Centrifugal Fan Online Monitoring and Multi-Level Information Fusion Diagnostic System

WANG Zihan[1,3], XU Li[2,3]*

(1.Polytechnic Institute of Zhejiang University, Hangzhou Zhejiang 310015, China; 2.College of Electrical Engineering, Zhejiang University, Hangzhou Zhejiang 310027, China; 3.Zhejiang University Robotics Institute, Ningbo Zhejiang 315499, China)

Abstract: There has been notable attention towards effectively monitoring and diagnosing the operational status of centrifugal fan recently. To address problems such as the susceptibility of fan data under actual working scenarios with environmental noise and the limitation of traditional model in extracting fault information, a centrifugal fan online monitoring and multi-level information fusion diagnostic system is proposed. The system's architecture involves a monitoring network composed of PLC and sensors, which enables the reading, recording, and visualization of various parameters in real time. A one-dimensional bilinear-CNN approach based on multi-level information fusion is employed to combine data and features for analyzing the fan's operational status. The accuracy of the result obtained is verified to be 99.09% which is higher than those of comparative methods. Thus, the system provides a feasible solution for monitoring and diagnosing centrifugal fan.

Key words: fault diagnosis; centrifugal fan; on line monitoring; information fusion; bilinear pooling; convolutional neural network

EEACC: 7230; 7220 **doi**: 10.3969/j.issn.1004-1699.2025.10.023

离心风机在线监测与多层次信息融合诊断系统

王子涵[1,3], 许 力[2,3]*

(1.浙江大学工程师学院, 浙江 杭州 310015; 2.浙江大学电气工程学院, 浙江 杭州 310027; 3.浙江大学机器人研究院, 浙江 宁波 315499)

摘 要: 离心风机运行状态的有效监测和故障诊断备受关注, 为解决实际工况下风机数据可靠性易受环境噪声干扰、传统网络模型故障信息挖掘不足等问题, 建立一种离心风机在线监测与多层次信息融合诊断系统。系统采用 PLC 与传感器组成的监测网络, 实时读取、记录及可视化各类数据, 基于多层次信息融合的一维 Bilinear-CNN 方法融合数据信息及特征, 分析风机运行状态。实验验证准确率为 99.09%, 与对比方法相比辨识准确性更高, 为离心风机状态监测和故障诊断提供有效解决方案。

关键词: 故障诊断; 离心风机; 在线监测; 信息融合; 双线性池化; 卷积神经网络

中图分类号: TH17; TH133.3 **文献标识码**: A **文章编号**: 1004-1699(2025)10-1898-08

离心风机是工业界常用的旋转设备, 通常在复杂、多变的工况下运行, 容易发生各类故障, 导致设备停运或损坏, 非计划停机会产生很大的经济负担[1], 为尽可能减少经济损失, 需要及时进行检修。因此, 在线监测离心风机运行状态, 诊断离心风机数据具有重要的现实意义。

离心风机车间通常有大量同时运行的设备需要监测。尽管已有诸多研究讨论了不同类型传感器的选择和分析[2], 但通常为单台风机的监测设备设计, 对组网风机传感设备的探讨较为有限。为了在复杂车间工况下部署大量监测节点, 构建监控网络, 本文选择了可编程逻辑控制器(PLC)作为解决方案, PLC 是工业界常用的控制器和组网设备, 其稳定性、可靠性以及对于复杂操作环境的适应性使其成为理想的选择, 能有效管理多个节点并实现高效数据交换。

当前离心风机故障诊断方法主要围绕单组振动传感器进行分析, 利用振动信号编码特征图[3]、特征频率[4]等进行诊断, 然而, 现场测量易受环境噪声干扰, 影响实验数据的准确性, 对特征图或频率识别造成噪声干扰, 仅依赖单组传感器难以确保数据的合理可靠。

故研究将重心转到多种传感器监测, 如振动、温度和电流传感器等, 鉴于监测信号的多样性和复杂

收稿日期: 2023-09-14 **修改日期**: 2023-12-19

性,本文采用多传感器信息融合方法解决该问题,以提高系统的容错率。多源信息融合通常分为数据层、特征层和决策层[5]。在数据层,朱丹宸等[6]提出将滚动轴承的多组一维振动信号转为二维灰度图,通过卷积神经网络(Convolutional Neural Network,CNN)处理结果,Xia 等[7]同样采用 CNN,结合不同位置振动信号处理结果;在特征层,田亮等[8]利用证据理论融合风机 Y 向振动状态真值与预测值的均方根误差诊断结果,张友等[9]提出自适应学习风机复杂高维数据特征的深度 CNN 网络;在决策层,Bigdeli 等[10]运用 RBF 核支持向量机(SVM)分别进行高光谱和激光雷达数据故障分类,利用朴素贝叶斯融合两者分类结果。调研发现,在异源数据分析上,多采用拼接等简单融合方法,缺乏不同位置、时空特征的深入挖掘,损失关联数据特征。在数据驱动分类上,传统方法如支持向量机、随机森林等,依赖人工提取特征的准确合理性,对比深度学习自动提取特征的特点,损失的部分信息无法得到有效利用。

