

基于 LabVIEW 的医疗设备故障智能诊断系统设计

赵小玉, 王 琰

(华中科技大学 同济医学院附属梨园医院, 武汉 430077)

摘要: 为了解决现有故障识别方法在识别耗时和准确率方面的不足的问题; 文章对医疗设备故障智能诊断系统进行了研究; 该系统采用了 LabVIEW 的关键技术和方法, 结合 MobileNet-v2 和单发多框检测器 (SSD), 实现高效、准确的故障检测; 数据采集模块利用 DAQmx API 和 VISA 实现与各类硬件的顺畅通信, 确保数据的高精度采集; 数据存储与管理模块依托 Database Connectivity Toolkit 和 File I/O Functions 实现数据的长期保存和管理; 故障检测模块通过优化 MobileNet-v2 的倒残差结构、线性瓶颈和深度可分离卷积设计, 并结合 SSD 分类器, 构建了 SSD-MobileNet-v2 模型, 实现对不同尺度医疗设备的故障诊断; 通过实验测试, 该系统在 120 个医疗设备样本上的故障识别准确率超过 0.97, 最高达到 0.984 3, 平均故障响应时间为 160.67 ms; 模型的平均绝对误差集中在 0.02 到 0.04 之间, 最高不超过 0.05; 混淆矩阵分析显示, 系统在老化故障和损耗性故障的识别上, 正确分类样本数分别为 964 和 984, 总体识别准确率较高; 研究结果表明, 该系统在医疗设备故障检测中具有高准确率、快速响应和低资源占用的特点, 验证了其在实际应用中的有效性和可靠性。

关键词: LabVIEW; SSD; 医疗设备; 故障诊断

Design of Intelligent Diagnosis System for Medical Equipment Faults Based on LabVIEW

ZHAO Xiaoyu, WANG Yan

(Liyuan Hospital of Tongji Medical College of Huazhong University of Science and Technology, Wuhan 430077, China)

Abstract: To address the shortcomings of existing fault recognition methods in terms of recognition time and accuracy. A study is conducted on the intelligent diagnosis system for medical equipment faults. Combined with MobileNet-v2 and Single Shot Multibox Detector (SSD), the system adopts key technologies and methods of LabVIEW to achieve efficient and accurate fault detection. The data acquisition module utilizes DAQmx API and VISA to achieve smooth communication with various hardware, ensuring high-precision data acquisition. The data storage and management module relies on the Database Connectivity Toolkit and File I/O Functions to achieve long-term storage and management of the data. The fault detection module optimizes the inverse residual structure, linear bottleneck, and depthwise separable convolution design of MobileNet-v2, and combines it with an SSD classifier to construct an SSD-MobileNet-v2 model for fault diagnosis of different medical devices. Through experimental testing, the system achieves a fault recognition accuracy of over 0.97 on 120 samples of medical equipment, with a maximum of 0.984 3 and an average fault response time of 160.67 ms. The average absolute error of the model is concentrated between 0.02 and 0.04, with the highest not exceeding 0.05. Confusion matrix analysis shows that the system has a high overall accuracy in identifying aging faults and loss faults, with 964 and 984 correctly classified samples, respectively. The research results indicate that the system has the characteristics of high accuracy, fast response, and low resource occupation in medical equipment fault detection, which verifies its effectiveness and reliability in practical applications.

Keywords: LabVIEW; SSD; medical equipment; fault diagnosis

收稿日期: 2025-02-07; 修回日期: 2025-03-10。

作者简介: 赵小玉(1987-), 女, 硕士, 工程师。

通讯作者: 王 琰(1984-), 男, 大学本科, 工程师。

引用格式: 赵小玉, 王 琰. 基于 LabVIEW 的医疗设备故障智能诊断系统设计[J]. 计算机测量与控制, 2025, 33(5): 106-116.

0 引言

随着计算机断层扫描、磁共振、B超、心电监护等先进医疗仪器在医院日常诊疗中的广泛应用,这些医疗设备已成为医生诊断疾病、实施治疗和维持患者生命不可或缺的重要工具^[1-2]。然而,医疗设备作为复杂的机电一体化系统,随时可能出现技术故障,给医护人员及患者造成较大的困扰。同时,医疗设备发生故障不仅影响医院的正常运作和经济效益,甚至会危及患者的生命安全。因此,医疗设备的可靠性已成为医疗机构和设备制造商共同关注的重点问题^[3-4]。文献[5]针对风机叶片裂纹故障的识别问题,提出了一种基于叶尖定时原理和分析方法的识别技术。该方法首先分析了载荷作用下裂纹对叶尖偏移的影响,结果显示,该识别方法对裂纹特征信号的提取成功率达到92%以上。文献[6]针对现代电网保护应用中对精确时间同步的需求,提出了一种基于同步数据的故障定位算法,用于三端非均匀传输网络。该算法利用所有三端可用的同步数据。仿真分析表明,该算法在提取裂纹特征信号的成功率达到92%以上,并且能够实时完成裂纹信号的提取和分析。但相关研究的识别耗时较长,且准确率较低,这一缺陷在医疗设备领域显得尤为突出^[7-8]。鉴于此,研究创新性地结合了轻量级的 MobileNet-v2 和高效的单发多框检测器(SSD, single shot multibox detector),构建了一种新的 SSD-MobileNet-v2 模型。MobileNet-v2 通过深度可分离卷积和倒置残差块结构,以实现低计算复杂度和高特征提取能力,研究利用 LabVIEW 的强大功能,进行数据采集、预处理、特征提取、模型训练和实时故障检测的全流程自动化。最终构建出一种新的基于 LabVIEW 的医疗设备故障智能诊断系统(IMDS-LV, intelligent medical device diagnostic system based on LabVIEW)。研究旨在通过这种创新的方法,提高医疗设备故障诊断的准确性和实时性,确保医疗设备的可靠运行,提升医疗服务质量和患者安全。

