

doi: 10.7690/bgzdh.2026.03.014

基于云边协同的枪械元器件生产质量大数据感知与可视方法

胡 瑶¹, 王宪升¹, 孙嘉伟², 姜黎明¹, 郝 佳², 张晓宁²

(1. 重庆建设工业(集团)有限责任公司工艺技术研究, 重庆 400054;

2. 北京理工大学机械与车辆学院, 北京 100081)

摘要: 针对枪械元器件生产制造过程中的质量问题, 提出一种基于云边协同的枪械元器件生产质量预警方法。通过云端数据分析和边缘智能感知, 实现对生产过程中的异常情况实时预警和快速处理, 从而提升生产制造率和质量。通过云边协同架构, 实现模型的云端训练与边缘端实时样本采集, 增强了枪械元器件质量预警算法在特定工况下的适应性和质量预警的实时性, 并通过边缘智能感知技术实现了智能化的预警反馈。实验结果表明, 该方法具有较高的实时性和准确性。

关键词: 大数据感知; 云边协同; 卷积神经网络; 迁移学习

中图分类号: TP392 **文献标志码:** A

Big Data Perception and Visualization Method for Firearms Component Production Quality Based on Cloud-edge Collaboration

Hu Yao¹, Wang Xiansheng¹, Sun Jiawei², Jiang Liming¹, Hao Jia², Zhang Xiaoning²

(1. Institute of Process Technology, Chongqing Jianshe Industry (Group) Co., Ltd., Chongqing 400054, China;

2. School of Mechanical and Vehicle Engineering, Beijing Institute of Technology, Beijing 100081, China)

Abstract: A quality warning method for firearm component production based on cloud edge collaboration is proposed to address quality issues in the manufacturing process of firearm components. Through cloud data analysis and edge intelligent perception, real-time warning and rapid processing of abnormal situations in the production process can be achieved, thereby improving the production rate and quality. Through the cloud edge collaborative architecture, the cloud training of the model and real-time sample collection at the edge are achieved, enhancing the adaptability of the firearm component quality warning algorithm under specific working conditions and the real-time quality warning. Intelligent warning feedback is also achieved through edge intelligent perception technology. The experimental results show that this method has high real-time performance and accuracy.

Keywords: big data pedigree; cloud edge cooperative; convolution neural network; transfer learning

0 引言

当前, 军工装备生产制造正在加速进入数字化阶段, 数据正在对装备生产的各个环节产生深远影响。在装备的质量控制方面, 各种维度的质量数据分散在各个业务环节, 造成质量数据孤岛、难以统筹利用、无法形成有效数据资产, 急需通过标准化的途径规范认知, 整合行业的数据特征, 行成面向离散军工制造的质量大数据标准体系。当前, 成枪及枪械元器件的质量是军工装备生产企业关注的重要指标。如果能够对成枪及元器件的质量进行预测, 则对枪械的生产制造过程管控大有帮助, 可提前预知质量问题的发生, 减少带来的成本和经济损失。

枪械元器件是枪支系统中不可或缺的组成部分, 其质量的好坏直接影响到枪支的性能和安全。然而, 由于制造技术和设备水平的不同, 各企业生

产出的枪械元器件质量上存在差异。如何提高枪械元器件生产的质量和效率, 成为枪械生产企业亟待解决的问题。其中, 成枪的合格率受诸多因素影响, 例如原材料、工艺、装配等, 笔者仅论述关键工艺尺寸数据波动对成枪合格率的影响。同时, 传统制造业的生产方式存在一定的局限性, 难以适应不断变化的市场需求和技术变革; 因此, 数字化转型成为制造业的趋势。

为解决上述问题, 国内外学者提出采用卷积神经网络(CNN)替代人工进行特征提取^[1-2], 将特征提取与分类在训练阶段相结合, 并将其优化为单个学习块, 在训练样本数量较大的情况下, 可获得较高的质量感知精度单纯在云计算环境下进行学习, 还必须考虑不同的用户对产品质量的适应性, 针对不同应用场景分别进行学习以获取对应的模型参数, 导致训练参数增加、任务繁重, 且可能与质量感知