目前多源数据处理主要集中在单层次融合,即对某层数据融合并直接输出结果[11],在多层融合方面,如:蔺万科等[12]提出最优聚类中心和权重欧氏距离的数据融合方法,并通过 Softmax 层进行决策融合,结果表明当选用合适的方法时多层融合更具准确性。

基于上述分析,本文提出了一种离心风机在线监测与多层次信息融合诊断系统,基于 PLC 采集温度与振动信息并对数据进行初步分析,结合 LabVIEW 设计上位机人机交互界面,以可视化展示离心风机的运行状态,实现风机组网监测、数据存储、设备管理等,有利于设备动态监测和质量监控。同时本文采用多层次信息融合方法,结合双线性卷积神经网络(Bilinear-CNN)进行离心风机的故障诊断,在数据层自适应加权融合同源传感器数据,在特征层提取并融合异源传感器特征,根据融合结果输出状态分类,实现离心风机的故障诊断。

1　系统总体设计

本系统硬件分为三部分:上位机端、PLC 控制端及传感器端。传感器端由多组基础传感器组成,包括两组相同参数的热电阻、温度变送器和振动传感器。PLC 为 S7-200ETH 版本,用于控制数据回路通断、初步分析及构建传感器网络。使用 LabVIEW 制作上位机端人机交互界面,通过 TCP/IP 协议查看 PLC 采集的传感数据、设备状况,并上传云端实现远程监控。

故障诊断方面,在数据层及特征层融合风机前后端温度、振动传感器数据,得到正常状态及四种故障状态的判断结果,故障状态为轴承损坏、叶轮不平衡、轴承异物、润滑油不足。经过数据预处理后,利用贝塞尔公式计算同源传感器数据的不确定度,作为融合权重指标,进行自适应权重融合并输入并行卷积池化层,分别提取数据特征,利用双线性池化层融合异源特征,挖掘关联信息,融合结果作为全连接层的输入,最终模型输出离心风机不同状态的判断结果。

2　数据采集与可视化

本系统的数据采集与可视化功能通过硬件部分体现,该部分涵盖四个方面,即通过 PLC 控制端构建传感器网络、进行数据初步分析、控制传感器回路的通断以及上位机端人机交互系统。本系统采用的传感器数据传输和集中控制架构,提高了离心风机运行状态的数据可视化和远程访问性。

2.1　构建传感器网络

系统由前文提到的基础传感器及 PLC 构建的多个独立监测子系统组成,如图 1 所示,旨在完成离心风机振动、温度等运行状态的监测功能。通过 TCP/IP 通信协议构造本地传感器网络拓扑,实现 PLC 与上位机间双向数据通信,上位机数据库采用 ODBC 接口,存储并查看云端数据,远程监控离心风机运行状态。

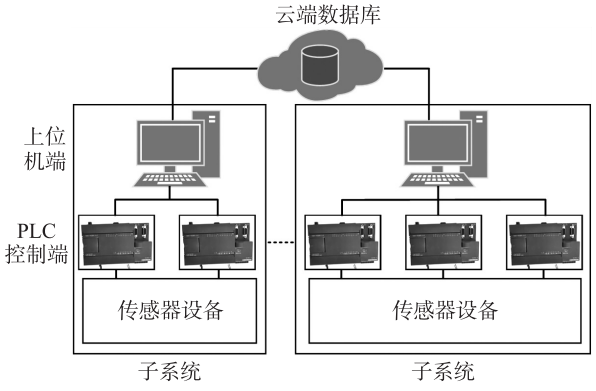

图 1　硬件网络

传感器无法直接在网络中传输数据,故依赖 PLC 进行传感器组网。PLC 通过以太网接口连接到网络,并为自身分配唯一的 IP 地址,上位机通过网络配置和 PLC 参数设置,确保 PLC 和上位机位于同一子网,保障网络可达性。使用基于 TCP/IP 的 Modbus TCP 通信协议,建立 PLC 与上位机之间稳定的通信连接,实现数据传输到上位机端进行记录和显示。

上位机端构建各个并联子系统的云端传输通道,通过人机交互界面实时显示传感器数据,同时上传数据到云端进行存储和分析,利用数据处理和分析算法进行实时监控和决策支持,远程管理并查看网络内设备状态与信息。

2.2 数据初步分析

PLC 通过逻辑编程对模拟量转数字量端(AD)采集的数据进行初步分析,分为预警、故障和正常三种状态,动态更新离心风机运行状态提示,闪烁提示灯。

记录采集数据,构成温度、振动数据数组,新数据压入数组底部,滑动更新数组信息。为区分故障与预警情况,分别记录长时数组(连续 10 个点)和短时数组(连续 4 个点),对两种数组分别进行方差、均值等数学分析,生成数组的数据特征。