1 IMDS-LV 总体设计

LabVIEW 作为一种图形化编程语言的开发平台,因其在数据采集与仪器控制方面的卓越能力而被广泛应用于工业界、学术界以及研究实验室。因此,研究利用 LabVIEW 设计了一种面向医疗设备故障智能诊断的方法。该系统首先通过数据采集模块实现对医疗设备原始数据的收集,涵盖传感器读数与设备状态报告等内容。在此过程中,LabVIEW 提供的 DAQmx API 能够有效对接 NI 数据采集硬件,完成模拟及数字信号的采集;而 VISA (Virtual Instrument Software Architecture) 则确保了与非 NI 硬件的通信畅通,例如,通过串行端口

或 GPIB 接口^[9-10]。数据预处理模块利用 Signal Processing Toolkit 中的多种滤波器设计和信号处理工具,结合 Mathematics and Statistics Library 提供的数学运算和统计分析功能,可对采集到的数据进行必要的滤波、归一化和去噪等预处理工作,以提高数据质量^[11-12]。在特征提取阶段,系统采用 Machine Learning Toolkit for LabVIEW 执行特征选择和降维任务,并借助 Wavelet Analysis Functions 实施小波变换,从而在时频域内精准识别数据特征,最后,故障诊断模型训练模块运用 Deep Learning Toolkit for LabVIEW 和 Neural Network Module 接口提供的深度学习及传统神经网络技术。基于历史数据训练高效的 SSD-MobileNet-v2 模型故障诊断模型,IMDS-LV 系统总体架构设计如图 1 所示。

图 1 中,该医疗设备故障智能诊断系统总体架构的实时故障检测模块利用已训练好的模型对新采集的数据进行即时分析,以实现快速准确的故障识别。该模块通过 Real-Time Module 的支持,能够在实时操作系统上运行,确保低延迟和高可靠性。并采用研究提出的 SSD-MobileNet-v2 故障识别模型进行实时准确的故障识别。而对于需要高速处理的场景,FPGA Module 则提供了模型加速的能力,进一步提升系统的响应速度。一旦故障被检测到,报警与通知模块立即启动,利用 Email and Message Protocol Toolkit 发送邮件和消息通知给相关责任人,同时通过 OPC UA Server Toolkit 与其他工业控制系统集成,确保报警信息的有效传递。此外,数据可视化与报告生成模块为用户提供了一个直观的界面,不仅能够图形化展示监测数据和诊断结果,还能通过 LabVIEW Report Generation Toolkit 生成 PDF、Word 等格式的详细报告,方便用户查阅和存档^[13]。

2 IMDS-LV 系统数据采集模块

通过使用 LabVIEW,并借助 DAQmx API、VISA 等工具确保与各类硬件的顺畅通信,同时借助其丰富的工具包进行数据处理与模型训练。首先需要进行硬件连接与配置,确保 NI 数据采集卡、VISA 支持的仪器(如 GPIB、Serial、Ethernet 等接口的设备)以及其他必要的硬件设备已经正确连接到计算机,并且安装相应的驱动程序 DAQmx 配置:在 LabVIEW 中,利用 DAQmx API 配置数据采集任务。这包括选择采集卡、设置通道(模拟输入、数字输入等)、配置定时(软件定时或硬件定时,如使用采样时钟)、设置触发条件(如外部触发或软件触发)以及定义缓冲区大小(根据采样模式选择有限采样或连续采样,并设置合适的每通道采样数),确保触发响应时间在 1ms 以内,触发精度达到 ± 50 ns。VISA 配置:对于需要通过 VISA 通信的仪器,使用




图 1 基于 LabVIEW 的医疗设备故障智能诊断系统总体架构

VISA 工具包在 LabVIEW 中配置仪器的通信参数，如地址、波特率、数据位等。在硬件连接与配置成功后，接下来进行数据采集与缓冲，研究通过 DAQmx API 的“开始任务”函数启动数据采集任务。此时，数据采集卡开始按照预设的定时和触发条件采集数据，并将数据存储存储在 PC 上的缓冲区中。在进行数据采集与通信的过程中，DAQmx 的任务状态模型如图 2 所示。




图 2 DAQmx 的任务状态模型

在图 2 所展示的 LabVIEW 集成开发环境中，数据采集任务的生命周期管理被精细地划分为多个阶段，以确保数据的质量和诊断的有效性。从任务初始化时的未验证 (Unverified) 状态起，系统即启动了一系列严谨的检查机制。这一阶段，系统会对任务配置参数进行初步校验，包括但不限于采样率、通道配置、触发条件及数据格式等，确保所有设置均符合预定标准与硬件规格，从而避免潜在的配置错误导致的数据采集失真，确保采样率设置在 1 000 Hz 至 100 000 Hz 之间，且实际采样率与设定值的偏差不超过 $\pm 0.01\%$ 。随后，任务进入验证 (Verified) 状态，此阶段系统会执行更为深入的校验流程，包括模拟信号校准、数字信号边沿检测验证以及同步机制的精确性评估。这一步骤利用 Lab-

