

DOI: 10.13382/j.jemi.B2104746

面向边缘计算的机械装备状态监测系统研究*

杨 琪 刘 畅 杨建维 徐其通
(昆明理工大学机电工程学院 昆明 650504)

摘 要:针对云计算框架的机械装备状态监测系统存在数据传输时延长、预警和诊断的实时性差等问题,提出一种面向边缘计算的机械装备状态监测系统,具有设备层、边缘层和云层3层架构。高实时性的计算任务部署在多个边缘计算节点,在边缘层进行数据的特征提取、降维处理、智能诊断、数据保存与上传。所提方法在高速机床主轴试验台进行验证,实验结果表明,基于边缘计算的状态监测系统比基于云计算的状态监测系统减少29.5%的输出时延,并节省了81.3%的云层储存空间,在保证较高诊断率的情况下,显著提高了系统实时性。

关键词:机械装备;云计算;边缘计算;状态监测;智能诊断

中图分类号: TN06;TP277 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on mechanical equipment condition monitoring system for edge computing

Yang Qi Liu Chang Yang Jianwei Xu Qitong

(Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650504, China)

Abstract: There exist some problems in the mechanical equipment condition monitoring system based on cloud computing framework. The problems of the extension of data transmission, poor real-time performance of early warning and diagnosis etc. Usually occur in practical application. This paper presents a mechanical equipment condition monitoring system for edge computing, which has three-tier architecture: Equipment layer, edge layer and cloud layer. High real-time computing tasks are deployed in multiple edge computing nodes, and data feature extraction, dimensionality reduction, intelligent diagnosis, data saving and uploading are carried out in the edge layer. The proposed method is verified on the spindle test-bed of high-speed machine tool. The experimental results show that the condition monitoring system based on edge computing reduces the output delay by 29.5% compared with the condition monitoring system based on cloud computing, saves 81.3% cloud storage space, and significantly improves the real-time performance of the system under the condition of ensuring a high diagnosis rate.

Keywords: mechanical equipment; cloud computing; edge computing; status detection; intelligent diagnosis

0 引 言

在机械领域,风力发电设备、航空发动机、高档数控机床等关键机械装备的安全可靠运行举足轻重,状态监测系统对大型机械装备运行维护和安全生产具有重大意义^[1]。由于需要监测的装备群规模大、测点多、采样频率高、采集周期长,从而获得了海量数据,推动故障诊断领域进入“大数据”时代^[2]。目前的状态监测系统主要采

用云计算集中调度和管控的方式,云端集中处理机械装备的工况数据和计算请求,分析和显示监测设备的健康状况。刘欢等^[3]和蔡春雨等^[4]先后搭建了私有云平台,采集电机和泵送系统工况数据后上传至云端,利用大数据、人工智能等技术在云服务器上建立监测装备的状态评估模型,实现对装备的状态监测^[5]。随着物联网的快速发展,以云计算架构为核心的在线监测系统面临数据暴涨的问题,系统运行时受云服务器的计算能力、储存容量、网络宽带等限制,实时性较差。边缘计算的提出,为

解决以云计算为核心的机械装备状态监测系统实时性差的问题提供思路^[6]。

边缘计算的理念是靠近数据的源头进行计算^[7],将部分数据在网络边缘进行处理会更有效率,意味着计算发生在网络边缘。目前边缘计算已经广泛应用于制造业、智能交通、智慧工厂^[8],江翼等^[9]提出了一种面向边云协同的变电装备多状态量监测系统框架,在边缘端进行数据处理并基于随机森林算法对的变电设备状态进行评价。丁恩杰等^[10]设计了边缘计算网关,在网络边缘感知信息预处理、在线诊断和实时反馈机制,实现了对监测机械设备状态的智能感知与故障诊断。张文龙等^[11]在云端进行一维卷积神经网络诊断模型训练,通过迁移方式部署到边缘端,用于轴承故障的实时诊断。王延之等^[12]运用传感器网络实时采集船舶轴系关键部位的状态数据,在云计算层进行机器学习、深度学习算法模型训练,实现对船舶轴系的状态监测与寿命预测。

上述基于边缘计算架构的机械装备状态监测系统取得了一定成果,但仍存在如下不足:1)不同的机械部件,对特征的敏感度不同,少量的特征值不能表征复杂系统的运行状态,影响后续诊断模型的准确率;2)在实际生产中,采集的数据多数是健康数据,使得云层数据质量不高,占用云层数据库内存;3)边缘层部署的模型不具备新颖值检测能力,意味着不能及时发现数据新模式(渐变故障)或突发性数据(突发故障)。针对以上问题本文提出