设定阈值范围,当新数据超过预设上限时,PLC 锁定风机状态,如果数据符合异常状态特征且持续一定时间或次数,PLC 确认警报并生成对应信号,以及时采取必要的措施,判断程序流程如图 2 所示。通过低于阈值的时间长短,判断是否需要清除警报状态,长时间未出现警报特征,恢复或保持正常状态,并相应地关闭警报。同时,通过数据维持在正常范围内的时间,判断是否需要清除之前的故障信息,以避免误判或冗余。

系统进行阈值及特征分析,对采集的传感器数据进行有效的初步处理和判定,快速响应异常情况,确保正常运行。

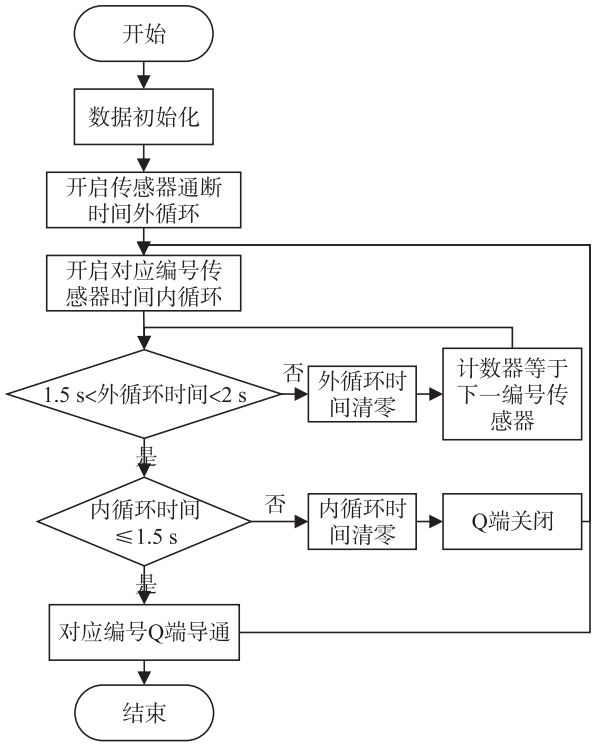

图 2 初步分析程序流程图

2.3 控制采集回路

在工业控制系统中,使用传感器来感知环境和设备状态是至关重要的,但工作车间电磁干扰及传感器之间干扰对 AD 端数据采集具有明显影响,故通过 PLC 控制输出端(Q)来决定外接传感器回路的通断,保障同一时刻仅一组传感器与 AD 端连接并构成回路,实现传感器数据的间断采集,该部分程序设计流程如图 3 所示。