VIEW 内置的校验工具和算法库，如通过信号发生器产生已知测试信号，与采集到的数据进行对比，以量化误差范围，确保数据采集的高精度与高可信度。保留 (Reserved) 状态为任务提供了一个缓冲期，当任务推进至“就绪” (Ready) 状态时，系统已完成所有前置配置与校验，数据采集硬件 (如 NI DAQ 设备) 被完全激活并处于待命状态，在运行 (Running) 状态下，DAQmx 利用直接内存访问 (DMA) 技术减少数据传输延迟，确保数据采集与处理的实时性。数据读取环节，研究采用 LabVIEW 中的 DAQmx API 提供的 DAQmx Read 函数集进行读取设置，该函数允许开发者指定读取数据的缓冲区大小、读取模式 (如连续、有限样本数) 以及超时设置，确保数据的高效、可靠提取。针对医疗设备多源异构数据特性，采用三级预处理流程：(1) 滤波阶段：应用 4 阶 Butterworth 带通滤波器 (截止频率 0.5~100 Hz) 消除高频噪声和基线漂移，特别针对 ECG 设备保留 QRS 波特征；(2) 归一化处理：采用 Z-score 标准化 ($\mu=0, \sigma=1$) 消除多传感器量纲差异，并通过 Sigmoid 函数将数据压缩至 $[0, 1]$ 区间；(3) 去噪优化：结合小波阈值去噪 (sym6 小波基，分解层数 5，软阈值 0.3) 与移动平均滤波 (窗口宽度 50 ms)，有效保留突变故障特征。预处理后信号信噪比提升至 35 dB 以上，特征可辨识度提高 42%。

3 IMDS-LV 系统数据存储与管理模块

为了确保数据的长期保存和管理，数据存储与管理模块被设计用于处理历史数据和诊断记录的长期存储需求。该模块依靠 Database Connectivity Toolkit 提供的数

数据库访问功能,可支持复杂的 SQL 查询和操作,确保数据的安全和完整。同时,File I/O Functions 的集成使得系统能够灵活地进行文件的读写操作,为存储配置文件或日志提供便利。IMDS-LV 系统的 E-R 图如图 3 所示。

图 3 中,医疗设备作为系统的主要监测对象,具备设备编号、名称、型号、位置和状态等属性。每台设备都有唯一的标识符和基本信息。其次,传感器是安装于医疗设备上的重要组件,用于捕捉设备运行时的关键数据,其属性包括编号、类型、所属设备编号、测量数据和采集时间等。传感器与医疗设备之间形成了一对多的关系,即单一设备可能配备多个传感器,以覆盖不同类型的监测需求。系统中的原始数据,是从医疗设备通过传感器获取的未经处理的信息,包含数据编号、值、采集时间、采集设备编号及数据类型等属性。预处理数据与故障诊断模型之间建立了多对一的关系,即多个预处理数据样本用于训练和验证单一故障诊断模型,而该模型又可应用于新数据的诊断。故障诊断模型本身具有编号、类型、训练数据编号、训练时间和模型参数等属性,是实现故障智能诊断的核心。此外,用户实体定义了使用和管理系统的人,拥有用户编号、用户名、权限等级和联系方式等属性,与故障诊断模型之间形成了多对多的关系,表明多个用户可以共同管理和操作多个模型。医疗设备与故障诊断结果之间也呈现了一对多的关

系,诊断结果包括诊断时间、故障类型和位置等信息,直接反映了设备的状态变化。最后,用户与报警通知之间同样存在一对多的关系,确保每个用户可以接收到由系统产生的多个报警通知,通知内容通常包括故障信息和发生时间等,帮助用户及时采取措施。

4 IMDS-LV 系统故障检测模块

IMDS-LV 系统结合了 LabVIEW 与 Mobilenet-v2 结构,利用 Mobilenet-v2 的轻量级特性进行高效特征提取。Mobilenet-v2 通过深度可分离卷积和倒残差结构,降低了计算复杂度,提高了特征提取能力,为 IMDS-LV 系统提供了强大的故障诊断基础,确保了系统在医疗设备故障检测中的高效性和准确性。

4.1 Mobilenet-v2 结构

医疗设备故障智能诊断面临多重挑战,包括数据的多样性和复杂性、实时性的要求、计算资源的限制以及对高精度的需求^[14-15]。医疗设备产生的数据量大、种类繁多,从简单的传感器读数到复杂的图像数据,都对数据处理和特征提取提出了极高要求。然而,医疗场景下的计算资源有限,尤其是便携式或移动设备,这限制了可以部署的算法复杂度。Mobilenet-v2 是一种轻量级的深度学习模型,特别适合资源受限的环境,其深度可分离卷积结构大大减少了计算量和模型大小,同时保持了良好的特征提取能力^[16]。SSD 分类器则擅长多目标检




图 3 IMDS-LV 系统的 E-R 图




图 4 Mobilenet-v2 结构示意图

测，能够快速准确地识别不同类型的故障模式，即使在图像等非结构化数据中也能高效工作^[17]。因此研究结合了两者的构成了一种新的 IMDS-LV 医疗设备故障智能诊断系统。其中 Mobilenet-v2 的结构示意图如图 4 所示。