了面向边缘计算的状态监测系统框架和边缘计算节点功能架构。首先提取多个特征值进行降维处理,引入故障诊断模型和新颖值检测模型,进行新颖值检测和故障诊断。其次,在边缘层建立数据筛选、传输和本地保存机制。最后,云层进行故障诊断模型和新颖值检测模型的训练,下发到边缘层,完成故障诊断模型的迭代,实现机械装备的实时状态监测。

1 面向边缘计算的机械装备状态监测系统框架

整体框架结构基于边云协同思想构建。云层的优势在:1)具有强大的计算资源,可以进行复杂运算,比如故障诊断和新颖值检测的模型训练;2)储存资源能力强,可以存放海量数据。但系统实时性较差。边缘层的优势在:1)实时性响应快速,贴近数据产生的源头,减少中间传输的过程,在边缘层进行数据处理、故障诊断等应用,系统响应更快,工业现场能及时得到反馈,出现故障时边缘层及时预警;2)服务对象单一,边缘计算是分布式架构,处理的数据不是云层聚合后的数据,在数据计算量和存储上都有优势。本文结合云层和边缘层优缺点分析,设计了整体框架,该框架由3层组成:云层、边缘层、设备层,如图1所示。




图1 面向边缘计算的状态监测系统框架

Fig. 1 Framework of condition monitoring system for surface edge calculation

1.1 设备层

在面向边缘计算的装备监测系统中,设备层由多种工业传感器组成。主要负责机械装备的多物理量数据同步采集,包括振动类型数据(加速度、速度、位移等信号)和非振动类型数据(电压、电流、温度等信号),最后发送到边缘层。在工业现场,收集的数据在大多数情况下是无标签的(不同的环境、操作条件、故障模式),采集信号类型多为振动信号数据,采样频率高,不能连续采集,通常是间歇性采集或者工况触发模式采集。

1.2 边缘层

边缘层是边缘计算框架的核心,主要载体为嵌入式控制系统,由众多边缘节点组成。集成数据处理、故障诊断、预警、数据储存和上传等应用。能有效减少传输时延,提高响应速度。

在面向边缘计算的机械装备多物理量状态监测系统中,边缘层实时接收设备层上传的数据后首先进行预处理,处理后的数据进行多个特征值提取,并进行降维处理,再送入部署到边缘层的故障诊断模型,进行故障识别,同时引入新颖值检测模型,检测数据点是否为异常点或者数据新模式。各边缘计算节点的输出数据通过建立的数据筛选机制传输到云层,用于云层故障诊断模型的更新。同时按照建立的保存策略将原始数据保存在边缘数据缓存区,等待云层访问。

在边缘层的层次上,没有信息聚合,只显示了机器每个部件的数据处理和实时分析结果,以便使用机器的用户可以轻松识别故障位置,并在必要时进行干预以恢复正常功能。

1.3 云层

云层主要载体为服务器或云平台,依托强大的计算能力,进行大数据分析、人工智能学习算法的训练、设备管理、历史数据管理和实时显示等任务。提供更高级的数字化、信息化、智能化应用。云层与边缘层互联互通,协调边缘计算节点的工作任务。

在面向边缘计算的装备状态监测系统中,云层结合设备端的传感器通道,配置多通道多物理量的采集任务(采样信号类型、采样频率、采样时间、阈值大小、测点备注),以 xml 格式通过通信协议下发到边缘层,控制边缘嵌入式系统的采集任务的启停。采集开始后,云层实时接收边缘层各计算节点的输出结果,包括每个部件的特征集、诊断标签等状态数据,保存在云层数据库。云层利用机器学习、深度学习等人工智能算法,对上传的状态数据进行实时显示、深度分析、故障诊断模型和新颖值检测模型的重训练,将训练好的模型以 Json 格式下发到边缘层完成模型迭代,其结果将用于实时预测边缘层的健康状态。