通过计数器循环记录导通端口序号,该序号的增减通过外部循环完成,对应序号的端口通断通过内部循环控制,设置导通的间隔缓冲时区,避免多回路同时导通。

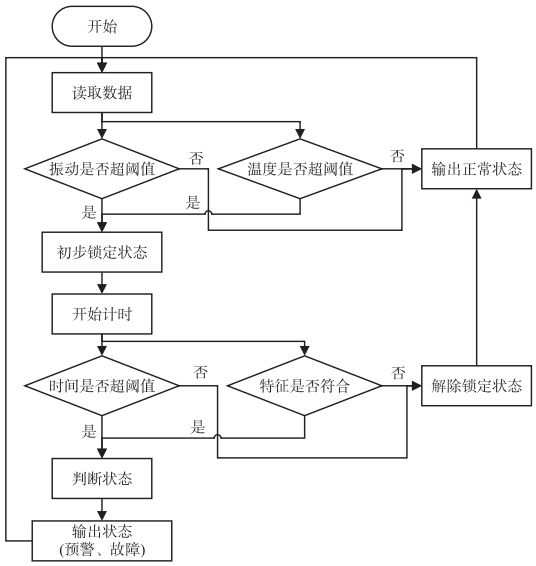

图 3 控制采集回路程序流程图

传感器与 PLC 的 Q 端、AD 端及供电电源构成数据采集回路,传感器呈并联关系,该方法便于离线风机系统的整体维护和排查。

2.4 上位机端人机交互系统

本系统的人机交互部分采用 NI 公司的 LabVIEW 软件开发完成,部分交互界面如图 4、图 5 所示。

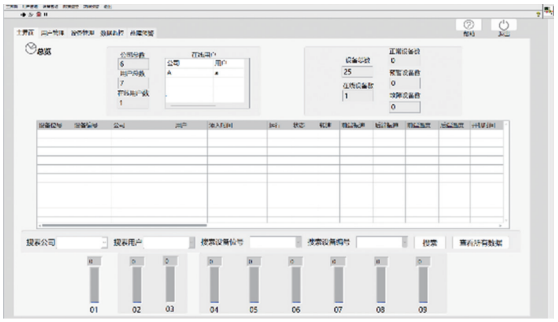

图 4 上位机交互主界面

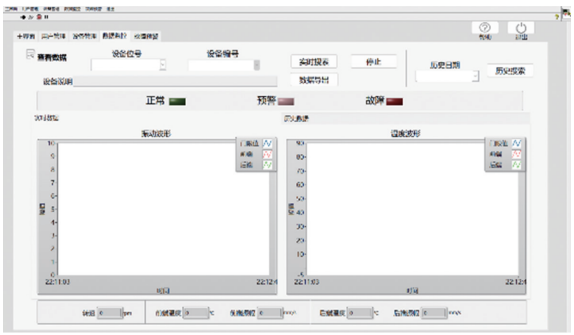

图 5　上位机交互数据监控界面

通过内置的 Modbus TCP 模块与本地 PLC 建立连接,实时读取并显示 PLC 数据,通过 ODBC 接口调用云端数据库,记录和管理设备的运行日志、报警信息、维修记录等,实现远程访问,在任何地点通过网络浏览器或移动设备监控。该系统具备可视化设备信息、管理信息、运行状态等多种功能,通过与网络内的所有风机设备建立连接,同时监控和管理多台设备,实现集中控制和维护,有效提升了设备的运行效率和安全性。

3　数据分析处理

3.1　数据层融合

3.1.1　数据清洗

在实际数据采集过程中存在开关机等非常规运行情况,数据采集精度受到影响,需要清洗数据,提高数据有效性。数据清洗前后某状态振动传感器数据如图 6 所示。

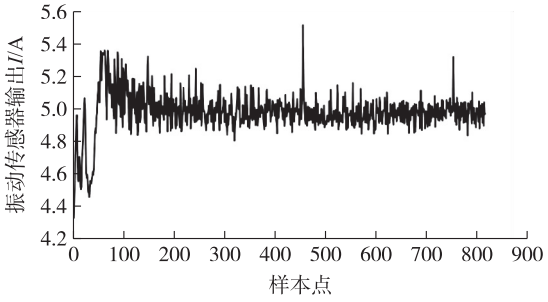

(a) 数据清洗前

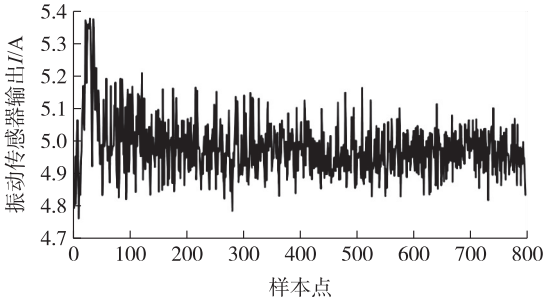

(b) 数据清洗后

图 6　数据清洗前后振动传感器数据对比

开关量清洗采用阈值限制,剔除温度传感器低于厂间室温(约 28 ℃)的数据,并同步剔除相应时段的振动传感器数据,该部分振速值约低于 0.75 mm/s。

由于温度测量过程持续温升,振动传感器相比温度传感器受环境影响更大,故仅筛选振动数据,计算清洗后振动数据方差,利用等深分箱中位数法平滑处理方差及与中位数偏差异常点,剔除后用箱型中位数替换异常量。

3.1.2　数据归一化

本文采集的两类数据量纲不统一且采集数值范围不同,故如式(1)所示进行归一化处理:

$$y_i=\frac{x_i-\min(\boldsymbol{x})}{\max(\boldsymbol{x})-\min(\boldsymbol{x})}\quad i=1,2,3\cdots n \tag{1}$$

式中:$\boldsymbol{x}$ 为未进行归一化处理的数据集,x_i 为未进行归一化处理的数据点,y_i 为完成归一化处理的数据点,$\min(\boldsymbol{x})$ 为数据集最小值,$\max(\boldsymbol{x})$ 为数据集最大值。

3.1.3　数据融合

为得到相对可靠的数据,对同一状态、不同时空同源传感器数据进行融合,数据融合常采用加权平均、机器学习等方法[13],考虑传感器的不确定度是多个同源传感器数据可靠性及数据测量质量的评判依据,不确定度越小,测量结果质量越高。故以最小化不确定度为约束指标[14],计算数据融合的加权值。

数据不确定度通过贝塞尔公式(2)得到:

$$s(x_i)=\sqrt{\frac{\sum_{j=1}^{n}(x_{ij}-\bar{x})}{n-1}}\quad i=1,2 \tag{2}$$

式中:i 的取值范围为 1 和 2,对应离心风机前端与后端两组设备,x_{ij}为第 i 组同源传感器数据的第 j 个点,$s(x_i)$ 为第 i 组同源传感器的不确定度,n 为第 i 组同源传感器数据集大小,$\bar{x}$ 为所有同源传感器数据的平均值,不同组数据均独立测量。