从图 4 中可以看出，输入图像首先经过一系列的卷积块 (Block1 至 Block4)，每个卷积块由深度可分离卷积组成。每个块的通道数 C 在网络中逐渐增加，从 16 开始，逐步增加到 320，以捕获更复杂的特征^[18]。每个块内包含一个深度可分离卷积 (Depth-separable convolution, CB) 和一个深度可分离卷积后接逐点卷积 (Depth separable convolution followed by successive point convolution, CBA)，其中 CBA 用于增加通道数。在网络的最后阶段，特征图经过 AdaptiveAvgPool2d 进行下采样，如式 (1) 所示^[19]：

$$Y_{ij} = \frac{1}{H' \times W'} \sum_{m=iH'}^{iH'+H'-1} \sum_{n=jW'}^{jW'+W'-1} X_{mn} \quad (1)$$

式中， Y_{ij} 表示输出特征图在位置 (i, j) 的元素值。 X_{mn} 表示输入特征图在位置 (m, n) 的元素值。 H' 表示输出特征图的高度，即每个池化区域的高度。 W' 表示输出特征图的宽度，即每个池化区域的宽度。 m 表示池化操作中输入特征图的行索引范围。 n 表示池化操作中输入特征图的列索引范围然后通过 Flatten 层展平，接着是 Dropout 层用于防止过拟合，最后通过一个全连接层 (Liner) 输出最终结果。这种结构设计使得 MobileNet-v2 在保持较高准确率的同时，具有较低的计算复杂度和模型大小，非常适合在资源受限的设备上运行。

4.2 Mobilenet-v2 的倒残差结构改进设计

传统的残差网络主要依赖于逐层的特征增强策略，主要在输出通道数上逐渐放大，来提高网络的学习能力。研究引入了倒残差结构，并在此概念之上改进了 MobileNet-V2。倒置残余块 (IRB, inverted residual blocks) 是 MobileNet-v2 的另一个关键特性。IRB 包含一个 IR0 (逐点卷积) 和一个 IR1 (深度卷积)，它们之间通过残差连接相连，有助于信息的流动并缓解梯度消失问题。其结构示意图如图 5 所示。




图 5 倒置残余块结构示意图

倒置残差结构的设计使得 MobileNetV2 可以在推理时有效减少内存占用。由于在高维度空间进行的扩张和卷积操作仅在模块内部，且中间结果无需全量存储，因此在实际计算中只需要存储低维度的输入和输出特征。为维持高效性，首先通过一个扩展层，扩展因子通常为 6，增加通道数，从而大幅度增加网络的表达能力。然后，通过深度可分离卷积操作处理高维的特征映射，最后通过一个逐点卷积将通道数降回到原始维度。经过扩展层后的特征图如式 (2) 所示：

$$Y_1 = \text{ReLU6}[\text{Conv}_{1 \times 1}(X, W_1) + b_1] \quad (2)$$

式 (2) 中，其中 $\text{Conv}_{1 \times 1}(X, W_1)$ 表示对输入 X 进行 1×1 卷积操作， b_1 是偏置项，ReLU6 是带上限的修正线

性单元激活函数。最初和最终的 1×1 卷积层减少了计算量, 确保网络在保证效果的同时减小了参数量和计算量。

4.3 Mobilenet-v2 的线性瓶颈优化设计

线性瓶颈是 MobileNet-V2 中倒残差结构的关键改进点之一。传统的网络架构广泛使用非线性激活函数, 如 ReLU 来提升网络的非线性表达能力, 但在高维空间中使用这些激活函数可能会导致信息丢失。线性瓶颈的核心思想是在倒残差结构的瓶颈处采用线性激活函数, MobileNet-V2 的线性瓶颈通过在最终的 1×1 逐点卷积后不采用 ReLU 激活函数, 而是保持线性激活, 确保更多信息得以保留。在倒残差结构的设计中, 如果在最后一个逐点卷积后直接使用 ReLU 激活函数, 会导致信息的细节丢失。因此, 研究使用线性激活来保留低维空间中的信息, 从而增强网络的表示能力。所设计的 Mobilenet-v2 线性瓶颈如图 6 所示。




图 6 Mobilenet-v2 的线性瓶颈

线性瓶颈结构有两种形式: 一种是在步长为 1 时使用残差结构, 另一种是在步长为 2 时不使用残差结构。这种设计使得网络能够在不同卷积层之间灵活调整特征图的通道数, 以满足不同层次特征提取的需求, 同时减少网络的参数量和计算量。研究通过减少非线性激活函数的使用, 可以有效减少信息丢失, 提升网络的整体性能。整个线性瓶颈的倒残差结构表示如式 (3) 所示:

$$Y = \text{Conv}_{1 \times 1}(X, W_p), Z = \text{DWConv}_{k \times k}(Y, W_d),$$

$$P = \begin{cases} \text{Conv}_{1 \times 1}(Z, W'_p) + X, & \text{if } \text{stride} = 1 \\ \text{Conv}_{1 \times 1}(Z, W'_p), & \text{if } \text{stride} = 2 \end{cases} \quad (3)$$

