

# 基于超参数优化机器学习算法与BP神经网络模型的 元器件质量监测与故障预测研究

邱云峰<sup>1,2</sup>, 李泽宏<sup>1</sup>

(1. 电子科技大学, 四川 成都 611731; 2. 贵州航天计量测试技术研究所, 贵州 贵阳 550009)

**摘要:** 为解决传统元器件质量管理方法在海量数据处理与分析中的局限性问题, 建立智能化质量监测机制以提升质量态势评估的准确率与可靠性。基于全寿命周期多源数据, 构建了融合质量监测与故障预测的双模型框架, 采用超参数优化机器学习算法, 集成出厂检验、使用过程质量保证及质量问题信息等6维度特征数据, 构建质量态势评估模型; 设计了基于BP神经网络的故障预测模型, 实现元器件质量状态的动态预警。在JZC-084系列电磁继电器与J599F26D系列低频连接器实验中, 故障预测误差低于0.1%, 质量态势评估准确率达95.1%, 优于技术指标要求; 随机森林分类模型验证显示, 平均精确率、召回率与F1-score分别达到83.6%, 81.2%与78.3%。该方法通过实时监测与多源数据协同分析, 显著提升质量决策科学性, 促进跨部门质量信息共享, 未来可通过模型参数优化进一步扩展应用场景。

**关键词:** 质量态势评估; 元器件质量管理; 全寿命周期数据; 故障预测; BP神经网络模型; 超参数优化

**中图分类号:** TB114.1; TN60; TP183; TP301.6

**文献标识码:** A

**DOI:** 10.14106/j.cnki.1001-2028.2025.0190

**引用格式:** 邱云峰, 李泽宏. 基于超参数优化机器学习算法与BP神经网络模型的元器件质量监测与故障预测研究[J]. 电子元件与材料, 2025, 44(10): 1237-1244.

**Reference format:** QIU Yunfeng, LI Zehong. Research on component quality monitoring and fault prediction based on hyperparameter-optimized machine learning algorithms and BP neural network model [J]. Electronic Components and Materials, 2025, 44(10): 1237-1244.

## Research on component quality monitoring and fault prediction based on hyperparameter-optimized machine learning algorithms and BP neural network model

QIU Yunfeng<sup>1,2</sup>, LI Zehong<sup>1</sup>

(1. University of Electronic Science and Technology of China, Chengdu 611731, China; 2. Guizhou Aerospace Institute of Measuring and Testing Technology, Guiyang 550009, China)

**Abstract:** To address the limitations of traditional quality management methods in processing and analyzing massive data for electronic components, this study aims to establish an intelligent quality monitoring mechanism for enhancing the accuracy and reliability of quality assessment. A novel dual-model framework integrating quality monitoring and fault prediction was established using the whole-life-cycle multi-source data; 1) A quality assessment model employing hyperparameter-optimized machine learning algorithms was constructed, utilizing six-dimensional feature data covering factory inspection, in-process quality assurance, and defect records; 2) A fault prediction model was designed based on a backpropagation (BP) neural network to enable dynamic early warnings. Experimental validation on JZC-084 electromagnetic relays and J599F26D

low-frequency connectors demonstrated that the proposed method achieved a fault prediction error rate lower than 0.1% and a quality assessment accuracy of 95.1%, which exceeded technical specifications. Verification via the random forest classifier showed average precision, recall, and F1-score values of 83.6%, 81.2%, and 78.3%, respectively. This data-driven approach significantly enhances scientific decision-making in quality management through real-time monitoring and cross-departmental data synergy. Future work will focus on model parameter optimization and scenario expansion to enhance prediction comprehensiveness.