2 边缘层计算节点功能架构

按照目前机械装备的状态监测系统应用,结合边缘计算框架,提出一种适用于机械装备监测系统的边缘计算节点功能架构,如图 2 所示。




图 2 边缘计算功能架构

Fig. 2 Edge computing function architecture

2.1 基于 PCA 降维的数据融合方法

从机械装备采集的原始数据不能直接反映机械的健康状况,因此需要进行信号分析或特征提取^[13],由于不同机械装备的不同部件对特征值的敏感度不同,所以需要提取多个特征值进行评价。其中部分数学表达式如表 1 所示。

从原始信号中提取的大量特征指标,需要降维技术来减少特征集的变量数量。主成分分析广泛应用数据的降维处理,其本质是通过线性变换将高维数据变换为低维的线性无关的表示^[14],提取数据的主要特征分量来代替原始数据。本文中提取的多个特征指标构建的训练集采用 PCA 降维处理,其步骤如下:

1) 构造原始特征数据矩阵 X ,假设 X 矩阵已经经过归一化处理,按照式(1)计算协方差矩阵。

$$C = \frac{X^T X}{m} \quad (1)$$

2) 对协方差矩阵 C 特征值分解可得:

$$C = v \lambda v^T \quad (2)$$

式中: v 为特征向量矩阵,矩阵 λ 特征值 $\lambda_1, \lambda_2, \dots, \lambda_n$, 对应的特征向量 $v_1, v_2, \dots, v_n$, 特征向量 v_i 称为原始矩阵 X 的第 i 个主成分, λ_i 特征值为各阶主成分的方差,将 $\lambda_1 \sim \lambda_n$ 按照降序排序, λ_i 越大,表示第 i 主成分包含的信息量更多。

3) 确定主成分个数,采用累积方差贡献率来判断主成分个数:

$$\sum_{i=1}^m \lambda_i / \sum_{j=1}^n \lambda_j \geq k \quad (3)$$

式中: m 是主成分个数, k 是阈值,一般选择贡献率大于 85%,则选择前 m 个主成分代替原特征矩,减少诊断模型

表 1 特征值计算公式
Table 1 Feature extraction calculation formula

时域特征	公式	频域特征	公式
标准差 (σ_x)	$\sqrt{\frac{\sum_{n=1}^N (x(n) - p_1)^2}{N - 1}}$	重心频率 (FC)	$\frac{\int_0^\infty fS(f) \, df}{\int_0^\infty S(f) \, df}$
有效值 (x_{rms})	$\sqrt{\frac{\sum_{i=1}^N X_i^2}{N}}$	均方频率 (MSF)	$\frac{\int_0^\infty f^2 S(f) \, df}{\int_0^\infty S(f) \, df}$
偏度系数 (S)	$\frac{\frac{1}{n} \cdot \sum_{i=1}^n (x_i - \bar{X})^3}{X_{rms}^3}$	均方根频率 ($RMSF$)	$\sqrt{\frac{\int_0^\infty f^2 S(f) \, df}{\int_0^\infty S(f) \, df}}$
峭度因子 (K)	$\frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{x_{rms}^4}$	频率方差 (VF)	$\frac{\int_0^\infty (f - FC)^2 S(f) \, df}{\int_0^\infty S(f) \, df}$
峰值因子 (C)	$\frac{X_p}{X_{rms}}$	频率标准差 (RVF)	$\sqrt{VF}$
波形因子 (W)	$\frac{X_{rms}}{X_{ma}}$		
脉冲因子 (I)	$\frac{\max(x_i)}{\bar{X}}$		
裕度因子 (L)	$\frac{\max(x_i)}{X_r}$		

2.2 基于 SVM 多分类的故障诊断节点

PCA 降维后,边缘层进行故障诊断。支持向量机 (SVM)适用于滚动轴承、电机、转子系统,在机械装备故障诊断领域已有广泛的应用,因此选用 SVM 算法对机械装备状态评估具有可行性^[15-16]。SVM 是健康状态识别中广泛使用的机器学习算法,基本思想就是通过核函数将低维度的线性不可分的空间映射到高维度特征空间,在特征空间中寻找一个几何间隔最大的分类面,将两类样本分开。SVM 数学模型如下:

对于两类线性可分样本集 $T = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$,其中 $x \in R^n, y = [-1, 1]$,考虑干扰因素,构造松弛变量 ξ 和惩罚系数 C ,则最优分类面转换为求解凸二次规划问题最优问题求解:

$$\begin{cases} y_i(\mathbf{w}^T x_i + b) \geq 1 - \xi_i, i = 1, \dots, n, \\ \xi_i \geq 0, i = 1, \dots, n, \end{cases} \quad (4)$$