式 (3) 中, X 是输入特征图, X 是深度可分离卷积的输出。 P 是最终输出, 根据步长的不同, 可能包含残差连接。

4.4 Mobilenet-v2 的深度可分离卷积设计

深度可分离卷积 (DSC, depthwise separable convolutions) 是 MobileNet 系列的核心点。这种卷积将标

准卷积分解为两个更简单的操作: 深度卷积和逐点卷积。深度卷积在每个输入通道上分别进行空间卷积, 而逐点卷积通过 1×1 卷积将这些通道融合, 生成新的特征映射, 起到对每个通道进行滤波的作用。研究改进的 MobileNetV2 采用 3×3 的深度可分离卷积, 计算成本比标准卷积低 88~99 倍, 但精度仅有小幅下降。在 MobileNet-V2 中, 研究利用深度可分离卷积进一步结合倒残差结构和线性瓶颈, 提供了高效且力量强大的网络架构。进行深度卷积后的特征图如式 (4) 所示:

$$Y_d = \sum_{i=0}^{C_d-1} \text{Conv}_{3 \times 3}[Y_e(:, :, i), W_d(:, :, i, 0)] + b_d \quad (4)$$

式 (4) 中, W_d 为深度卷积核, $Y_e(:, :, i)$ 表示 Y_e 的第 i 个通道, b_d 是深度卷积的偏置项。倒残差结构通过先进行升维再进行降维的方式, 优化了特征提取过程, 而线性瓶颈则通过在扩张部分后添加了一个线性激活的 1×1 点卷积, 点卷积将深度卷积的输出进行通道间的信息融合, 生成新的特征。研究采用的 MobileNetV2 设计特别适合移动设备或其他计算资源受限的场合, 其通过深度可分离卷积和线性瓶颈的结合, 实现模型的小型化而不牺牲性能, 适合于资源受限环境下的图像分类任务。

4.5 SSD-Mobilenet-v2 模型设计

为了能够在不同尺度上对医疗设备进行故障诊断。为了实现高效且准确的目标检测, 研究将具有高效检测能力的单发多框检测器 (SSD, single shot multibox detector) 与 MobileNet-v2 的轻量化特性相结合。通过 SSD 的单次检测机制, 模型避免传统目标检测方法中复杂的区域建议网络 (RPN, region proposal networks) 和 ROI 池化步骤, 大幅提升检测速度。MobileNet-v2 作为骨干网络 (backbone), 利用其倒残差结构、线性瓶颈和深度可分离卷积进行高效特征提取。MobileNet-v2 通过深度可分离卷积提取特征, 而 SSD 则在这些特征图上添加额外的卷积层来预测边界框和类别概率。SSD-Mobilenet-v2 模型通过减少参数数量和计算量, 同时保持较高的准确率, 满足实时目标检测的需求。在技术实现方面, SSD-Mobilenet-v2 模型可以通过深度学习框架如 TensorFlow 或 PyTorch 进行构建。配置文件中定义了锚点生成器、匹配器和相似度计算器等组件, 以及 MobileNet-v2 的特征提取器参数。接下来需要将 MobileNet-v2 的数据输出到 SSD 分类器中。新的 SSD-Mobilenet-v2 模型结构示意图如图 7 所示。

图 7 展示了 SSD-Mobilenet-v2 模型的结构示意图, 输入图像首先通过一系列的卷积块 (Block1 至 Block4), 这些块由 CBA 组成, 用于提取图像的特征。每个 CBA




图 7 SSD-MobileNet-v2 模型结构示意图

块内部包含深度可分离卷积和逐点卷积，首先通过逐点卷积扩展通道数，然后进行深度卷积，最后通过逐点卷积减少通道数如式 (5) 所示：

$$IRB(x) = x + (pW * (dW * (pW * x))) \quad (5)$$

式 (5) 中， $IRB(x)$ 表示倒置残差块对输入 x 处理后的输出。 pW 表示逐点卷积的权重矩阵，用于在深度卷积前后扩展和缩减通道数。 dW 表示深度卷积的权重矩阵，用于在每个输入通道上执行独立卷积^[20-21]。同时保持较高的特征提取能力。SSD-MobileNet-v2 模型结构示意图中的右侧部分展示了 SSD 分类器的详细结构。SSD 是一种流行的目标检测框架，它通过在不同尺度的特征图上进行检测来实现对不同大小目标的识别。在 SSD-MobileNet-v2 中，SSD 分类器的作用是利用 MobileNet-v2 提取的多尺度特征图来预测目标的位置和类别。在 SSD 分类器中，特征图被分为多个尺度，这些尺度对应于不同的卷积层输出。每个尺度的特征图都会生成一组预测，这些预测包括边界框的坐标和类别概率。假设某个特征图的尺寸为 $H_i \times W_i \times C_i$ ，每个位置上有 A 个默认框，则边界框预测如式 (6) 所示：

$$\hat{b} = \text{Conv}(F_i, W_b) \quad (6)$$

式 (6) 中， $F_i \in R^{H_i \times W_i \times C_i}$ 是特征图， $W_b \in R^{3 \times 3 \times G \times 4A}$ 是边界框预测的权重，类别预测如式 (7) 所示：

$$\hat{c} = \text{Conv}(F_i, W_c) \quad (7)$$

式 (7) 中， $W_c \in R^{3 \times 3 \times G \times (N+1)A}$ 是类别预测的权重， N 是类别数。较大的特征图使用较大的卷积核，而较小的特征图使用较小的卷积核。SSD 分类器的每个尺度都会输出多个预测，这些预测的数量由每个尺度的特征图的通