**Keywords:** quality situation assessment; component quality management; whole-life-cycle data; fault prediction; BP neural network model; hyperparameter optimization

随着电子装备复杂性与可靠性需求的不断提升,作为电子装备核心基础单元的元器件,其质量控制已成为制约系统效能的关键因素<sup>[1]</sup>。有研究表明,超过60%的电子系统故障可追溯至元器件质量问题,而现代工业场景中元器件呈现的多批次、海量数据与多品类特征,进一步加剧了质量管理的复杂性。传统方法主要依赖人工经验与统计规则,难以有效地整合全生命周期内的质量数据,更无法满足实时监测与早期预警的工程需求<sup>[2]</sup>。

近年来,学术界在质量分析领域取得了显著进展:统计过程控制(SPC)技术通过工序能力指数来评估批次质量稳定性<sup>[3-4]</sup>,基于应力损伤机理的失效物理模型预测元器件寿命<sup>[5]</sup>,机器学习算法如随机森林、支持向量机等也被用于质量分类等<sup>[6-7]</sup>。然而,现有研究仍存在三大瓶颈:其一,数据利用局限于单一阶段(如出厂检验或现场失效),缺乏跨生命周期多源异构数据的深度融合;其二,模型构建多采用固定参数配置,未针对质量数据的时序性与高维度特征进行自适应优化;其三,分析方法侧重事后追溯,难以为预防性维护提供实时决策支持。这些问题导致质量态势评估精度不足、故障预警滞后,严重制约高可靠电子系统的研发进程<sup>[8-9]</sup>。

为突破上述局限,本研究提出了一种融合多源数

据与智能算法的协同解决方案。通过构建“质量监测-故障预测”双模型架构,集成超参数优化机器学习与BP神经网络方法<sup>[10-12]</sup>,系统性解决了全生命周期数据整合、动态特征提取等核心问题。建立的质量评估模型在JZC-084电磁继电器与J599F26D低频连接器中实现了95.1%的准确率,故障预测误差低于0.1%,显著优于现有统计方法与单一数据源模型<sup>[13-17]</sup>。本研究揭示了质量特征与失效模式间的定量关联规律,构建了复杂电子系统可靠性分析的新方法体系,不仅为失效机理研究提供了理论依据,更对电子产品可靠性设计与寿命预测具有重要工程指导意义。

## 1 元器件质量监测与故障预测的研究背景和基本原理

### 1.1 元器件质量监测与故障预测的研究背景

元器件质量态势评估通过整合全生命周期数据,构建了包含6个主要特征的质量指标体系,服务于质量管理人员、选用管理和设计人员的实时监测与预警需求。如图1所示,该评估体系分为三层:第一,数据获取层通过技术手段与人机协作方式采集全生命周期数据;第二,状态监测层利用关联规则挖掘技术分析数据内在关联;第三,决策支持层通过机器学习模型预测质量演化趋势。

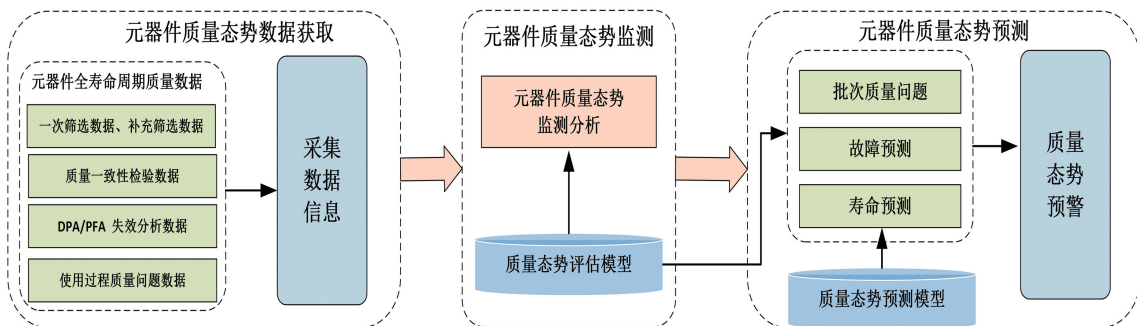


图1 元器件质量态势评估总体技术方案图

Fig. 1 Technical scheme for component quality assessment

### 1.2 元器件质量监测的基本原理

元器件质量监测的核心是通过超参数优化算法构建机器学习模型, 提取质量数据特征, 运用大数据挖掘算法建模, 评估元器件态势变化趋势, 为质量监控提供显性化分析支撑。

