

doi: 10.7690/bgzdh.2021.09.013

## 基于大数据分析的航空产品故障管控

罗月婉, 刘沙杭, 张振中

(成都飞机设计研究所检验室, 成都 610065)

**摘要:** 为提高航空产品故障诊断精度与维修保障的效率, 提出一种基于大数据分析技术的航空产品故障管控方法。从数据挖掘算法在产品管理中的应用进行分析, 依据航空产品检定数据和历史故障数据, 构建产品故障与寿命预估的关联分析模型, 对大数据分析技术在航空产品的应用现状与发展前景进行阐述。分析结果表明, 该研究可为未来航空产品质量管控和维修保障提供思路。

**关键词:** 大数据分析; 数据挖掘; 航空产品; 故障预测; 维修保障

**中图分类号:** V19    **文献标志码:** A

## Management and Control of Aviation Product Failure Based on Big Data Analysis

Luo Yuewan, Liu Shahang, Zhang Zhenzhong

(Testing Department of AVIC Chengdu Aircraft Design & Research Institute, Chengdu 610065, China)

**Abstract:** In order to improve the accuracy of fault diagnosis and the efficiency of maintenance support for aviation products, a fault management and control method based on big data analysis technology is proposed. This paper analyzes the application of data mining algorithm in product management, and constructs the association analysis model of product failure and life prediction based on aviation product verification data and historical fault data. Finally, the application status and development prospect of big data analysis technology in aviation products are described. The analysis results show that the research can provide ideas for future aviation product quality control and maintenance support.

**Keywords:** big data analysis; data mining; aviation products; fault prediction; maintenance support

## 0 引言

目前大数据分析技术在航空领域已经引起了广泛关注。大数据分析技术对航空产品设备进行故障管控与预测是提高飞机安全性、可靠性和保障性的重要措施, 也是未来航空产品设备管控的发展趋势与关键技术。

产品质量事故是指产品在设计和生产过程中由于质量缺陷而不能满足要求, 从而对使用过程中的人员、设备和环境造成负面影响的事件<sup>[1]</sup>。

在装备数量增加、部队任务强度增大的背景下, 有着高故障率产品的故障数量增加较多。在航空产品的故障管控中, 无论是针对机载成品、地面设备还是其他产品, 故障件的批次性、检验数据和同型号的历史故障数据都隐含着丰富的规律特性。依靠数据挖掘技术, 通过大数据融合与关联分析模型, 可以进一步提高故障诊断精度与维修保障的效率。

## 1 大数据分析技术在航空领域中的现状

洛克希德-马丁公司提出的预测与健康管理技

术(prognostics and health management, PHM)以数据预测为核心, 通过有效的大数据分析技术, 为飞机提供独立监测、健康管理及应急反应措施<sup>[2]</sup>。目前, PHM 技术主要利用的是飞参数据、飞行管理数据、各类传感器或机上设备的运行数据, 利用航空产品的检定数据和历史故障数据进行故障预测和寿命评估的研究还较为匮乏。

在近几年现役飞机完好率影响因素的统计中, 产品故障是影响完好率和平均故障间隔时间(mean time between failure, MTBF)的最主要因素, 主要表现为故障率高、外场未备有足够备件, 而交通不便使得备件的调配周期较长, 外场缺件情况愈加明显, 致使飞机停飞。基于大数据分析技术对产品的故障和寿命进行预估, 可以为上述问题提供一条新的解决思路。

### 1.1 数据挖掘

文献[3]分析了国内某航空公司利用大数据技术对航材进行保障和库存优化的案例。文献[4]利用

收稿日期: 2021-05-20; 修回日期: 2021-06-25

作者简介: 罗月婉(1994—), 女, 四川人, 硕士, 工程师, 从事大数据分析、神经网络、故障识别、图像处理研究。E-mail: 250682629@qq.com。

了随机森林算法，对智能电表的基础检定数据和出厂数据进行挖掘分析，以此实现对每只电表的预估寿命和可能发生的故障类型进行预测，实验结果也验证了数据挖掘在电表故障管控方面的有效性。

数据挖掘技术是从大量不完整、有噪声、随机数据中提取潜在有用信息和知识的过程<sup>[5]</sup>。数据挖掘技术可以对数据进行自动分析，对逻辑进行归纳，并最终挖掘出潜在的模式<sup>[6-7]</sup>。文献[8]将数据挖掘方法应用于飞机控制执行器早期故障诊断。文献[9]提出了一种基于数据挖掘的故障特征集优化模型，有效地提高了故障诊断率，也证明了数据挖掘技术可以有效地应用于航空产品的故障管控中。