收稿日期: 2024-11-21; 修回日期: 2024-12-15

第一作者: 胡 瑶(1996—), 男, 重庆人。

和时限要求冲突^[3-5]。

随着物联网技术的不断发展，越来越多的数据产生在网络边缘。为了提高效率，现在的研究越来越关注边缘计算和云计算等概念；然而，如果只依赖于边缘计算来训练模型，由于边缘端的计算能力和存储能力有限，训练过程会变得缓慢。

收集足够的数据以满足模型充分训练的任务也很具挑战性。为解决问题，可借鉴深度学习领域中的思想，即将云端资源的高性能计算和存储能力与边缘设备的个性化适应能力和时间限制控制相结合^[6]。笔者提出一种基于云边协同的枪械元器件生产质量预警方法，最大化云端和边缘端的优势，通过协调计算资源和实时性要求，实现对枪械元器件的实时质量波动进行感知和预测。

1 整体框架设计

整体方案的构建思想是采用云端和边缘端的协同。云具有强大的计算能力和丰富的存储能力，可实现大规模的复杂计算，并可储存大量的数据；然而，云服务的时效性和可定制性使其无法满足实时需求。在边缘端，因其与业务对象的高度耦合，使得其具有更强的实时性和可实现业务定制化等优势。该方法在处理海量数据时，存在着计算资源受限的问题，这已成为制约其发展的瓶颈。笔者针对枪械元件生产实时质量感知问题，综合分析云/边缘端的优缺点，提出充分发挥两者优势的解决方案。设计整体框架如图 1 所示。

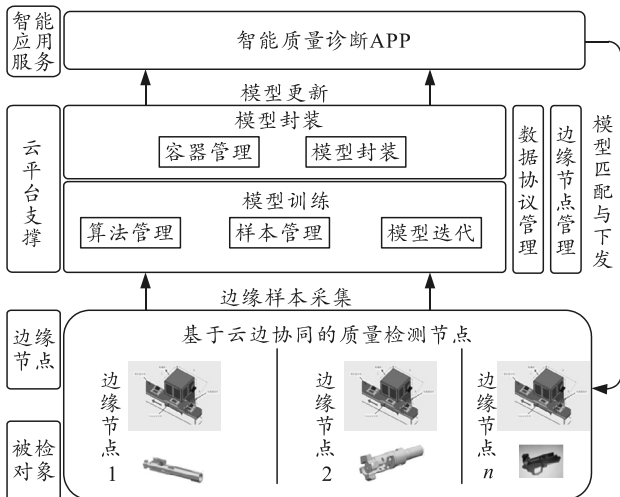


图 1 整体框架设计

为了实现云端数据分析和边缘智能感知，需要对生产过程中产生的数据进行采集。数据采集主要包括：

- 1) 确定采集对象：确定需要采集的参数和指

标，例如温度、湿度、振动等。

- 2) 选择传感器和智能设备：根据采集对象的不同，选择适合的传感器和智能设备。

- 3) 设置传感器和智能设备：在生产现场设置传感器和智能设备，将采集到的数据传输到云端进行分析。

图 1 中，云端主要进行存储训练样本数据和训练普适化模型的过程。通过持续训练更新枪械元器件的质量感知和可视化普适模型，从而得到一般化的训练结果。在边缘端通过数据感知装置采集枪械元器件的实时状态数据，并将其传递给云端进行存储，以用于不同的质量感知场景中作为中间结果使用。可以看出：云端数据分析主要通过对生产过程中产生的数据进行分析，发现其中的异常情况并进行预警。边缘智能感知则主要通过在生产现场设置传感器和智能设备，实时监测生产过程中的各种参数和指标，并通过分析数据发现异常情况并进行预警。云端数据分析和边缘智能感知相结合，可以实现生产过程中的实时监测和快速预警，从而帮助企业及时发现生产质量问题，采取措施避免问题的进一步扩大，从而提高产品质量和生产效率。