采用的机器学习算法主要为随机森林预测算法, 为了更全面地评估随机森林预测算法的性能, 引入了人工神经网络(Artificial Neural Network, ANN)和极限梯度提升(XGBoost)这两种常见机器学习算法进行对

比分析。ANN 通常包含多个隐藏层, 能够自动提取和学习数据的特征表示, 从而实现对复杂任务的准确预测; XGBoost 是基于 Boosting 算法的思想, 在每一轮训练中沿着残差减小的负梯度方向建立分类回归树, 并且引入树模型的复杂度以增强泛化性能。

为了使机器学习模型达到最佳性能, 需要对模型的超参数进行优化。各优化算法的流程如图 2 所示。主要有遗传算法(GA)、差分进化(DE)算法、粒子群优化(PSO)算法和贝叶斯优化(BO)算法。

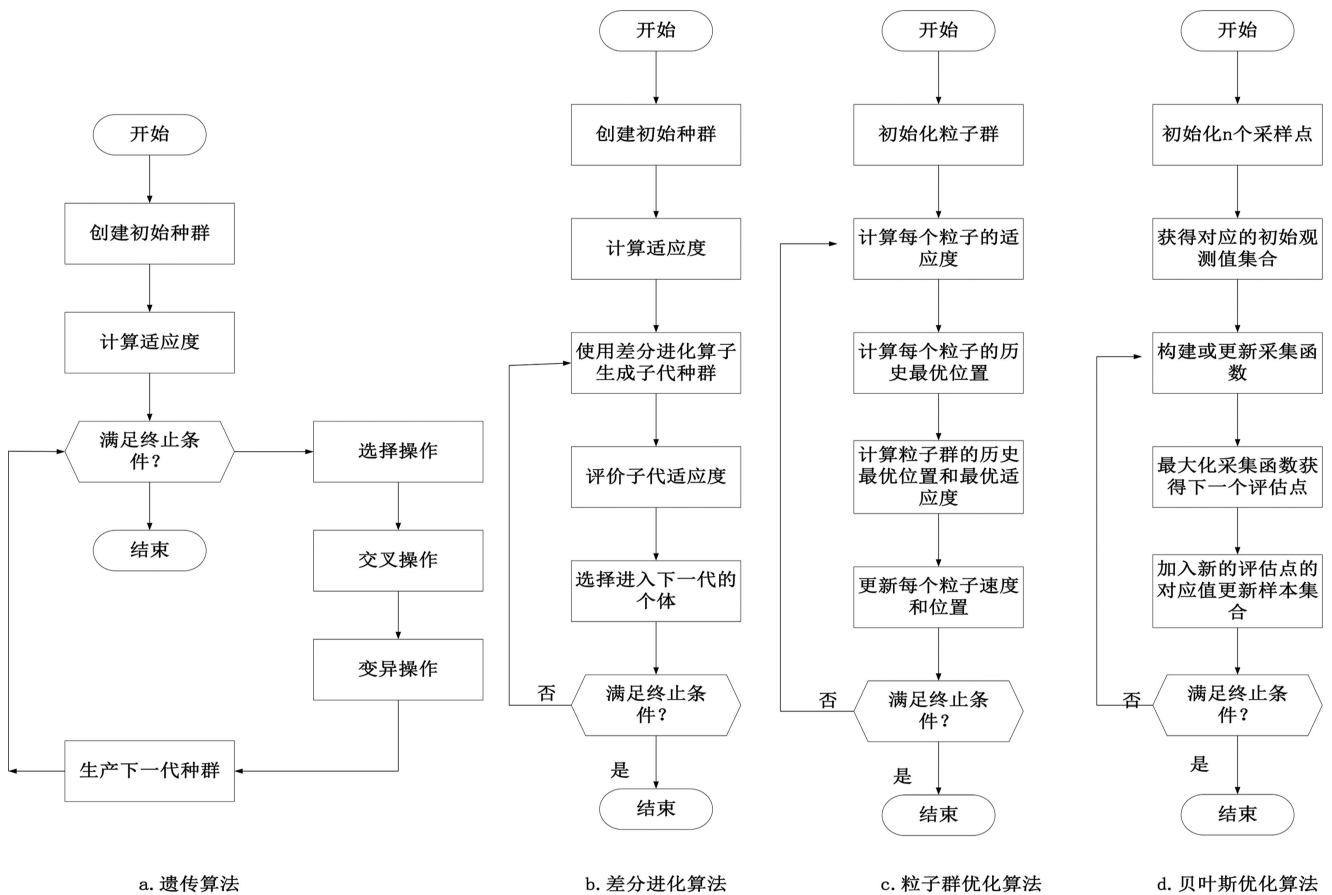


图 2 超参数优化算法流程图

Fig. 2 Flowchart of hyperparameter optimization algorithm

### 1.3 元器件故障预测的基本原理

BP 神经网络是一种具有反向传播功能的人工神经网络, 基于 BP 神经网络的故障预测模型采用三层架构, 如图 3 所示: 输入层与隐藏层各含 64 个神经元, 网络中的每个神经元是一个节点, 网络由输入层、隐藏层和输出层组成。连接权重系数负责连接前层和后层。

在模型训练过程中, 通过反向传播算法计算输出误差, 并采用 RMSprop 优化器动态调节权重。为防止

过度拟合, 设置早停机制(val\_loss 监控)与 L2 正则化约束。具体训练过程如下, 通过以下两个步骤来更新这些权值。隐藏层中的所有神经元的输出通过以下等式计算:

$$net_i = \sum_{j=0}^m w_{ji}x_j, \quad i = 1, 2, \dots, n \quad (1)$$

$$y_i = f_H(net_i), \quad i = 1, 2, \dots, n \quad (2)$$

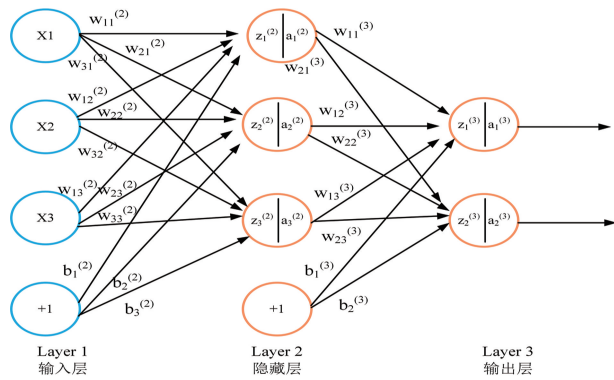


图3 BP神经网络结构图

Fig. 3 Architecture of BP neural network

式中:  $net_i$  是第  $i$  个节点的激活值;  $y_i$  是隐藏层的输出;  $f_H$  为节点的激活函数。

本研究在寿命预测中使用 ReLU 函数以及 Sigmoid 函数作为激活函数。ReLU 函数又称为修正线性单元 (Rectified Linear Unit), 是一种分段线性函数, 其弥补了 sigmoid 函数以及 tanh 函数的梯度消失问题。ReLU 函数如图 4 所示曲线。

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

Sigmoid 函数是将取值为  $(-\infty, +\infty)$  的数映射到  $(0, 1)$  之间。Sigmoid 函数如图 5 所示曲线。

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (4)$$

Sigmoid 函数作为非线性激活函数, 可用在网络

最后一层, 作为输出层进行二分类。

## 2 质量监测与故障预测的模型建立

### 2.1 基于超参数优化机器学习算法的质量监测方法

基于机器学习算法的元器件质量态势感知预测模型框架流程图如图 6 所示。具体包含: 元器件质量态势感知数据采集、数据预处理与划分、机器学习模型建模、模型评估四部分。