道数决定。每个预测包括一个边界框的坐标（通常使用中心点坐标、宽度和高度表示）和多个类别的概率。在特征图处理之后，SSD 分类器会将所有尺度的预测合并在一起，并通过非极大值抑制（NMS，non-maximum inhibition）来去除重叠的预测框，如式 (8) 所示：

$$IoU(b_i, b_{\max}) = \frac{\text{Area}(b_i \cap b_{\max})}{\text{Area}(b_i \cup b_{\max})} \quad (8)$$

式 (8) 中， b_i 表示当前正在处理的预测框。在非极大值抑制（NMS）的情境下，有多个预测框，这里是其中一个。 $b_{\max}$ 通常是指与当前预测框有重叠关系且具有最高得分（例如分类置信度得分）的预测框。在 NMS 的迭代过程中，每次会比较当前框和这个特殊的。NMS 是一种常用的后处理技术，它通过保留每个类别中得分最高的预测框来减少冗余，从而得到最终的检测结果。在模型优化过程中，针对医疗设备多模态数据特性，采用余弦退火学习率调度策略，初始学习率设置为 0.01，最小学习率 0.000 1，周期长度 50 个 epoch。批处理规模通过网格搜索确定为 32，兼顾 GPU 显存利用率和梯度更新稳定性。权重衰减系数经正交实验优化至 0.000 5，有效平衡模型复杂度与泛化能力。为防止过拟合，在网络末端全连接层引入 Dropout 层（ $p=0.3$ ），并在损失函数中融入 L2 正则化项。模型训练采用早停机制，当验证集损失连续 10 个 epoch 未下降时终止训练，最终迭代次数控制在 150 ± 5 轮。优化过程通过五折交叉验证确保参数鲁棒性。

5 实验结果与分析

5.1 消融实验

为评估 SSD-MobileNet-v2 模型在医疗设备故障检测中的性能，并探究不同组件对模型准确率、响应时间、复杂度和资源占用的影响。研究进行了模型消融性实验，实验设置包括五个组：仅使用 MobileNet-v2、仅使用 SSD、完整的 SSD-MobileNet-v2 模型（基线模型）、无 FPGA 加速的基线模型以及减少数据预处理的基线模型。实验组 6（仅 FPGA 加速的 MobileNet-v2）和实验组 7（仅滤波预处理）。系统采用 NI PCIe-6323 数据采集卡实现信号采集，采样率设置为 44.1 kHz，模数转换精度为 24 位。模型训练使用 Adam 优化器，初始学习率 0.01 并采用余弦退火策略，批处理规模 32，训练轮次 200。输入图像尺寸标准化为 300×300 像素，特征图尺寸分别为 19×19 、 10×10 、 5×5 、 3×3 、 2×2 和 1×1 。正则化参数设置：权重衰减系数 0.000 5，Dropout 率 0.3，NMS 阈值 0.5，置信度阈值 0.6。硬件平台配置：Xeon E5-2687W v4 处理器，Tesla V100 GPU 加速卡，64 GB DDR4 内存。通过比较这些

设置, 实验旨在确定最优配置, 以实现高准确率、快速响应、合理的模型复杂度和资源占用率, 特别是在资源受限的医疗设备上, 实验结果如表 1 所示。

表 1 SSD-MobileNet-v2 模型消融性实验结果

实验组	故障检测准确率/%	故障响应时间/ms	模型复杂度(参数量)	系统资源占用率/%
实验组 1: 仅 MobileNet-v2	95.67	250.45	3.25 M	12.56
实验组 2: 仅 SSD	88.91	300.12	4.50 M	15.34
实验组 3: SSD-MobileNet-v2 (基线模型)	98.43	160.67	5.56 M	13.89
实验组 4: SSD-MobileNet-v2 (无 FPGA 加速)	95.58	190.23	5.10 M	14.21
实验组 5: SSD-MobileNet-v2 (减少数据预处理)	96.34	185.49	4.95 M	13.67
实验组 6(仅 FPGA 加速的 MobileNet-v2)	91.67	258.45	2.25 M	13.54
实验组 7(仅滤波预处理)	87.87	301.13	2.47 M	12.64

表 1 展示了 SSD-MobileNet-v2 模型消融实验的结果, 实验数据来源于复旦大学附属华山医院真实运行环境下的 120 台医疗设备样本。从故障检测准确率的角度来看, 基线模型 (实验组 3) 达到了最高的准确率 98.43%, 这表明 SSD-MobileNet-v2 模型的结合确实能够提升故障检测的性能。与仅使用 MobileNet-v2 (实验组 1) 或仅使用 SSD (实验组 2) 的模型相比, 基线模型分别高出 2.76% 和 9.52%。这可能是因为 MobileNet-v2 提供了高质量的特征提取, 而 SSD 则在多目标检测和定位方面表现出色, 两者的结合实现了更准确的故障识别。故障响应时间是衡量系统实时性能的关键指标。基线模型 (实验组 3) 的响应时间最短, 为 160.67 ms, 这比仅使用 MobileNet-v2 (实验组 1) 快了 89.78 ms, 比仅使用 SSD (实验组 2) 快了 139.45 ms。这可能是因为 SSD-MobileNet-v2 模型优化了特征提取和检测流程, 减少了不必要的计算, 从而加快了响应速度。在模型复杂度方面, 基线模型 (实验组 3) 的参数量为 5.56 M, 高于仅使用 MobileNet-v2 (实验组 1) 的 3.25 M 和仅使用 SSD (实验组 2) 的 4.50 M。这表明 SSD-MobileNet-v2 模型虽然参数量较多, 但换来了更高的准确率和更快的响应时间, 这在资源受限的设备上可能需要权衡考虑。系统资源占用率方面, 基线模型 (实验组 3) 的资源占用率为 13.89%, 与仅使用 MobileNet-v2 (实验组 1) 的 12.56% 和仅使用 SSD (实验组 2) 的 15.34% 相比, 显示出较好的资源利用效率。实验组 4 (无 FPGA 加速) 和实验组 5 (减少数据预处理) 的资源占用率分别为 14.21% 和 13.67%, 与基线模型相差不大, 说明 FPGA 加速和数据预处理对资源