2 云边协同质量预警算法的设计思路

2.1 枪械元器件质量预警算法的设计准则

笔者提出一种质量追溯算法，利用枪械元器件的质量敏感尺寸信号作为质量预测模型的输入，并以枪械元器件质量异常预警作为可视化的输出。这是因为枪械元器件的尺寸信号易于采集，并能够很好地反映元器件的状态。在云端使用样本数据训练了一个普适化质量预警模型，同时采用实时采集和训练的方式，在边缘端生成了面向个性化工况的枪械元器件质量预测模型。笔者基于实时采集的枪械元器件振动数据实现了对枪械元器件质量的实时质量感知。

在上述任务场景中，质量预警算法需要全面提取质量敏感尺寸信号的特征。同时，云端的质量感知模型需要服务于个性化的边缘端质量感知与可视任务。笔者提出了面向枪零部件关键尺寸灵敏度分析方法，灵敏度分析用于研究模型状态或输出变化对系统参数或周围条件变化的敏感程度的方法。笔者通过灵敏度分析确定对合格率预测模型影响较大的工艺尺寸参数，以此选择关键检测参数。灵敏度分析依据的是检测数据(枪械的工艺尺寸参数值和对应的合格率)。

2.2 关重工艺尺寸的灵敏度分析

全局灵敏度分析可评估单个参数及其相互作用对模型输出的影响程度。笔者使用 Sobol 方法分析了合格率模型的工艺参数敏感性，其基础是用方差表征输出的不确定性，分析过程如图 2 所示。

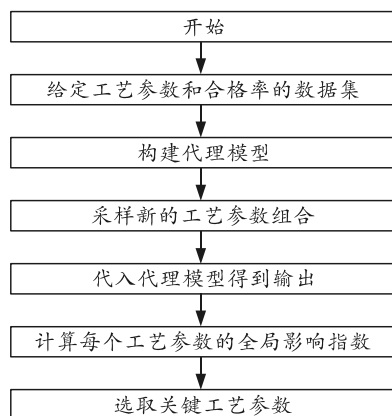


图 2 工艺参数对成枪射击的全局灵敏度分析流程

工艺参数对成枪射击的全局灵敏度分析：

1) 给定工艺参数组合和对应的合格率数据集。在枪械生产的流程中，必须进行质量控制测试以保证其质量。这些测试包括测量枪械元器件的特征变量，例如表面粗糙度和套管尺寸等。用表示测量得到的枪械的特征，用表示枪械的数据集。然后，测量枪械射击准确度 Y 。

2) 构建代理模型。通过构建关重尺寸和射击准确率的代理模型，比如多项式响应曲面法、克里金法、梯度增强克里金法、支持向量机、空间映射和人工神经网络等方法，对一组关键尺寸的组合和其对应的射击准确度进行分析和预测。

Sobol 方法假定输出结果具有对称分布，并在此基础上认为模型输出的方差为各参数所有阶方差之和。方差越大，则说明模型的输出变化对该参数变化的敏感程度越高。

3) 采样新的工艺参数组合。Sobol 方法，就是在其切实可行域中对各参量作蒙特卡洛抽样，并将抽样后的参量取值用于仿真，从而获得较多的结果。

这个参数的一阶影响指标是参数方差与输出结果方差之比，高阶影响指数则可通过参数和其他参数的偏方差计算得出。这些指标用于灵敏度分析以确定哪些参数对系统最敏感。

4) 带入代理模型得到输出。将采样得到的采样数据带入已经建立好的代理模型，得到不同采样参数组合所对应的的输出。

5) 计算每个工艺参数的全局影响指数。一个参

数的全局影响指数是该参数在系统中对目标变量的影响程度的综合指标，包括一阶和高阶影响指数的累加。

通过上述步骤，笔者可以分别计算出的一阶影响指数和全局影响指数。估计量的准确度取决于 N ，可以通过顺序地添加点，并计算指数来选择 N 的值，直到估计值达到一些可接受的收敛。