#### 1) 元器件质量态势感知数据采集

主要采集了 XX-12A、XX-22 等型号的系统元器件选用报告、双清单材料、质量工作总结报告、近 10 年元器件筛选信息等数据, 提取了示范型号设计选用数据、质量问题数据、质量检验数据等组成元器件质量问题溯源及预警数据集。




图4 ReLU 函数

Fig. 4 ReLU activation function




图5 Sigmoid 函数

Fig. 5 Sigmoid activation function

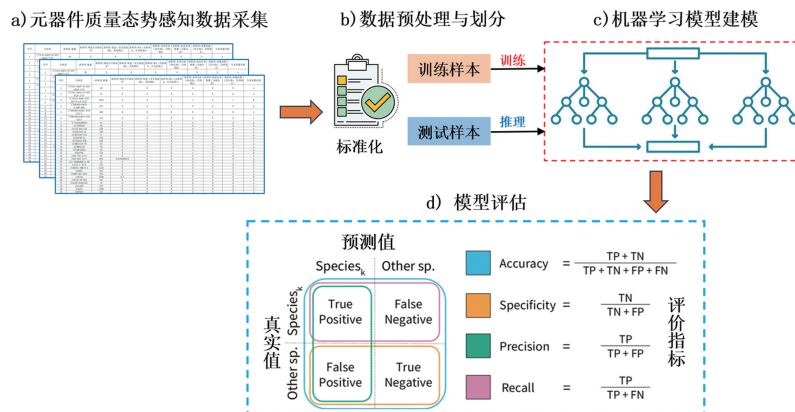


图6 元器件质量态势感知模型框图

Fig. 6 Framework of component quality awareness mode



阵及预测结果如图 8 所示。

混淆矩阵:

```
[[135  4  0  0]
 [ 2 11  0  0]
 [ 0  0  2  2]
 [ 0  0  0  2]]
```

分类结果:

	precision	recall	f1-score	support
A	0.985	0.971	0.978	139
B	0.733	0.846	0.786	13
C	1.000	0.500	0.667	4
D	0.500	1.000	0.667	2
accuracy			0.949	158
macro avg	0.805	0.829	0.774	158
weighted avg	0.959	0.949	0.951	158

图 8 机械学习模型测试结果图

Fig. 8 Precision results of mechanical learning model testing

模型测试结果如表 2 所示, 模型预测准确率为 95.1%。

### 2.2 基于 BP 神经网络的故障预测方法

故障预测模型分为数据处理、构建寿命预测模型、

模型训练及优化、模型验证四部分, 具体流程如图 9 所示。

#### 1) 数据处理

数据处理采用超参数优化机器学习算法的质量监测方法, 进行数据整合与质量监测。

整合了 11 个文档的 254 条数据至 CSV 文件, 剔除非共有字段(如吸合回跳、PARTID 等), 保留全文档一致的转换功能、释放功能字段。将设备状态 PASSFG 的 FAIL/PASS 转换为 0-1 标签。

表 2 机械学习模型测试结果

Tab. 2 Testing results of mechanical learning model

实验次数	准确率(%)	精确率(%)	召回率(%)	F1 分数(%)
1	95.6	84.6	89.1	85.5
2	94.9	85.8	71.6	71.9
3	94.9	80.5	82.9	77.4
平均值	95.1	83.6	81.2	78.3