融合数据的不确定度为:

$$s(y)=\sqrt{\frac{\sum_{j=1}^{n}(y_j-\bar{y})}{n-1}} \tag{3}$$

$$y=\sum_{i=1}^{2}\omega_i x_i \tag{4}$$

式中:y 为同源传感器数据融合后的信息,式(4)代入式(3)经化简与极值求解,得权重计算方法为:

$$\omega_i=\left[\frac{1}{s^2(x_i)\sum 1/s^2(x_i)}\right] \tag{5}$$

经过数据融合前后温振数据分别如图 7 所示。

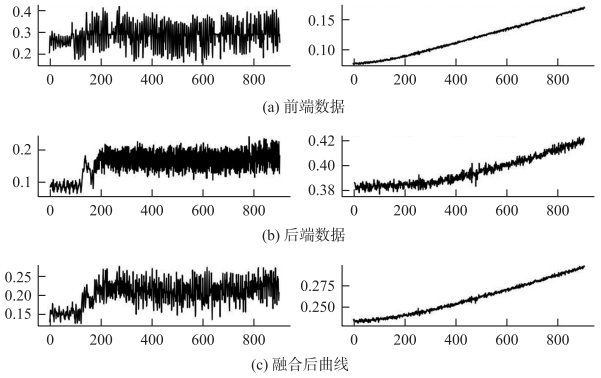

图 7 数据融合前后某组采样点数据

3.2 特征层融合

3.2.1 卷积神经网络

CNN 多用于特征提取,通过多层滤波器逐层提取输入数据特征,进行预测和分类[15]。CNN 一般包括卷积、池化和全连接层。在卷积层,进行卷积操作,使用非线性激活函数构建输出特征。池化层通过池化窗口下采样简化卷积输出特征。全连接层对多层卷积池化后的特征进行处理和分类,展平输出的特征向量。类似人工神经网络,实现节点全连接。具体形式如下:

$$Y^{(l)}=f(X^{(l-1)}\otimes W^{(l)}+B^{(l)}) \quad l\geqslant 1 \tag{6}$$

$$X^{(l)}=\text{pooling}(Y^{(l-1)})+B^{(l)} \quad l\geqslant 1 \tag{7}$$

$$Y^{(l+1)}=f(X^{(l+1)} * W^{(l+1)}+B^{(l+1)}) \quad l\geqslant 1 \tag{8}$$

式中:l 为卷积层数,Y 为卷积层输出,W 为卷积核,B 为偏置项,X 为输入项,f 为激活函数,pooling 为池化下采样操作。

本文重点关注不同状态连续时段下的传感器数据,即时间序列数据,故采用一维卷积神经网络(1D-CNN)进行处理,卷积核、输入项均为一维向量结构,符合时间序列的数据特征。

3.2.2 双线性池化

双线性池化(Bilinear Pooling)通常被用于特征融合[16-17],包含两个特征提取器,即从同一个样本提取出不同类型的特征 x 和特征 y,两类特征经过外积相乘、池化以及归一化操作得到特征融合结果,该方法能够更全面地提取样本特征。

双线性池化操作如下:

$$\text{bi}(l,I,f_A,f_B)=f_A^{\mathrm{T}}(l,I)f_B^{\mathrm{T}}(l,I)\in \boldsymbol{R}^{M\times N} \tag{9}$$

$$\boldsymbol{\xi}(I)=\sum \text{bi}(l,I,f_A,f_B)\in \boldsymbol{R}^{M\times N} \tag{10}$$

$$\boldsymbol{x}=\text{vec}(\xi(I))\in \boldsymbol{R}^{M\times N} \tag{11}$$

$$\boldsymbol{y}=\text{sign}(x)\sqrt{|\boldsymbol{x}|}\in \boldsymbol{R}^{M\times N} \tag{12}$$

$$\boldsymbol{z}=y/y_2\in \boldsymbol{R}^{M\times N} \tag{13}$$

式中:对于样本 I 在位置 l 的两个特征 $\boldsymbol{f}_A$ 和 $\boldsymbol{f}_B$,在本文中为两组一维特征向量。式(9)完成两个特征的双线性相乘,式(10)对外积结果进行池化操作得到关联性矩阵,式(11)将关联性矩阵转换为向量 $\boldsymbol{x}$,式(12)及式(13)对 $\boldsymbol{x}$ 进行归一化操作,$\boldsymbol{z}$ 为最终融合后的特征向量。

3.2.3 一维 Bilinear-CNN 网络

基于上述分析,本文采用一维 Bilinear-CNN 网络,自动提取及融合离心风机运行状态温振特征,获取诊断结果。本文的网络结构如图 8 所示,包括 4 部分:输入层、特征提取层、特征融合层以及输出层。

输入层利用数据分割方法降低输入维度,基于温度及振动数据的时序特点,通过滑动窗口对其进行处理,根据设定的采样步长分割数据,同时考虑时序数据前后相关性,保留部分重叠片段。分割后数据可以扩充数据集,以提升深度学习预测效果。

特征提取层包含三个并行卷积池化层,并行层参数一致,激活函数为 tanh,分别提取温度及振动数据特征,第一个卷积层设置较大卷积核(128×1),提高感受野,充分学习数据信息,第二、三个卷积层设置较小卷积核(16×1),用于深度挖掘数据特征,采用最大池化操作,池化大小为 2,简化特征维数,交替的卷积池化层实现输入数据非线性特征的层级式提取,特征提取层最终输出两组大小一致的特征矩阵,分别代表温度特征和振动特征。