## 1.2 深度学习

在数据挖掘中，深度学习是时下热门的机器学习方法，深度学习利用复杂、庞大的神经网络进行经验积累<sup>[10]</sup>，在对故障进行预估时，传统的故障诊断效果直接由输入特征决定，几乎所有特征都依赖于专家的经验和知识。对于新的对象或字段，很难手动提取特征。随着数字信息和互联网的发展，传统的特征提取更难以适应；然而，深度学习网络可以实现从输入到输出的无特征提取的映射，并且深度学习具有迁移学习能力，可应用于航空产品数据这类的不平衡样本。

在 2013 年，自从文献[11]将深度置信网络应用于飞机发动机故障诊断以来，越来越多的学者将深度学习应用于故障诊断和预测领域，并获得了许多研究成果；文献[12]将深度置信网络用于车辆传动系统的故障分类识别；文献[13]将深度学习用于高速列车的运行装置故障诊断；文献[14]将深度置信网络用于故障特征的提取和诊断；文献[15]对目前深度学习在故障诊断方面的技术和挑战进行了评述。根据上述文献，深度学习已在故障诊断领域中得到了广泛应用，但是研究还不是很成熟，特别是对于机载成品等故障数据稀少且样本不平衡的航空产品。在这些领域中，有必要对深度学习的建模能力进行研究。

在深度学习算法中，基于卷积神经网络(convolutional neural network, CNN)诊断方法的研究成果很少。该方法作为一种重要的深层神经网络方法，是一种在深度监督和学习下的机器学习模型，擅长挖掘数据的局部特征，自适应地提取全局训练

特征和分类；另外，CNN 方法非常适用于海量数据的处理。通过学习海量数据的特征，可以识别海量数据中包含的信息；因此，在深入学习诊断算法发展的基础上，利用 CNN 进行诊断是未来的发展方向。

## 2 数据集的构建与预处理

建立航空产品的故障管控和预测系统的关键是确定大数据分析关联模型，利用产品的批次、入所检定数据、型号、供应商、所属机型以及历史故障和故障期等多维度基础检验信息，可以对某型产品可能发生的故障类型和其剩余寿命周期进行关联分析预测，在实际数据和历史记录的海量统计基础中，挖掘分析产品存在的故障趋势及隐患，依靠客观数据分析支撑而非传统故障机理或经验推测进行故障定位，为产品设备的故障预测、维修过程和寿命周期提供保障决策，同时可以对产品供应商进行评估，对故障件同批次产品进行故障预检。

关联分析的目的是找出数据库中隐含的关联网络，然而关联函数往往是非线性不确定的。

### 2.1 数据集的构建

在航空产品的检修故障中，故障类别有传感器故障、通信模块故障、外观故障、电池故障、硬盘故障、主板故障、显示故障和密封问题故障等。

上述检修故障和其发生故障时的使用寿命可以作为模型的目标输出向量，而模型的输入向量则有产品名称、型号、编号、批次号、供应商名称、所属机型、所属系统、历史检验数据和故障数据、故障期。

在对数据进行关联挖掘时，往往需要对数据进行清理与去噪，从而得到更为准确、更为可靠的相关规则。

### 2.2 数据的清理与去噪

一般情况下，原始维修数据存在 2 个问题：数据丢失和噪声数据。

航空产品的历史故障数据可以在检验人员的记录中查询，但是对于相同的故障原因和维修方法，不同的维修人员对同一维修行为又有不同的描述；因此，可能产生不同的故障维修数据，即数据丢失。在这种情况下，需要在数据挖掘时对数据进行清理。不同的数据清理方法的优缺点如表 1 所示<sup>[16]</sup>。

表1 处理缺失值的方法介绍

数据问题	数据清理方法	方法介绍	方法优势	方法缺点
缺失值	手动填写缺失值	基于经验的人工填充	针对某些典型数据,由有经验的工人填写更准确	当日期设置有许多缺失值时,时间消耗很长,通常不可行
使用全局常量 填充缺失值	用相同的常量替换所有缺失的属性值	简单的方法	当存在许多缺失值时,该方法可能存在质量问题	
使用属性平均值填充缺失值	替换为平均属性	简单的方法	非数字数据难以实现,且方法不可靠	
缺失值推断与预测	基于推理的工具确定或决策树归纳	结果准确,与其他属性有较强的属性关系	需要更多的时间和信息	