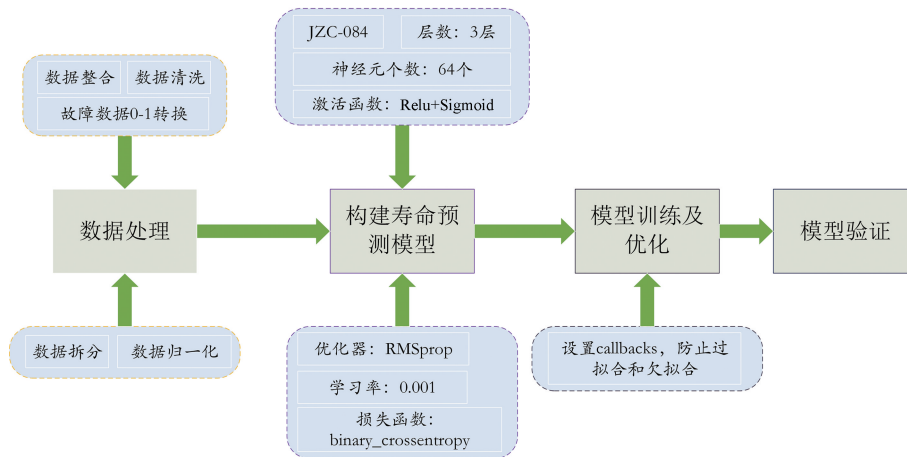


图 9 故障预测流程图

Fig. 9 Fault prediction workflow diagram

用 Pandas 加载数据并清除无效值, 分离特征与标签: 删除目标字段 PASSFG 后, 80%数据作为训练集, 20%作为验证集, 标签单独提取。最后对特征数据进行归一化处理以优化训练效果。

#### 2) 构建寿命预测模型

构建了基于 BP 神经网络的二分类模型: 模型设置为 3 层结构(输入层、隐藏层、输出层), 输入层与隐藏层神经元数量根据数据特征确定, 输出层为 1 个神经元。激活函数选用 ReLU(输入层、隐藏层)和 Sigmoid(输出层), 使输出值限制在 [0, 1] 区间。训练配置采用二元交叉熵损失函数(binary \_

crossentropy)、RMSprop 优化器, 并以准确率(ACC)作为评估指标。

#### 3) 模型训练及改进

在数据拟合过程中, 为每个完成的时期打印一个点来显示训练进度, 选择 1000 次作为本次模型的数据拟合次数, 按 20%比例从训练集中取出一部分作为验证集; 返回一个 history 对象, 储存训练过程中的 loss 信息等, 作为后续的数据模型图例展示。为了防止过拟合, 首先定义了 callbacks 的操作设置, 采用了每 10 次拟合进行一次判断是否停下, 判断依据是当 val\_loss 不改变甚至降低。在训练过程中, 如果出现了欠拟合

的现象, 即删除 callback 操作, 并将训练次数调整为 200 次。

4) 模型验证

由于继电器正常数据量较小, 在模型训练完成后, 将 4 条正常数据与 6 条故障数据整合为验证数据集, 通过预测输出, 比对误差情况进行模型验证。

3 实验设计与故障预测模型结果

3.1 JZC-084 继电器的故障预测结果

JZC-084 系列电磁继电器基于 BP 神经网络故障预测模型核心部分如图 11 所示, 构建如上节所述模型。

在数据拟合过程中, 为每个完成的时期打印一个点来显示训练进度, 由于在训练过程中出现了欠拟合的现象, 所以删除 callback 操作, 并将训练次数调整为 200 次。按 20% 比例从训练集中取出一部分作为验证集, 返回一个 history 对象, 储存训练过程中的 loss 信息等。根据验证集的预测数据与真实数据的对比误差情况来观察模型的训练效果, 以便进行模型验证。

1) 测试案例一

继电器数据一共 54 条, 其中继电器正常数据有 4 条。在模型训练时, 随机选取了继电器总数据中 80% 的数据作为训练集, 剩下的 20% 作为测试集, 测试集的数据如图 10 所示。

9	0	70	1	115	1	174	1	211	1	246	1
21	1	72	1	117	1	175	1	212	1	250	1
25	1	77	1	127	1	177	1	216	1		
29	1	79	1	140	1	185	1	221	1		
32	1	81	1	142	1	192	1	224	1		
36	1	82	1	147	1	193	1	230	1		
39	1	87	1	148	1	195	1	235	1		
47	1	88	1	165	1	197	1	238	1		
58	1	99	1	167	1	208	1	241	1		
67	1	103	1	172	1	211	1	242	1		