6) 选取关键工艺指数。经过 5)，可以得到每个工艺参数的全局影响指数。分别对这些工艺参数的全局影响指数进行排序，然后选择前 N 个最大的指数所对应的参数，即是此类工艺参数的关键工艺指数。

2.3 云端算法的构建与训练

近年来，枪械元器件质量预测领域涌现出一些优秀的机器学习算法^[7-9]。预测模型的构建分为：1) 基于时间序列的模型构建方法；2) 基于神经网络的模型构建方法。笔者基于神经网络模型，引入长短期记忆网络(long short-term memory, LSTM)。该模型不是单独将关键工艺参数映射到合格率，而是能够随时间学习从关键工艺参数到合格率的映射函数。

LSTM 是循环神经网络 RNN 分支，其设计的目的旨在比普通的 RNN 更好地存储和访问历史序列信息。LSTM 擅长序列到序列的学习并且引领某些领域，如机器翻译进入了一个颠覆性发展阶段。

针对目前循环神经网络中普遍存在的 LSTM 神经元单元，在其外部 RNN 环路的基础上，引入了“LSTM 细胞”，实现了对 LSTM 神经元单元的控制，从而有效地解决这些问题。经典的 LSTM 网络与一般的 RNN 结构相似，唯一的区别就是 LSTM 单元的定义不一样。图 3 为“LSTM 细胞”的环路神经网络的单位。




图 3 “LSTM” 细胞单元的结构

笔者首先根据事先人为指定的规则对加工数据

进行统计分析，计算每批次的成枪合格率，然后对数据进行归一化操作，这些合格率数据即为算法的训练数据。

算法的一个关键参数是滑动时间窗的大小，即多少个输入数据对应一个预测的输出数据，如图 4 所示。




图 4 滑动时间窗

指定滑动时间窗长度 N ，则每 N 个一次检验合格率对应一个成枪一次检验合格率预测值 q ，同时 LSTM 神经网络输入层特征个数也对应为 N 。通过指定滑动时间窗，可以实现对训练数据的分割和整理。如果滑动时间窗大小为 days_for_train ，给定序列的长度为 d ，将输出长度为 $(d - \text{days_for_train} + 1)$ 个输入/输出对。

- 模型输入：一次交验合格率历史数据。
- 模型输出：合格率预测值序列。
- 算法参数设置如表 1 所示。

表 1 算法参数设置

模型参数	内容
input_size	输入层特征个数：为滑动时间窗大小
num_layers	堆叠 LSTM 的层数，默认值为 1
hidden_size	隐藏层单位数
损失函数	均方损失函数
output_size	输出层特征个数，为 1

2.4 边缘端样本实时采集与算法模型迭代更新

在本文中，边缘端的主要任务是进行枪械元器件生产过程中的实时质量样本采集和模型计算。算法模型是通过云端下发的普适化模型参数，并通过云边协同架构到达边缘端进行特定化应用。为了适应不同边缘端的特性，需要进行相应的调整。主要的调整策略包括：

- 1) 根据边缘端样本输入，前期进行人工验证判断，将影响模型准确率的有效样本提取至云端模型进行再训练，对模型进行更新和备份；
- 2) 根据边缘端的计算资源和边缘样本，选择与之匹配的质量预警模型。