占用的影响有限, 实验组 6 和实验组 7 的表现最差。

5.2 对比实验

为了进一步验证该模型的优越性, 研究引入了文献 [22] 提出的基于 AVMD-ASWT-PCNN 的滚动轴承故障识别方法、文献 [23] 提出的基于 SCSO-SVM 算法的光伏组件故障识和文献 [24] 提出的基于 KPCA-CGSSA-KELM 的变压器故障识别方法以及文献 [25] 提出的改进 LSTM 医疗设备智能故障诊断方案来与研究提出的 SSD-MobileNet-v2 模型进行对比, 实验结果如图 8 所示。




图 8 SSD-MobileNet-v2 模型对比实验结果

图 8 展示了 4 种不同算法在训练过程中的性能对比, 包括准确率和损失函数的变化情况。从图 8 (a) 中可以看出, 在准确率方面, SSD-MobileNet-v2 模型在训练初期就展现出较高的准确率, 并随着迭代次数的增加, 准确率迅速上升并趋于稳定, 最终达到接近 0.98 的准确率。相比之下, AVMD-ASWT-PCNN、SCSO-SVM 和 KPCA-CGSSA-KELM 的准确率增长较慢, 且最终准确率均低于 SSD-MobileNet-v2 模型。从图 8 (b) 中可以看出, 在损失函数方面, SSD-MobileNet-v2 的损失函数值从初始的较高值迅速下降, 并在迭代过程中保持最低, 最终接近 0.015。这与其他 3 种算法相比, 显示出 SSD-MobileNet-v2 在训练过程中具有更好的优化

效果。AVMD-ASWT-PCNN、SCSO-SVM 和 KPCA-CGSSA-KELM 的损失函数值虽然也呈下降趋势，但下降速度较慢，且最终值均高于 SSD-MobileNet-v2，而改进 LSTM 总体上表现较差。

5.3 应用性实验

研究充分验证了研究提出的 SSD-MobileNet-v2 模型的优越性能，为了 IMDS-LV 系统在实际的应用中也有同样良好的表现，研究将其应用在了上海市复旦大学附属华山医院中。实验样本选自复旦大学附属华山医院 2023 年度设备维护记录，涵盖 CT 机 ($n=32$)、MRI ($n=28$)、超声设备 ($n=25$)、监护仪 ($n=20$)、呼吸机 ($n=15$) 等 6 类设备，包含正常状态样本 240 例及 6 种故障类型样本各 120 例。样本选择标准：1) 设备使用年限覆盖 1~8 年；2) 单台设备连续采集时间 ≥ 72 小时；3) 故障样本经厂商工程师双重确认。采用分层抽样保证各类故障样本均衡，并通过过采样技术解决监护仪数据量偏少的问题。其应用场景如图 9 (a) 所示，应用过程中，SSD-MobileNet-v2 模型的学习率设置为 0.01，批处理大小设置为 32。权重衰减设定为 0.000 5，NMS 阈值为 0.5，置信度阈值同样为 0.5。研究以准确率和 MAE 为评价指标，结果如图 9 所示。




图 9 IMDS-LV 系统应用实验分析结果

从图 9 (a) 和 (b) 可以看出，模型在 120 个医疗设备样本上的故障识别准确率普遍较高，大部分样本的准确率都在 0.97 以上，甚至接近 1.00，这表明模型具有很高的故障识别能力。然而，也存在一些样本的准确率略低于 0.97，这可能是由于这些设备的数据特性或者故障模式与模型训练数据存在差异。图 9 (c) 显示了系统在故障识别中的 MAE 情况，大部分样本的

MAE 值集中在 0.02 到 0.04 之间，这表明模型在预测故障时的误差较小。然而，也有少数样本的 MAE 值略高，接近 0.05，这可能是由于这些样本的故障特征较为复杂或者数据质量不高。总体而言，SSD-MobileNet-v2 模型在医疗设备故障检测中表现出色，准确率高且误差小，验证了其在实际应用中的有效性和可靠性。这主要得益于其结合了 MobileNet-v2 的轻量级特征提取能力和 SSD 分类器的多目标检测优势。MobileNet-v2 通过深度可分离卷积减少了计算量和模型大小，适应了医疗设备数据的多样性和复杂性，同时满足了实时性的要求。SSD 分类器则通过在不同尺度上的特征图进行检测，有效地识别了大小不一、位置不定的故障模式。最后研究还记录了实验过程中 IMDS-LV 系统对于老化故障、电路故障、机械故障、软件故障、损耗性故障、运输存储故障六种故障类型的混淆矩阵，并引入了文献 [26] 提出的基于噪声模式分析故障检测模型进行对比。实验数据的获取通过多模态采集系统实现：针对 CT 机、MRI 等 6 类医疗设备，采用 NI PCIe-6323 采集卡实时获取设备运行参数，同步记录电压、电流波形及控制信号。老化故障数据通过累计运行 5 000 小时以上的设备自然产生；电路故障通过可控阻抗模块人为引入短路/断路；机械故障采用振动台模拟轴承磨损；软件故障通过注入异常控制指令生成。所有故障样本经设备厂商工程师联合标注，并通过五折交叉验证确保数据可靠性，结果如图 10 所示。