图 10 JZC-084 继电器测试集真实数据  
Fig. 10 Test data of JZC-084 electric relay

将预测结果大于等于 0.98 的判定为故障器件“1”, 预测结果小于等于 0.02 的判定为正常器件“0”。预测误差是对训练后模型的考核指标, 如果模型预测结果与测试集真实结果不一致(例如真实值为“1”, 预测结果为“0”), 则认为预测结果产生了误差。最终“0”代表元器件正常无损坏, “1”代表元器件为故障器件。第一列表示测试集数据在总数据中的序号。该模型对测试集的预测数据如图 11 所示。

由图可知, 测试集数据中只有第一个数据为“0”, 其余数据均为“1”。对测试集的预测数据中,

第一个为 0.00090298, 其余均为 1。预测误差小于 0.1%, 满足技术指标。

[0.00090298]	[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]
[1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]	] [1.]

图 11 JZC-084 继电器测试集预测数据  
Fig. 11 Predicted data of JZC-084 electric relay test set

2) 测试案例二

由于继电器数据中正常数据的数据量只有四个, 导致了随机选取的测试集中正常数据只有一个, 正常数据量过少。将 4 条正常数据与 6 条故障数据整合为测试数据集, 再次进行测试。测试数据集的真实数据和模型对测试集预测数据如图 12 所示。

0	1	[1.]	] [1.]
1	1	[1.]	] [1.]
2	0	[0.00000122]	] [0.99999976]
3	1	[0.99999976]	] [0.00000057]
4	0	[0.00000057]	] [0.99999994]
5	1	[0.99999994]	] [0.99999990]
6	1	[0.99999990]	] [0.99999950]
7	1	[0.99999950]	] [0.00000001]
8	0	[0.00000001]	] [0.00005241]
9	0	[0.00005241]	] [0.00005241]

图 12 JZC-084 测试数据与预测数据  
Fig. 12 JZC-084 test data versus predicted data

测试数据中序号为 2, 4, 8, 9 的数据为“0”, 其余为“1”。模型预测出的序号为 2, 4, 8, 9 的数据结果非常接近“0”, 其余为“1”或者非常接近“1”。模型的预测误差均小于 0.1%, 故障预测模型准确率不低于 80%, 满足技术指标。

3) 置信度分析

由于故障预测结果预测值是“0”和“1”, 不符合正态分布, 无法进行置信区间的估算。

3.2 J599F26D 低频连接器的故障预测结果

J599F26D 系列低频连接器故障预测模型是先进行基于超参数优化机器学习算法的质量监测, 再采用基于 BP 神经网络的二分类模型。

J599F26D 系列低频连接器数据共 651 条, 其中绝缘电阻异常数据有 4 条, 插拔力异常数据 12 条(绝缘电阻和插拔力超差代表器件失效)。在模型训练时, 随机选取了总数据中 80% 的数据作为训练集, 剩下的

20%作为测试集，测试集的真实数据如图 13 所示。预测数据如图 14 所示。

0	70	1	115	1	174	1	211
0	72	1	117	1	175	1	212
1	77	1	127	1	177	1	216
1	79	1	140	1	185	1	221
1	81	0	142	1	192	1	224
1	82	1	147	1	193	0	230
1	87	1	148	1	195	1	235
1	88	1	165	1	197	1	338
1	99	1	167	1	208	1	341
1	103	1	172	1	211	1	342

图 13 J599F26D 低频连接器测试集真实数据

Fig. 13 Test data of J599F26D low-frequency connector

[0.00090298]	[1.]	]	[1.]	]	[1.]	]	[1.]	]	
[0.00090298]	[1.]	]	[1.]	]	[1.]	]	[1.]	]	
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[0.00090298]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[0.00090298]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]
[1.]	]	[1.]	]	[1.]	]	[1.]	]	[1.]	]