式中: $\mathbf{w}$ 是 n 维空间向量, b 为偏置常数,在式(4)约束下求解下式最小值:

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (5)$$

对于不等约束问题,采用采用 Lagrange 方法对偶求解,构造 Lagrange 函数:

$$L(\mathbf{w}, b, a) = \frac{1}{2} \|\mathbf{w}\|^2 - \sum_{i=1}^n (\mathbf{w} \cdot x_i + b) + \sum_{i=1}^n a_i \quad (6)$$

求解 Lagrange 函数最小值,对 $\mathbf{w}$ 和 b 求偏导后得到:

$$\mathbf{w} = \sum_{i=1}^n a_i y_i x_i \quad \sum_{i=1}^n a_i y_i = 7 \quad (7)$$

将式(7)带回 Lagrange 函数中得:

$$L(a) = \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n a_i a_j y_i y_j \cdot x_j \quad (8)$$

至此,建立两类的最优分类面决策函数:

$$f(x) = \text{sign}\left(\sum_{i,j=1}^n \alpha_i y_i (x_i x_j) + b\right) \quad (9)$$

再由此推广到非线性的情况,用非线性向量维输入向量 $\phi(x) = (\phi_1(x), \dots, \phi_l(x))$,将分类数据映射到高维特征空间,使其线性可分。对应的最优分类面决策函数为:

$$f(x) = \text{sign}\left(\sum_{i,j=1}^n \alpha_i y_i (\phi^T(x_i) \cdot \phi(x_j)) + b\right) \quad (10)$$

通过引入核函数 $K(x_i \cdot x)$ 代替上式高维特征空间的复杂运算。最后的最优分类面决策函数为:

$$f(x) = \text{sign}\left(\sum_{new} y_i \alpha_i^* K(x_i \cdot x) + b^*\right) \quad (11)$$

本文研究对象为机械装备所表现出的多种故障类

型,需要提取多个故障类型构建 k 类故障训练集。对于 k 分类问题,采用“一对一”^[17]分类方法,对第 i 和 j 使用 SVM 二分类算法进行学习。即满足式(12)约束:

$$\begin{cases} (\mathbf{w}^{ij})^T \phi(x_i) + b^{ij} \geq 1 - \xi_i^{ij}, & y_i = i \\ (\mathbf{w}^{ij})^T \phi(x_i) + b^{ij} \leq -1 + \xi_i^{ij}, & y_i = j \\ \xi_i^{ij} \geq 0 \end{cases} \quad (12)$$

求解函数最小值:

$$\frac{1}{2} \|\mathbf{w}\|^2 + C \sum_i \xi_i^{ij} (\mathbf{w}^{ij})^T \quad (13)$$

和 SVM 二分类算法一样,构造 Lagrange 函数,对 $\mathbf{w}$ 和 b 求偏导解最小值后带回 Lagrange 函数建立最优面决策函数。

$$f(x) = \text{sign}((\mathbf{w}^{ij})^T \phi(x) + b^{ij}) \quad (14)$$

对于测试样本的多分类采用“投票法”,依次将测试样本输入到分类器中,带入上式计算,输入判定结果为 i 类,则 i 类加一票,反之 j 加一票。将 $k(k-1)/2$ 分类器对测试集进行判定后, k 分类中那一类得票数越多,则判定为那个故障类别。

2.3 基于 SVDD 的新颖值检测节点

由于 SVM 分类算法是监督学习,是针对有多个故障标签的数据进行学习,机械装备的新获得的数据作为测试样本,通过训练好的诊断模型预测的故障结果总会和诊断模型中的某一个故障标签相关联,在这种情况下,无法在边缘层识别出数据新模式或突发异常数据,不能及时的发现异常工况数据或产生误判。提出基于支持向量机描述 (SVDD) 算法,能有效区别正常状态数据和异常状态数据,很好地应用于机器故障新模式或突发故障检测当中^[18-19]。

SVDD 其本质和 SVM 类似,不同的是 SVDD 在特征空间中寻找一个尽可能全部包围训练样本且体积最小的超球体而非超平面。其数学模型如下:

设一个样本集 $X = \{x_1, x_2, \dots, x_n\}$, 在特征空间中定义一个超球体,球心 a 和对应的超球体半径 R , 和二分类 SVM 一样,构造惩罚系数 C 的松弛变量 ξ_i , 转换为求解凸二次规划问题最优问题求解,满足下式:

$$\begin{cases} \| \phi(x_i) - a \|^2 \leq R^2 + \xi_i, & i = 1, 2, \dots, m \\ \xi_i \geq 0, & i = 1, 2, \dots, n \end{cases} \quad (15)$$

求解最小值:

$$R^2 + C \sum_{i=1}^n \xi_i \quad (16)$$

后续求解方法和 SVM 类似,构造 Lagrange 函数后对 R, a, ξ_i 求偏导后引入核函数得到:

$$L = \sum_i \alpha_i K(x_i, x_i) - \sum_{i,j} \alpha_i \alpha_j K(x_i, x_j) \quad (17)$$

解上式 α_i 最优解,其中 $0 < \alpha_i < C$ 的对象称为支持向量。任意支持向量 x 到中心 a 的距离就是映射空间 ϕ

中超球体的半径 R , 则球体半径 R^2 为:

$$R^2 = K(\mathbf{x} \cdot \mathbf{x}) - 2 \sum_i a_i K(\mathbf{x} \cdot x_i) + \sum_{i,j} a_i a_j K(x_i \cdot x_j) \quad (18)$$

如果新数据点 z 到中心 a 的距离为球体半径 R , 则半径的平方为:

$$f(z) = K(z \cdot z) - 2 \sum_i a_i K(z \cdot x_i) + \sum_{i,j} a_i a_j K(x_i \cdot x_j) \quad (19)$$

根据公式 $R^2 - f(z)$ 计算差值,判断新数据 z 为正常点还是为异常点,如果差值大于 0,表示落在球体内,为正常点;如果小于 0,则表示新数据点落在球体外,为新颖值。新颖值检测算法旨在检测未知故障和突发异常。

2.4 三重数据判定机制

在面向边缘计算的机械装备监测系统中,由于采样频率高,测点多,一个通道采集一次的数据量为 400 KB,多个通道的同时传输极大的占用网络带宽,使传输时延变长,占用云层存储负荷。针对这个问题,建立三重数据判定机制,流程图如图 3 所示。

边缘层获取原始数据后进行特征提取后,进入边缘层三重判定机制。

1) 阈值报警节点,数据的某个特征值大小大于等于设置的阈值时,节点判定为异常;

2) 新颖值检测节点,数据被新颖值检测模型判断为非健康数据,该数据可作为数据新模式或突发异常点,节点判定为异常;

3) 故障诊断节点,数据被故障诊断模型判断为非健康数据,节点判定为异常。

上述的 3 个判断节点,作为原始数据上传的条件,如果 3 个判定节点都是 N(无异常、无阈值报警、无故障等判定结果),可将该点作为正常数据,原始数据不上传到云层;如三重判定至少有一个被判定为 Y,则认为该点为阈值超限、新模式或明确故障,上传该时刻的原始波形到云层,进行深度分析,如果分析结果为故障,则打上标签添加到故障诊断模型的训练集,用于模型的重训练,再下发到边缘层完成模型迭代。需要注意的是,大部分时间获取的数据是健康的数据,这类健康数据将暂时保存在边缘装备的数据缓冲区内,云层可随时下载边缘缓冲区的数据。同时边缘层实时上传提取的特征集和诊断结果标签并保存,在云层可了解机械装备的健康状态。减小数据传输量的同时,以尽可能少的数据去评价装备的状态情况。

3 系统应用验证

为验证系统,按照图 1 的框架和图 2 的节点功能架构搭建了边缘计算的机械装备状态监测系统,并用边缘




图 3 三重判定机制

Fig. 3 Triple decision mechanism

计算框架和云计算框架方案进行对比实验。首先,评估边缘计算的状态监测系统在机械装备状态检测的新颖值检测和故障诊断能力,其次对比云框架下监测系统执行数据传输延时和数据传输到故障诊断结果输出的总延迟时间。最后比较两个方案中云层数据库的内存总量。

3.1 实验平台及方案

利用高速机床主轴试验台作为实验平台,进行系统相关边缘计算节点验证。该平台由机械主轴为主要监测对象,PCB 35A15 型加速度三轴传感器和 IEPE 型加速度传感器分别放置在主轴、电机端,同时进行 4 个通道的数据采集,量程为 50 Gpk。选择一张四通道的 NI 9234 采集卡,最大采样频率为 51.2 kS/s,插在 NI cRIO 9038 机箱插槽上。高速机床主轴试验台如图 4 所示。