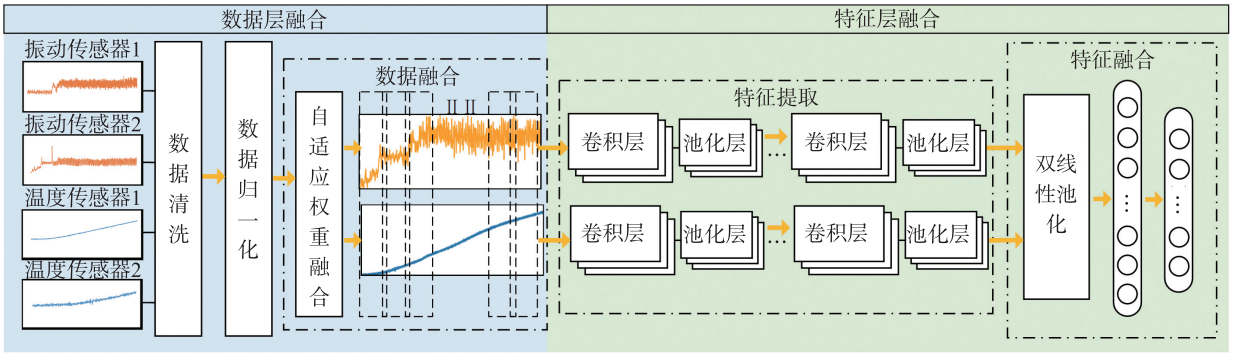

图 8 本文多层次信息融合方法框架

特征融合层采用双线性池化,融合同一时段的两组特征,两组输入特征尺寸均为(N,C,F),其中 N 为数据维度,C 为通道数,F 为特征数,经过双线性融合后特征尺寸为(N,C,$F\times F$),充分体现两类特征的关联性。

输出层由三个全连接层及一个批处理层(Batch Normalization,BN)组成,第一个展平层,将所有特征矢量首尾连接组成一维向量,第二个全连接层节点数为 64,进一步学习融合后的特征,保留关键特征,结合 BN 防止数据过拟合,最后一个全连接层输出分类结果,其神经元个数与状态类别数目保持一致,利用 Softmax 回归分类器输出诊断状态类别。

3.3　实验结果与分析

3.3.1　数据集描述

本文选用无锡某风机公司的离心风机进行采样,设备安装位置如图 9 所示,热电阻贴在风机轴承座表面,振动传感器安装在轴承座 Y 向,传感器数据输出线与 PLC 连接,离心风机包括转子组件、电机、叶轮和传送带等,在转子的前轴承(前端)、后轴承(后端)处均装有温度传感器及振动传感器,检测设备表面温度及径向振动。