图 14 J599F26D 低频连接器测试集预测数据

Fig. 14 Predicted data of J599F26D low-frequency connector test set

由图可知，测试集数据中只有 4 个数据为“0”，其余数据均为“1”。对测试集的预测数据中，有 4 个为“0.00092”，其余均为“1”。预测误差小于 0.1%，故障预测模型准确率不低于 80%，满足技术指标。

### 4 结论

在电子装备可靠性需求日益提升的背景下，本研究提出了一种融合全寿命周期多源数据的元器件质量监测与故障预测方法。通过建立超参数优化随机森林模型，实现了质量态势的精准评估，实验准确率达到 95.1%；基于 BP 神经网络的故障预测模型在继电器与连接器测试中表现出色，预测误差低于 0.1%，故障预测模型准确率不低于 80%。未来将重点开发高效动态多源数据建模、将模型应用扩展至集成电路及功率模块等核心器件，并融合物理失效规律与 AI 模型，以驱动质量管理体系智能化升级。

### 参考文献：

- [1] 陈卓. 基于故障物理的 MOSFET 寿命预测研究 [D]. 成都: 电子科技大学, 2021.
- [2] 孟彦辰. 基于性能参数退化的航天继电器可靠性建模与评估研究 [D]. 哈尔滨: 哈尔滨工业大学, 2015.
- [3] 王宇琦. IGBT 疲劳老化失效剩余使用寿命预测的研究 [D]. 西安: 西安电子科技大学, 2017.
- [4] Sahay R, Pugalenti K, Raghavan N. Remaining useful life estimation of lithium-ion batteries via hyperparameter optimized bi-long short-term memory recurrent neural networks [C]//2023 Global Reliability and Prognostics and Health Management Conference. NY, USA: IEEE, 2023; 1-8.
- [5] 张菲菲, 李志刚. 基于 BP 神经网络的继电器剩余寿命预测 [J]. 低压电器, 2012(1): 11-14.
- [6] 鲁光祝. IGBT 功率模块寿命预测技术研究 [D]. 重庆: 重庆大学, 2012.
- [7] 王宇琦. IGBT 疲劳老化失效剩余使用寿命预测的研究 [D]. 西安: 西安电子科技大学, 2017.
- [8] 郭稳. 功率 MOSFET 剩余使用寿命预测方法及热疲劳建模研究 [D]. 南昌: 华东交通大学, 2020.
- [9] 王一行. VD 功率 MOSFET 失效机理及寿命预测技术研究 [D]. 哈尔滨: 哈尔滨工业大学, 2017.
- [10] 王佳炜, 王召斌, 黄周霖. 果蝇算法优化的 BP 神经网络在电磁继电器贮存寿命预测中的应用 [J]. 电器与能效管理技术, 2019(2): 19-24.
- [11] 张菲菲, 李志刚. 基于 BP 神经网络的继电器剩余寿命预测 [J]. 低压电器, 2012(1): 11-14.
- [12] 李雪岭. 基于 BP 神经网络的交流接触器电寿命预测 [D]. 天津: 河北工业大学, 2015.
- [13] 郭旭东, 宋浏阳, 王华庆, 等. 基于改进 CNN-LSTM 的剩余使用寿命预测方法 [J]. 测控技术, 2021, 40(5): 21-26.
- [14] 武博, 靳冬, 杨积东, 等. 基于检测数据主成分分析的筒弹寿命评估预测模型 [J]. 导弹与航天运载技术, 2021(6): 60-63.
- [15] 王泽平. 基于深度神经网络的锂离子电池剩余使用寿命预测方法研究 [D]. 重庆: 重庆大学, 2020.
- [16] 陈明, 胡安, 刘宾礼. 绝缘栅双极型晶体管失效机理与寿命预测模型分析 [J]. 西安交通大学学报, 2011, 45(10): 65-71.
- [17] 尹双艳, 吴美熹, 李汉智, 等. 一种基于间接健康因子的锂离子电池剩余使用寿命预测方法 [J]. 航天器环境工程, 2021, 38(6): 648-654.