边缘计算系统的搭建选用 NI-cRIO 9038 控制器作为边缘控制器,处理器内核 1.30 GHz Dual Core Intel Atom,搭载 Kintex-7 系列的 Xilinx FPGA。控制器包括两部分,LabVIEW FPGA(设备层)和 LabVIEW RT(边缘层)。选用笔记本电脑,搭载运行内存 1 G 和单核 CPU 作为云服务器,其中云服务器中集成了和边缘层的主要计算节点。测试实验中,按照图 5 的方案,分别计算采集卡从单通道




图 4 高数机床主轴实验台

Fig. 4 High number machine tool spindle test bench

上传到 4 个通道数据上传的传输时延、4 个通道数据从传输到故障诊断结果输出总时延,总时延即表示维修指令的反馈时间。测试实验取 20 组数据的平均值作为结果,进行对比实验。云计算框架和边缘计算框架数据传输和计算节点总时延对比方案如图 5 所示。

在对比方案测试之前,先采集少量机械主轴的 4 个工况数据,提取特征构建训练集。健康数据的训练集作为唯一正样本用于新颖值检测模型训练;4 种工况数据构建的训练集用于故障诊断模型训练,每个工况 250 组,训练好的模型下发到边缘层。测试时,机械主轴按照表 1 的测试集依次更换 4 种工况,每个工况采集 80 组数据,




图 5 边缘计算框架和云框架对比实验方案

Fig. 5 Comparative experimental scheme of edge computing framework and cloud framework

每组数据采样间隔 3 s,采样点数为 51 200。电机正常工况采集,采样间隔和采样点数配置和机械主轴一致。三轴传感器和 IEPE 加速度传感器分别采集机械主轴和电机的工况数据。机床主轴训练集和测试集描述如表 2 所示。

表 2 数据集描述

Table 2 Dataset description


样本类型	采样点数	训练集样本	测试集样本	标记
正常	51 200	250	80	0
内圈故障	51 200	250	80	1
外圈故障	51 200	250	80	2
滚动体故障	51 200	250	80	3

3.2 实验结果与分析

首先,NI cRIO 9038 边缘设备按照表 1 方案,依次获取 4 种工况下的数据作为测试集,由于选用的三轴传感器,在三轴传感器 Z 轴的振动最为明显,选择 Z 轴方向的通道对系统边缘层中的两种模型进行测试,图 6 所示是在边缘层对 Z 轴方向通道的新颖值检测结果和故障分类结果。


从图 6(a)中可以看出,前 80 组数据幅值 ≥ 0 ,为正常样本,表示为健康数据,后 80 组 < 0 ,为负样本,表示为异常点或新模式,检测结果和实际相符;对于故障诊断模型的输出结果,从图 6(b)可以看出,4 种已知工况共计 320 组数据预测结果和标签重合率较高,误判集中在内圈和外圈,经过多次测试诊断,准确率在 96%左右。训练集样本越多,诊断率越高。

图 7 所示为数据传输和边缘计算节点总时延。多通道的数据传输时延测试由图 7(a)可知,边缘计算框架中 LabVIEW FPGA(设备层)到 LabVIEW RT(边缘层)数据传输时延明显低于 LabVIEW FPGA 到云服务器的传输时延,且随通道数量越多,数据传输时延会越长;图 7(b)为 4 个通道数据从数据传输到各计算节点输出总时延,由于云服务器和边缘层的硬件性能相当,各个计算节点的



(a) 新颖值检测

(a) Novel value detection



(b) 故障分类结果

(b) Fault classification results

图 6 新颖值检测节点结果诊断节点结果

Fig. 6 Novel value detection node and diagnosis node results

输出时延没有明显差异,但云服务器的数据传输时延导致总时延越长。在四通道数据传输实验中,边缘计算框架比云计算框架在总输出时延上减少了 43.3%的传输时延;在总延时的对比上,边缘计算框架比云计算框架减少了 29.5%的时延,但随着通道数量越多,边缘计算框架优势会更加明显。据项目经验,中小型系统的通道数量在

70 左右,多个边缘设备构成分布式架构,意味着边缘计算框架会比云计算框架的输出时延更少。该实验测试证明边缘计算框架下的机械装备在线监测系统具有低延时、高响应的优势。