由上表可以看到:与其他方法相比,表中的贝叶斯形式或决策树归纳法使用当前数据中的大多数信息来预测缺失值,在估计缺失值时考虑其他属性的值,保留缺失值与其他属性之间关系的可能性更大;因此,用于处理维护数据缺失值的方法可行,并且数据可靠。

噪声数据是指测量变量中存在随机误差或方差的数据,可能的解决方案是绑定、回归或集群技术。这些方法的介绍如表2所示<sup>[17]</sup>。

表2 噪声数据的处理方法

数据问题	数据清洗方法	方法介绍
噪声数据	绑定	通过查询排序的数据来平滑其“邻域”数据
	回归	使用回归来拟合数据
	聚类	异常值可以通过聚类来检测,在这种情况下,类似的值被组织成组或“集群”

### 3 基于 CNN 的产品故障与寿命预估模型

产品故障与寿命预估模型对信息进行综合分析,挖掘输入向量数据与目标输出向量的相关性,利用相关算法从故障征兆中找出故障原因和故障发生率,预估使用寿命的潜在统计规律。在此基础上,提前做好检修准备、提高故障定位效率,为航空产品的健康状况、运行保障、维修诊断提供辅助技术支持。

#### 3.1 基于 CNN 故障预估模型的训练过程

在模型构建所需的算法中,CNN 是一种特殊的深度神经网络模型。其特殊性体现在 2 方面:1) 神经元连接不完全;2) 同一层中某些神经元之间连接的权重是共享的。不完全连接和权重分担的网络结构使其更接近生物神经网络,降低了网络模型的复杂性和权重的个数。

CNN 具有容错性好、并行处理能力和自学习能力强等优点,能够处理环境信息复杂、背景知识不清、推理规则不清等问题,使样本具有缺陷大、失真大、运行速度快、自适应性能好等优点。它通过结构重组和减轻权重,将特征提取功能集成到多层

感知器中,忽略了识别前复杂的矩阵特征提取过程。

如图 1 所示,卷积神经网络结构包括卷积层、下采样层和全链路层。每个层具有多个特征映射,每个特征映射通过卷积滤波器提取输入的特征,映射多个神经元。

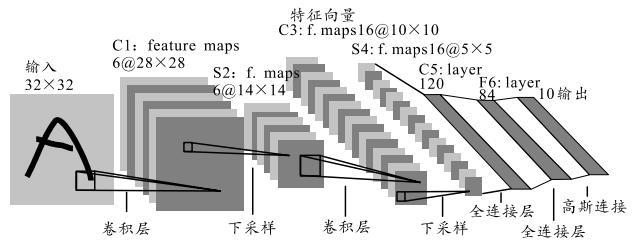


图1 LeNet5 卷积神经网络结构

训练算法主要由 2 个阶段组成:

1) 前向传播阶段。

- ① 从数据集中提取一组数据作为网络的输入;
- ② 计算相应的实际输出,信息从输入层转换到输出层。

2) 反向传播阶段。

- ① 计算实际输出值与理想值之间的差值;
- ② 根据误差最小化的目标调整权重矩阵。

这 2 个阶段的工作一般应有精度控制要求。该网络的训练过程如下:

- 1) 选择训练数据组并随机选择  $N$  样本集样本作为训练数据;
- 2) 将每个权重和阈值设置为接近 0 的小随机值,并初始化控制参数和学习速率;
- 3) 从训练数据组中选择一个输入向量和其对应的目标输出向量,将其输入到网络中;
- 4) 计算网络的中间层输出向量和实际输出向量;
- 5) 将输出矢量中的元素与目标输出向量中的元素进行比较,以计算输出误差和中间层隐藏单元的误差;
- 6) 依次计算每个权重的调整量和阈值;
- 7) 调整权重和阈值;
- 8) 判断输出向量的指标是否满足精度要求。如

果不满足, 返回 3), 继续进行迭代; 如果满足, 则产品故障与寿命预估模型已训练完成。

### 3.2 故障管控系统的良性循环

训练完成的产品故障与寿命预估模型应具有较高的预测精度, 为产品的故障管控人员及时进行排故提供决策支持。同时, 成功地将排故记录转化为新的历史维护记录, 成为系统的良性循环, 其逻辑如图 2 所示。

