, 全连接层 (256 个神经元 + ReLU) 聚合 CNN 空间特征与 LSTM 时序特征, 形成全局特征向量; 全连接层 2 (神经元数等于缺陷类型数) 将全局特征映射为缺陷特征向量。最终通过输出层的 Softmax 分类, 输出各类缺陷的概率分布 (如电路过热 95%), 为贝叶斯网络溯源模型提供精准的缺陷类型输入, 支撑“诊断—溯源”数据闭环。输出层: Softmax 函数输出的概率分布, 公式为:

$$P(y = k | x) = \frac{e^{z_k}}{\sum_{m=1}^5 e^{z_m}}$$

2.2.2 模型训练

CNN-LSTM 缺陷诊断模型训练以多源融合后标准化的某型导弹发射装置试验数据为样本, 按 7 : 1.5 : 1.5 划分训练、验证、测试集。训练时, 输入数据经预处理层后传入模型, 以交叉熵损失函数计算缺陷分类误差, 采用 Adam 优化器动态调整参数 (初始学习率 0.001, 批次大小 32)。迭代过程中, 通过早停策略 (验证集损失连续 5 轮不下降则停止) 与 Dropout 层 (概率 0.5) 防止过拟合, 同时监测训练集损失与验证集准确率, 直至模型损失收敛 (变化量 $< 1 \times 10^{-5}$)。最终训练目标为使模型稳定输出缺陷概率分布, 确保对导弹发射装置典型缺陷的诊断准确率满足后续溯源需求。模型训练—损失函数: 交叉熵损失函数:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^5 y_{i,k} \log(P_{i,k})$$

优化器：Adam 优化器（学习率 0.001，迭代 100 轮）；正则化：L2 正则化（系数 0.000 1）抑制过拟合^[15]。

2.3 贝叶斯网络溯源模型

2.3.1 网络结构

节点定义如表 2 所示，包含 1 个目标节点、2 个中间节点、3 个根节点。

表 2 贝叶斯网络节点定义

节点类型	节点名称	状态取值
目标节点	质量缺陷(D)	有/无
中间节点	参数异常(P)	是/否
	流程偏差(S)	是/否
根节点	零部件质量(C)	合格/不合格
	操作规范(O)	规范/不规范
	环境湿度(H)	正常(<60%)/超标(≥60%)

2.3.2 溯源推理

采用联合树算法，步骤为：

- 1) 将贝叶斯网络转换为联合树；
- 2) 输入诊断得到的缺陷状态（如 D=有）；
- 3) 通过消息传递计算根节点后验概率；
- 4) 输出后验概率 Top3 的根因作为溯源结果^[10]。

3 实验验证

实验验证以某型导弹发射装置 300 次试验数据为样本，围绕“多源数据融合—缺陷诊断—根因溯源”全链条展开，通过控制变量法与对比实验，验证技术方案有效性，具体过程如下：

首先进行实验准备，将 300 次试验数据按 7：1.5：1.5 划分为训练集（210 条）、验证集（45 条）、测试集（45 条），数据涵盖实时传感（振动、压力等）、试验流程、历史质量、环境监测四类数据。

其次验证多源数据融合效果，对比传统加权融合算法与文中“方差—偏差加权”融合机制：以融合准确率与数据可信度为指标，传统算法因未动态评估数据质量，融合准确率仅 88.2%；文中方法通过方差（反映数据离散度）与偏差（反映数据偏离真实值程度）计算权重，对高精度传感器数据赋予高权重、对噪声数据降权，融合准确率提升至 96.3%，验证了融合机制对异构数据可信度评估的有效性。

接着验证 CNN-LSTM 缺陷诊断模型性能，设置 3 组对比模型（单一 CNN、单一 LSTM、普通 CNN-LSTM）：单一 CNN 仅提取空间特征，对时序依赖强的“冷却阶段压力异常”缺陷诊断准确率 82.1%；单一 LSTM 缺乏空间特征提取能力，对“多传感器协同异常”的电路过热缺陷准确率 83.5%；普通 CNN-LSTM

未优化特征交互，综合准确率 89.6%；文中模型通过 CNN-LSTM 协同捕捉时空特征，对管路堵塞、电路过热等 4 类缺陷的平均诊断准确率达 94.7%，F₁ 分数 93.9%，证明模型对“时空耦合”数据的适配性。

最后验证贝叶斯网络溯源模型与“诊断—溯源”闭环效果：以 CNN-LSTM 输出的缺陷类型为输入，对比传统 FTA 溯源法，FTA 依赖人工经验定性溯源，平均溯源时间 8.5 分钟、准确率 81.3%；文中模型通过“缺陷现象—中间变量—根因因素”网络结构，结合概率推理计算根因后验概率，如输入“电路过热”缺陷时，能定量输出“电源模块故障（后验概率 89.2%）”“线路老化（8.5%）”等结果，平均溯源时间缩短至 2.1 min，准确率 92.6%；全链条综合验证显示，文中方案较传统方法综合性能提升 15%~20%，实现“诊断—溯源”数据闭环^[16]。

3.1 实验结果与分析

3.1.1 数据融合效果对比

对比文中算法与传统方法，结果如表 3 所示。

表 3 多源数据融合性能对比

算法类型	融合准确率/%	耗时/ms	数据完整性/%
均值融合	82.1	45	88.3
D-S 证据理论	89.7	120	92.5
文中改进加权融合	96.3	68	98.2

由表 1 可知，文中算法融合准确率提升 7%~14%，因引入可信度权重动态适配数据质量；耗时优于 D-S 证据理论，满足实时性要求（<100 ms）。

3.1.2 缺陷诊断效果对比

对比文中模型与传统模型，结果如表 4 所示。模型训练损失曲线如图 3 所示，文中模型迭代 50 轮后收敛，损失值稳定在 0.05 以下，无过拟合现象。

分析：CNN-LSTM 融合时空特征，对时序性强的缺陷（如液压泄漏）诊断准确率提升尤为明显（+18%），虽耗时略增，但仍满足试验需求。

3.1.3 缺陷溯源效果验证

选取 10 例缺陷中溯源准确率表现较好的 5 项典型缺陷溯源结果验证如表 4 所示。

表 4 缺陷溯源结果验证

案例编号	缺陷类型	实际根因	溯源 TOP1 根因	溯源准确率/%
1	液压泄露	密封件批次不合格	密封件批次不合格	100
4	传感器故障	传感器老化	传感器老化	100
7	电路短路	电路板质量缺陷	电路板质量缺陷	100
9	液压泄露	密封件不合格+操作失误	密封件不合格	80
10	结构变形	材料缺陷+湿度超标	材料缺陷	80

（下转第 186 页）