边缘端算法的更新与有效边缘样本选择策略如图 5 和 6 所示。

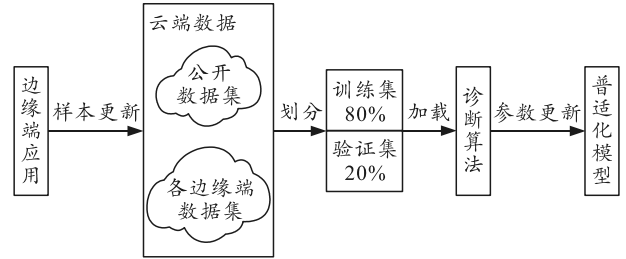


图 5 云边协同的模型更新迭代流程

图 5 中，采用云边协同架构设计实验环境，在云端使用 2 块 GTX3080GPU、CPU 和扩展的 2T 硬盘生成质量预警模型。

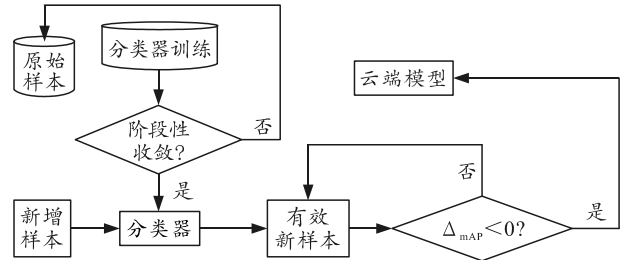


图 6 边缘有效样本选择策略

在边缘端，使用本地样本进行个性化训练，生成可应用于边缘端的个性化质量感知模型。实时采集振动信号，加载在个性化质量感知模型上，实时生成质量预警结果，做出相应的决策，该架构能够有效提高质量预测的准确性和效率。

3 实验设计与验证

通过实验方案设计探究：

- 1) 对比边缘请求云端模型进行计算，边缘模型实时计算的响应速度；
- 2) 通过运行协同的样本选择和模型更新，是否能够快速提高枪械元器件质量预警的准确率，并有效地节约训练时间和资源。

3.1 实验环境搭建

笔者设计的实验环境分为云端和边缘端 2 部分，云端硬件系统由 2 块 GTX3080GPU、CPU 和 2T 硬盘组成。整个云端普适化模型训练的程序使用 Python 完成，使用 Python 搭建实时质量感知、可视化和信号识别程序，能够对实时信号进行实时质量预警与可视化。

3.2 实验平台框架设计

实验平台框架设计方案如图 7 所示。云端实验平台负责基础模型的生成和定期更新模型的下发，云端基于 DOCKER 容器构建轻量化的工业 APP，支持分布式边缘质量检测单元的质量应用需求。

边缘实验平台负责实时采集有效样本和在线计算，将云端的模型在实际工况下应用和检验。边缘实验平台由边缘质量感知阵列+边缘计算单元+边缘质量模型组成，可对质量波动预警的准确性、运行时间进行记录，同时可以将有效样本定期上传至云端进行再训练。

3.3 实验结果

根据事先人为指定的规则对加工数据进行统计分析，计算每个批次的成枪合格率，选取 11 个批次的成枪数据，每个批次的成枪合格率如表 2 所示。

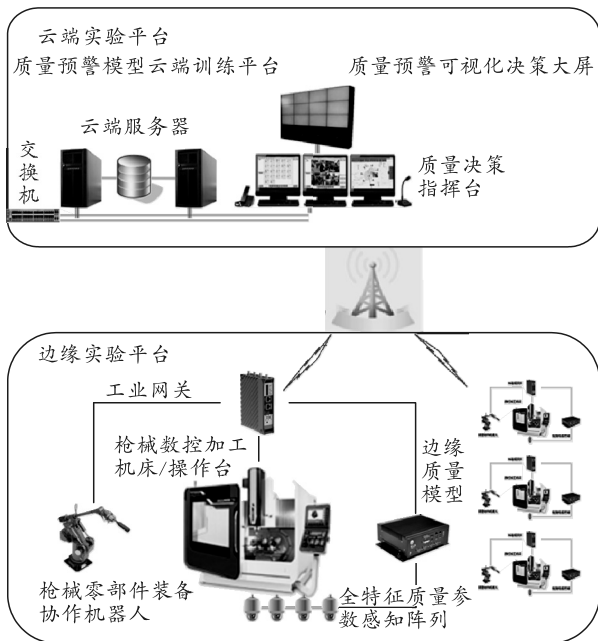


图 7 实验平台框架设计方案

表 2 成枪 1 次交验合格率预测样本 %

批次	1	2	3	4	5	6
合格率	0.98	0.98	0.99	0.97	0.97	0.98
批次	7	8	9	10	11	
合格率	0.96	0.98	0.95	0.97	0.96	