图7 数据传输和计算节点总时延

Fig. 7 Total delay of data transmission and computing nodes

最后从云层服务器储存数据量的角度来看,在边缘层的数据只有满足条件(故障、新模式、阈值超限),原始信号才会传输到云层,否则只上传特征集和故障诊断标签。云层的数据存储容量如表3所示。

表3 云服务器储存容量

Table 3 ECS storage capacity

系统框架	储存的原始信号(M)	储存的特征矩阵(M)	总存储空间(M)
边缘计算	95.6	0.31	95.91
云计算	512	0	512
节约率/%	-	-	81.3

由表3可以看出,基于边缘计算框架的状态监测系统节约了81.3%的储存空间,当装备状态健康时,只上传特征集和故障标签,4个通道只需要310 KB的容量,而在实际生产中,获取的数据大部分都是健康数据,通过面向边缘计算的机械装备状态监测系统,能大幅减少上传数据,有效减小系统数据传输延时,减轻云层计储存负荷,提高系统的实时性。测点越多、采样频率越高的监测对象,优势更加明显。

4 结论

针对云计算框架下的机械装备状态监测系统实时性差的问题,提出面向边缘计算的机械装备状态监测系统框架。在边缘层进行数据的特征提取、降维处理、智能诊断、数据保存与上传。最后结合实际案例对面向边缘计算的机械装备状态监测系统进行评估,结果表明,本文提出的方案相对于云计算框架方案能明显减小数据传输延时和云层存储负荷,显著提高状态监测系统的实时性。对实现机械大数据的的实时边缘感知,提升生产制造的智能化有重要意义。

参考文献

[1] 国家自然科学基金委员会工程与材料科学部. 机械工程学科发展战略报告[M]. 北京: 科学出版社, 2010.
Department of Engineering and Materials Science, National Natural Science Foundation of China. Development Strategy Report of Mechanical Engineering [M]. Beijing: Science Press, 2010.

[2] 雷亚国, 贾峰, 孔德同, 等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Y G, JIA F, KONG D T, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54 (5): 94-104.

[3] 刘欢, 毕道伟, 刘嘉熙, 等. 基于云平台的核电设备监测诊断架构设计与实现[J]. 制造业自动化, 2021, 43(1): 68-73.
LIU H, BI D W, LIU J X, et al. Design and implementation of monitoring and diagnosis architecture for nuclear power equipment on cloud platform [J]. Manufacturing Automation, 2021, 43 (1): 68-73.

[4] 蔡春雨, 陈志刚, 钟新容, 等. 基于云平台的压裂车泵送系统监测设计与实现[J]. 国外电子测量技术, 2021, 40(10): 145-150.
CAI CH Y, CHEN ZH G, ZHONG X R, et al. Design and implementation of fracturing truck pumping system monitoring based on cloud platform [J]. Foreign Electronic Measurement Technology, 2021, 40 (10): 145-150.

[5] CALABRESE F, REGATTIERI A, BORTOLINI M, et al. Predictive maintenance: A novel framework for a data-driven, semi-supervised, and partially online prognostic health management application in industries [J]. Applied Sciences, 2021, 11(8): 3380.

[6] 施巍松, 孙辉, 曹杰, 等. 边缘计算:万物互联时代新型计算模型[J]. 计算机研究与发展, 2017, 54(5): 907-924.
SHI W S, SUN H, CAO J, et al. Edge computing-an