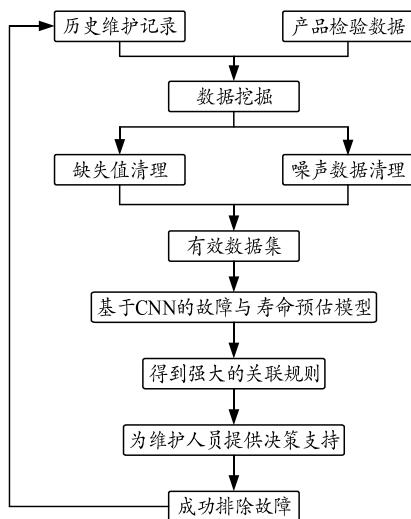


图 2 产品故障与寿命预估模型的逻辑

## 4 结论

笔者从航空产品的故障预估和寿命管控着手, 详细阐述了大数据分析技术在此领域的应用现状与发展前景, 得出以下结论:

1) 提出了基于航空产品的基础信息和检验数据搭建的故障关联分析模型, 以实现对成品故障预测与寿命管控, 提升飞机故障诊断精度与维修保障的效率。

2) 由于保密原因, 文中未能公布数据和分析结果。同时由于目前的航空产品信息管理系统还不完善, 每件成品的履历信息未完全数字化; 因此, 在工程实现前, 必须对该模型和应用体系进行详细的实验论证, 实现该技术的分阶段有序推进。

## 参考文献:

- [1] HE Y H, CUI J M, LIU F D, et al. Risk-based quality accident ranking approach using failure mechanism and Axiomatic domain mapping[J]. Total Quality Management & Business Excellence, 2018(12): 1–22.
- [2] YANG L, WANG J, ZHANG G. Aviation PHM System Research Framework Based on PHM Big Data Center[C]// 2016 IEEE International Conference on Prognostics and Health Management (ICPHM). IEEE, 2016: 1–5.
- [3] 罗雅方. 大数据时代民航航材管理问题研究[D]. 北京: 北京邮电大学, 2017.
- [4] 黄吉涛, 樊博, 周媛奉, 等. 基于随机森林的智能电表故障及寿命预测模型[J]. 兵工自动化, 2019, 38(10): 57–60.
- [5] JIAWEI H, MICHELINE K. Data Mining: Concepts and Techniques[J]. Data Mining Concepts Models Methods & Algorithms Second Edition, 2006, 5(4): 1–18.
- [6] BANDARU S, NG A H C, DEB K. Data mining methods for knowledge discovery in multi-objective optimization: Part A-Survey[J]. Expert Systems with Applications, 2017, 70(1): 139–159.
- [7] LIU Y, MA P, CUI H. Design and Development of FPGA-based High-Performance Radar Data Stream Mining System[J]. Procedia Computer Science, 2015, 55(1): 876–885.
- [8] VERESNIKOV G S, SKRYABIN A V. The development of data mining methods criteria to identify failures of aircraft control surface actuator[J]. Procedia Computer Science, 2017, 112(1): 1007–1014.
- [9] GUO Y, LI G, CHEN H, et al. Optimized neural network-based fault diagnosis strategy for VRV system in heating mode using data mining[J]. Applied Thermal Engineering Design Processes Equipment Economics, 2017, 125(1): 1402–1413.
- [10] ZHANG C, XU L, LI X, et al. A Method of Fault Diagnosis for Rotary Equipment Based on Deep Learning[C]// 2018 Prognostics and System Health Management Conference. IEEE, 2018: 958–962.
- [11] TAMILSELVAN P, WANG P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115(1): 124–135.
- [12] 单外平. 基于深度信念网络的变速器故障分类识别研究[D]. 广州: 华南理工大学, 2015.
- [13] 谢吉朋. 云平台下基于深度学习的高速列车走行部故障诊断技术研究[D]. 成都: 西南交通大学, 2015.
- [14] 赵光权, 葛强强, 刘小勇, 等. 基于 DBN 的故障特征提取及诊断方法研究[J]. 仪器仪表学报, 2016, 37(9): 1946–1953.
- [15] HAO R, QU J F, CHAI Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. Control and Decision, 2017, 32(8): 1345–1358.
- [16] HAN J W, MICHELINE K. Data mining: concepts and techniques[J]. Data Mining Concepts Models Methods & Algorithms Second Edition, 2006, 5(4): 1–18.
- [17] JIA B H, WANG Y X, YANG Z Q. The research of data mining in AHM technology based on association rule[C]// 2011 Prognostics and System Health Management Conference. IEEE, 2011: 1–8.