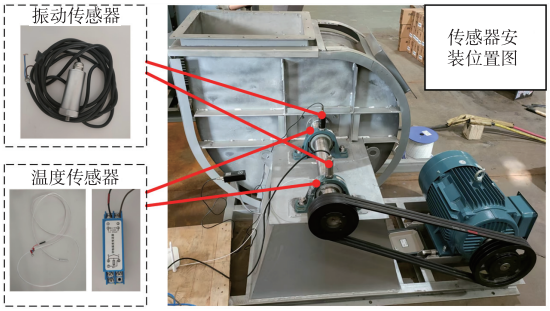

图 9　传感器安装位置

采样 2 000 r/min 转速下的正常状态和四种故障状态的数据,数据样例如图 10 所示。

预处理后数据以 10 s 为分割步长,每组包含 100 个采样点,滑动窗口重叠 20 个采样点,每种状

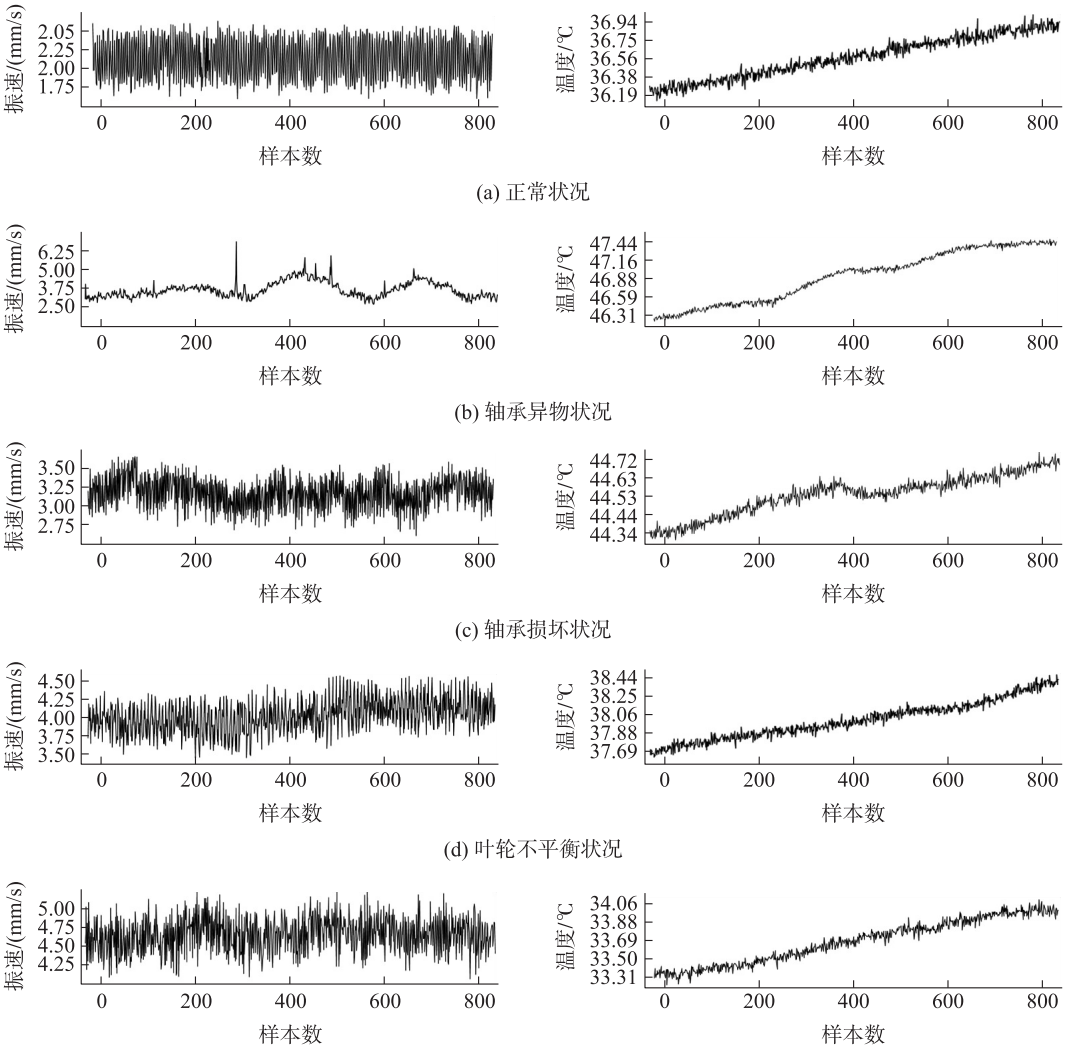

图 10　五种状态数据特点

态类别含有约 200 个数据组,数据集共约 1 000 个数据组,训练集与测试集按 7∶3 比例划分。

诊断模型运行平台为 Windows10 系统,CPU 使用 12th Gen Intel® Core i7-12700 处理器,GPU 显卡使用 NVIDIA GeForce RTX 3060 Ti。

3.3.2 模型评判标准

采用式(14)所示的准确率来判断模型性能。

$$\text{Accuracy}=\frac{\text{TP}+\text{TN}}{\text{TP}+\text{TN}+\text{FP}+\text{FN}} \tag{14}$$

式中:TP 为真正例,即某状态被正确分类的数目,TN 为真负例,即其他状态被正确识别的数目,FP 为假正例,即其他状态被错误分类的数目,FN 为假负例,即某状态被识别错误的数目。

3.3.3 诊断结果及对比分析

为验证本文诊断模型的效果,选用多种对比方法,分成两组进行,第一组为多层融合效果分析,由于实验数据为前后端温度与振动数据,在数据层的对比方法选用温度或者振动其中一组数据,仅在数据层融合为一个序列,输入网络并输出结果,由于无法采用双线性池化层,故用同结构参数的 CNN 代替,在特征层的对比方法是不进行数据层的融合,前后端数据直接输入网络并融合特征,对结果进行分析,与本文方法进行对比,数据如表 1 所示;第二组为特征层提取与融合对比,选用人工特征方法、传统拼接方法,讨论不同特征提取和融合方法效果,其中人工特征包括温度数据最大值、最小值及振动数据最大值、最小值、均值、均方差值、方差、峰值因子、标准差、脉冲因子等时域特征,传统拼接方法为串联数据的情况,结果如表 2 所示。

表 1 多层实验结果对比

诊断方法	多传感器信号	数据层融合		特征层融合	
		振动传感器	温度传感器	振动传感器	温度传感器
Bilinear-CNN	99.09±0.37	74.12±0.77	74.45±6.15	71.43±5.82	57.14±1.83
BPNN	76.42±0.06	65.83±0.04	69.40±0.05	60.00±0.25	46.70±0.07
SVM	89.13±0.03	66.75±0.03	66.20±0.04	73.30±0.13	56.70±0.13

表 2 特征提取与融合实验结果对比

诊断方法	本文方法	人工特征方法	传统拼接方法
Bilinear-CNN	99.09±0.37	82.63±1.05	92.72±6.31
BPNN	76.42±0.06	79.85±0.02	77.94±0.34
SVM	89.13±0.03	77.51±0.08	76.21±0.02

对比算法采用反向传播神经网络(Back Propagation Neural Network,BPNN)和 SVM,BPNN 隐藏层结构为 200-50-5,输入层随方法改变,分别为 200、10、400、100,SVM 采用 RBF 核函数,为保证结果的可靠性,每组实验重复 5 次。