LSTM 神经网络的算法训练参数设置如表 3 所示。

表 3 LSTM 神经网络训练参数

LSTM 算法训练参数	取值	LSTM 算法训练参数	取值
输入层特征个数	3	输出层特征个数	1
隐藏层节点数	6	损失函数	均方损失函数
LSTM 的层数	2	迭代次数	500

利用表 4 中的训练数据训练 LSTM 神经网络模型，并以最后一个滑动窗口数据样本作为 LSTM 神经网络的预测输入，计算下批次合格率的预测值。本次实验基于前 11 批次的合格率数据进行循环训练，最终得到合格率预测模型，并进行模型测试。

表 4 LSTM 神经网络测试结果

输入	输出	耗时/ms
0.96	0.97	1 657
0.97	0.98	1 984
0.98	0.97	1 355
0.97	0.99	2 683
0.99	0.97	2 449
0.97	0.97	2 521
0.97	0.96	1 507
0.96	0.96	1 972

测试结果表明，基于云边协同的质量预测模型的训练和应用具有较好的实时性和自适应性，能够满足生产线边缘模型边训练边应用边更新的需求。

4 结束语

笔者提出了一种基于长短期记忆神经网络的云/边缘协同枪械元器件生产质量预警方法，通过采集、处理和分析生产过程中的数据，实现了实时的质量预警，并通过边缘智能感知技术实现了智能化的预警反馈。实验结果表明，该方法具有较高的实时性和准确性。理论上，该方法可以大幅缩短复杂工况下的质量预测模型的开发，从而节省大量训练成本。此外，该方法可以在训练样本不充足的情况下有效提高质量预警的准确性。由于其具有实时性、准确性和样本局限性等方面的优势，未来的研究将进一步探索其在更多关键零部件质量预测和质量感知方面的应用策略。其中，重点研究原材料、热处理和表面处理的工艺参数数据、批次间的差异数据等对合格率的影响，为制造枪械装备关键零部件的生产质量感知和预测性维护提供高可行性的方案。

参考文献：

- [1] CAO P, ZHANG S. TSNG 1Pre processing frce gear faul diagnosis using small datasets with deep convolutional neural network based transfer learning[J]. IEEE Xplore, 2017, 6(99): 26241-26253.
- [2] ABDELTABER O, AVCI O, KIRANYAZ M S, et al. 1-DCNNs for Structural damage detection: verifca tion on a structural health monitoring benchmark data[J]. Neuro computing, 2018, 275(1): 1308-1317.
- [3] JANSSENS O, SLAVKOVIKJ V, VERVISCH B, et al. Convolutional neural network based fault detection for rotating machinery[J]. Sound &Vibration, 2016, 377: 331-345.
- [4] SATYANARAYANAN M, BAHL P, CACERES R, et al. The case for vm based cloudlets in mobile computing[J]. Pervasive Computing, 2009, 8(4): 14-23.
- [5] BONOMI F, MILITO R, ZHU J, et al. Fog Computing and its role in the internet of things[C]//Proceedings of the Mcc Workshop on Mobile Cloud Computing. USA:

New York, 2012: 13-16.

[6] LUO Z, SMALL A, DUGAN L, et al. realtme deep learring computer vision on low computing[EB/OL] (2018-10-02)[2019-10-11]. https: //arxiv.org/abs/1810.01069.

[7] GUO X, CHEN L, SHEN C. Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis[J]. Measurement, 2016, 93: 490-502.

[8] LU C, WANG Z, ZHOU B. Intelligent fault diagnosis of rolling bearing using hierarchical convolutional network based health state classification[J]. Advanced Engineering Infor matics, 2017, 32: 139-151.