- emerging computing model for the Internet of everything era [J]. Journal of Computer Research and Development, 2017, 54(5): 907-924.
- [7] SHI W, CAO J, ZHANG Q, et al. Edge computing: vision and challenges [J]. IEEE Internet of Things Journal, 2016, 3(5): 637-646.
- [8] 李辉, 李秀华, 熊庆宇, 等. 边缘计算助力工业互联网: 架构、应用与挑战[J]. 计算机科学, 2021, 48(1): 1-10.
- LI H, LI X H, XIONG Q Y, et al. Edge computing enabling industrial internet: Architecture, applications and challenges [J]. Computer Science, 2021, 48(1): 1-10.
- [9] 江翼, 刘正阳, 王文瑞, 等. 面向边云协同的变电装备多状态量监测系统研究[J]. 电力系统保护与控制, 2021, 49(6): 138-144.
- JIANG Y, LIU ZH Y, WANG W R, et al. Research on multi-state monitoring system of substation equipment based on edge-cloud collaboration [J]. Power System Protection and Control, 2021, 49(6): 138-144.
- [10] 丁恩杰, 俞啸, 廖玉波, 等. 基于物联网的矿山机械设备状态智能感知与诊断[J]. 煤炭学报, 2020, 45(6): 2308-2319.
- DING EN J, YU X, LIAO Y B, et al. Key technology of mine equipment state perception and online diagnosis under Internet of Things [J]. Journal of Coal, 2020, 45(6): 2308-2319.
- [11] 张文龙, 胡天亮, 王艳洁, 等. 云/边缘协同的轴承故障诊断方法[J]. 计算机集成制造系统, 2020, 26(3): 589-599.
- ZHANG W L, HU T L, WANG Y J, et al. Cloud/edge collaborated bearing fault diagnosis method [J]. Computer Integrated Manufacturing Systems, 2020, 26(3): 589-599.
- [12] 王延之, 吴军, 陈作懿, 等. 基于边缘计算的船舶轴系智能监测技术[J]. 兵器装备工程学报, 2021, 42(8): 287-291.
- WANG Y ZH, WU J, CHEN Z Y, et al. Intelligent monitoring technology of ship shafting based on edge calculation [J]. Journal of Ordnance and Equipment Engineering, 2021, 42(8): 287-291.
- [13] LEI Y, YANG B, JIANG X, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap [J]. Mechanical Systems and Signal Processing, 2020, 138.
- [14] ABDI H, WILLIAMS L J. Principal component analysis[J]. Wiley Interdisciplinary Reviews: Computational Statistics, 2010, 2(4): 433-459.
- [15] 王一鹏, 陈学振, 李连玉. 面向小波包混合特征和支持向量机的机床主轴轴承故障诊断研究[J]. 电子测量与仪器学报, 2021, 35(2): 59-64.
- WANG Y P, CHEN X ZH, LI L Y, et al. Research on fault diagnosis of machine spindle bearing based on wavelet packet mixing feature and SVM [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 59-64.
- [16] 韩光辉, 韩守亮, 李高鹏, 等. 纯电动车用驱动电机滚动轴承状态监测方法[J]. 电子测量与仪器学报, 2021, 35(2): 130-135.
- HAN G H, HAN S L, LI G P, et al. Condition monitoring method of rolling bearing for driving motors of pure electric vehicles [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(2): 130-135.
- [17] ACHMAD WIDODO, BO-SUK YANG. Support vector machine in machine condition monitoring and fault diagnosis [J]. Mechanical Systems & Signal Processing, 2007, 21(6): 2560-2574.
- [18] SCHOILOPF B, WILLIAMSON R, SMOLA A. Support vector machines for classification and regression: Advances in neural information processing systems 12 (NIPS 1999) [C]. Denver, CO, 1999.
- [19] 王小飞, 王元鑫, 曲建岭, 等. 面向大样本飞参数据的航空发动机性能监控方法[J]. 仪器仪表学报, 2020, 41(7): 175-184.
- WANG X F, WANG Y X, QU J L, et al. An aero-engine performance monitoring method based on large scale flight data [J]. Chinese Journal of Scientific Instrument, 2020, 41(7): 175-184.

作者简介



杨琪, 2019 年于宜宾学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为设备状态监测及故障诊断系统开发。

E-mail: pkayjoy1996@163.com

Yang Qi received B. Sc. from Yibin University in 2016. Now he is a M. Sc. candidate at Kunming University of Science and Technology. His main research interests include the development of equipment condition monitoring and fault diagnosis system.



刘畅 (通信作者), 2017 年于昆明理工大学获得博士学位, 中国振动工程学会故障诊断专业委员会委员, 现为昆明理工大学高级工程师、硕士生导师, 主要研究方向为信号处理理论与方法、压缩感知与稀疏表示、机械故障诊断。

E-mail: Liuchang2019@aliyun.com

Liu Chang (Corresponding author) received Ph. D. from Kunming University of Science and Technology in 2017. He is also a member of the Fault Diagnosis Professional Committee of the Chinese Society of Vibration Engineering. Now he is a senior engineer and master supervisor of Kunming University of technology. His main research interests include signal processing theory and methods, compressed sensing and sparse representations, machinery fault diagnosis.