从表 1 和表 2 可以看出,本文诊断方法准确率高于对比的 BPNN 和 SVM 的诊断效果,在数据层多源信息融合方法优于单一传感器的状态判断效果,且多层融合的方法具有更好的特征互补性。在特征层本文方法优于对比方法,且相较于人工特征及传统拼接融合方法,具有更好的特征挖掘和融合能力。故本文诊断方法可以有效完成数据层融合,并从融合数据中自动提取并融合特征,完成离心风机运行状态分类。

4 结论

本文提出了一种离线风机在线监测与多层次信息融合诊断系统,基于传感器与 PLC 的协同,实现离心风机组网监测与数据传输,实时查看、管理多设备运行状态,实现智能化和多功能化的离心风机监测系统,有效促进设备动态监测和质量监控。本文基于多层次信息融合的一维 Bilinear-CNN 方法判断离心风机状态,经过采样数据验证,所提方法的平均准确率为 99.09%,优于其他对比方法,验证了多传感器可以进行特征互补与提高容错率,多层融合使蕴含在原始数据的特征通过逐层非线性特征提取,挖掘异源传感器之间的时空关系,充分利用传感器信息进行离心风机状态判断。

参考文献:

[1] 潘岚川. 基于卷积神经网络的一次风机故障预警研究[D]. 北京:华北电力大学,2021.

[2] Jing L,Wang T,Zhao M,et al. An Adaptive Multi-Sensor Data Fusion Method Based on Deep Convolutional Neural Networks for Fault Diagnosis of Planetary Gearbox[J]. Sensors,2017,17(2):414.

[3] 赵志宏,李春秀,窦广鉴,等. 基于 MTF-CNN 的轴承故障诊断研究[J]. 振动与冲击,2023,42(2):126-131.

[4] 蔡文迹,李醒飞,鲁建宇. 基于振动信号分析的动力调谐陀螺仪滚珠轴承故障诊断[J]. 传感技术学报,2021,34(3):340-345.

[5] Meng T,Jing X Y,Yan Z,et al. A Survey on Machine

Learning for Data Fusion[J]. Information Fusion,2020,57:115-129.
[6] 朱丹宸,张永祥,潘洋洋,等. 基于多传感器信号和卷积神经网络的滚动轴承故障诊断[J]. 振动与冲击,2020,39(4):172-178.
[7] Xia M,Li T,Xu L,et al. Fault Diagnosis for Rotating Machinery Using Multiple Sensors and Convolutional Neural Networks [J]. IEEE/ASME Transactions on Mechatronics,2018,23(1):101-110.
[8] 田亮,袁存波. 基于 LSTM 和证据理论的引风机轴承故障诊断[J]. 动力工程学报,2023,43(5):614-621.
[9] 张友,李聪波,林利红,等. 基于多源信息融合和 ADCNN 的离心鼓风机故障诊断[J]. 重庆大学学报,2022,45(10):86-96.
[10] Bigdeli B, Samadzadegan F, Reinartz P. A Decision Fusion Method Based on Multiple Support Vector Machine System for Fusion of Hyperspectral and LiDAR Data[J]. International Journal of Image and Data Fusion, 2014, 5(3):196-209.
[11] Chen H P,Hu N Q,Cheng Z,et al. A Deep Convolutional Neural Network Based Fusion Method of Two-Direction Vibration Signal Data for Health State Identification of Planetary Gearboxes[J]. Measurement,2019,146:268-278.
[12] 蔺万科,宋华,南新元,等. 一种基于最优聚类中心与权重欧氏距离的多源异质传感器数据融合方法[J]. 传感技术学报,2022,35(1):49-56.
[13] Banerjee T P, Das S. Multi-Sensor Data Fusion Using Support Vector Machine for Motor Fault Detection[J]. Information Sciences,2012,217:96-107.
[14] 周密,刘永葆,黄树红,等. 多层次信息融合技术在燃气轮机故障诊断中的应用[J]. 海军工程大学学报,2009,21(6):45-49,61.
[15] 肖秦,张雨昕,王颖瀛,等. 基于卷积神经网络的酵母出芽特征识别方法[J]. 电子器件,2023,46(4):1096-1103.
[16] Lin T Y,RoyChowdhury A,Maji S. Bilinear CNN Models for Fine-Grained Visual Recognition[C]//2015 IEEE International Conference on Computer Vision, Satiago, Chile,2015:1449-1457.
[17] Gao Z,Wu Y W,Zhang X X,et al. Revisiting Bilinear Pooling:A Coding Perspective[C]//34th AAAI Conference on Artificial Intelligence,New York,NY,USA,2020,34(4):3954-3961.

王子涵(2000—),女,浙江大学工程师学院硕士研究生,主要研究方向为智能控制与智能系统,zh.wang@zju.edu.cn;

许　力(1964—),男,通讯作者,博士,浙江大学电气工程学院教授,主要研究方向为智能控制与智能系统、智能机器人和工业自动化,xupower@zju.edu.cn。