[9] ZHANG W, PENG G, LI C, et al. A new deep learning model for fault diagnosis with good anti noise and domain adaptation ability on raw vibration signals[J]. Sensors, 2017, 17(2): 425.

(上接第 47 页)

通过上述实验可知：笔者所提方法通过设备运行状态特征数据的降维处理，提高了故障识别效率，并通过模糊集与动态故障树的结合，提高了设备故障识别的正确度及精确度，获得更好的识别效果。

5 结束语

广播电视传输设备故障的及时发现，是保证广播电视平稳运行的关键，但是传统的方法不能较全面地识别广电传输设备故障状态，存在检测效率低、精确度低的问题；为此，提出基于动态故障树的广播电视传输设备故障状态识别研究。获取设备运行数据特征，对设备运行数据实行去噪处理，完成设备故障状态识别。实验结果表明：利用该方法能够精准快速识别广播电视传输设备故障状态，实际应用效果更好。该方法解决了传统方法中存在的问题，为设备故障识别领域奠定了基础。

参考文献：

[1] 梁睿君, 冉文丰, 余传粮, 等. 基于 CWT-CNN 的齿轮箱运行故障状态识别[J]. 航空动力学报, 2021, 36(12): 2465-2473.

[2] 詹君, 程龙生, 彭宅铭. 基于 VMD 和改进多分类马田系统的滚动轴承故障智能诊断[J]. 振动与冲击, 2020, 39(2): 32-39.

[3] 王硕禾, 巩方超, 古晓东, 等. 基于特征融合的变电设备类型及故障识别算法研究[J]. 铁道学报, 2021, 43(4): 95-100.

[4] 王化玲, 刘志远, 赵欣洋, 等. 基于故障敏感分量和改进 K 近邻分类器的故障状态识别[J]. 重庆大学学报,

2020, 43(12): 33-40.

[5] 王召广, 杨宇飞, 闫召洪, 等. 基于 ReliefF-LMBP 算法的涡轴发动机气路故障模式识别[J]. 推进技术, 2021, 42(1): 220-229.

[6] 赵柄锡, 冀大伟, 袁奇, 等. 采用时域与时频域联合特征空间的转子系统碰磨故障诊断[J]. 西安交通大学学报, 2020, 54(1): 75-84.

[7] 李俊, 黄开明, 帅晶. 无线探空仪回波信号的变分模态分解与降噪研究[J]. 电子技术应用, 2020, 46(12): 103-106, 110.

[8] 蒋华伟, 张磊, 周同星. 基于信息熵的小麦储藏品质多指标权重模型研究[J]. 中国粮油学报, 2020, 35(6): 105-113.

[9] 姜淑娟, 张旭, 王荣存, 等. 基于路径分析和信息熵的错误定位方法[J]. 软件学报, 2021, 32(7): 2166-2182.

[10] 袁庆军, 王安, 王永娟, 等. 基于流形学习能量数据预处理模板攻击优化方法[J]. 电子与信息学报, 2020, 42(8): 1853-1861.

[11] 宋月亭, 吴晟. 基于相似度优化和流形学习的协同过滤算法改进研究[J]. 计算机工程与科学, 2020, 42(2): 351-357.

[12] 刘金, 宋红军. 基于二次约束二次规划的窗函数设计方法[J]. 西安科技大学学报, 2020, 40(3): 458-463.

[13] 程志友, 刘荡荡, 吴吉, 等. 基于集对分析与可变模糊集的电能质量综合评估[J]. 电网技术, 2020, 44(5): 1950-1956.

[14] 顾兆军, 彭辉. 基于模糊集和熵的工控系统灰色风险评估模型[J]. 计算机工程与设计, 2020, 41(2): 339-345.

[15] 陈东宁, 魏星, 姚成玉, 等. 连续时间 T-S 动态故障树重要度分析方法[J]. 仪器仪表学报, 2020, 41(9): 232-241.