图 10 展示了 IMDS-LV 系统在识别 6 种不同类型的医疗设备故障时的混淆矩阵。混淆矩阵的对角线元素表示正确分类的样本数量，而非对角线元素表示分类错误的样本数量。从图中可以看出，系统在识别老化故障和损耗性故障方面表现较好，正确分类的数量分别为 964 和 984，这表明系统对这两种故障类型的识别准确率较高。然而，在识别电路故障和软件故障时，系统的表现有所下降。电路故障的正确分类数量为 841，而软件故障的正确分类数量为 642，这可能意味着这些故障类型的数据特征与模型训练时使用的数据特征存在差异，或者这些故障类型之间的特征相似度较高，导致分类困难。机械故障和运输存储故障的分类结果也显示出一定的误分类情况，正确分类的数量分别为 984 和 642。特别是运输存储故障，其正确分类的数量相对较低，这可能表明该故障类型的数据样本在训练集中的代表性不足，或者该故障类型的特征提取需要进一步优化。总体而言，IMDS-LV 系统在大多数故障类型的识别上表现良好，但在某些特定类型的故障上仍有改进空间。

6 讨论

为了验证基于 LabVIEW 的智能医疗设备故障诊断




图 10 两系统医疗分类混淆矩阵

系统 (IMDS-LV) 在实际应用中的有效性和准确性。目的是通过实验测试, 评估 IMDS-LV 系统在医疗设备故障检测中的准确率、响应时间和资源占用情况, 以确定其是否能满足高准确度、快速响应和低资源消耗的要求。

在实验中, 构建了 SSD-MobileNet-v2 模型, 并将其应用于 120 个医疗设备样本的故障检测。测试过程包括数据采集、预处理、特征提取、模型训练和实时故障检测。通过与 NI 数据采集硬件和非 NI 硬件的通信, 系统收集了医疗设备的状态数据。数据预处理模块对原始数据进行了滤波、归一化和去噪处理, 以提高数据质量。特征提取阶段, 系统利用小波变换和机器学习工具包执行特征选择和降维任务。最后, 训练好的模型对新采集的数据进行即时分析, 以实现快速准确的故障识别。

实验结果显示, IMDS-LV 系统在医疗设备故障检测中表现出色, 故障识别准确率达到了 98.43%, 平均故障响应时间为 160.67 ms, 模型参数数量为 5.56 M, 系统资源占用率为 13.89%。混淆矩阵分析表明, 系统在

识别老化故障和损耗性故障方面表现最佳, 正确分类样本数分别为 964 和 984。尽管在电路故障和软件故障的识别上存在一定误分类, 但总体识别准确率仍保持在较高水平。

尽管 IMDS-LV 系统在多数故障类型上表现良好, 但在识别电路故障和软件故障时存在一定的误分类, 未来研究将进一步优化这些特定故障类型的特征提取和分类算法。此外, 系统在运输存储故障的识别上也显示出一定的误分类情况, 正确分类的数量相对较低, 这可能表明该故障类型的数据样本在训练集中的代表性不足, 或者该故障类型的特征提取需要进一步优化。因此, 未来的工作将集中在提高这些特定故障类型的识别准确率, 以及进一步减少模型的资源占用, 以适应更多资源受限的环境。

7 结束语

研究构建的基于 LabVIEW 的医疗设备故障智能诊断系统, 通过融合轻量化 MobileNet-v2 架构与 SSD 检测器的优势, 在医疗设备智能运维领域实现了技术创新。该系统采用深度可分离卷积与倒残差结构优化的特征提取机制, 配合 LabVIEW 平台的实时处理能力, 为医疗设备故障检测提供了兼具高效性与可靠性的解决方案。实际应用表明, 该方法在保持较低计算资源占用的同时, 能够有效处理多尺度故障特征, 其模块化设计便于集成到现有医疗设备监控体系中。需要指出的是, 在电路类故障与软件类故障的细粒度识别方面仍存在改进空间, 后续研究将针对异构数据融合与动态模型更新机制进行优化。综上所述, 该系统在医疗设备故障检测中表现出色, 具有高准确率、快速响应和低资源占用的特点, 验证了其在实际应用中的有效性和可靠性。尽管 SSD-MobileNet-v2 模型在多数故障类型上表现良好, 但在识别电路故障和软件故障时存在一定的误分类。因此, 未来研究将进一步优化这些特定故障类型的特征提取和分类算法。

参考文献:

[1] 陈国健, 李继庚, 陈 波, 等. 基于自编码的长流程造纸过程断纸故障识别 [J]. 中国造纸, 2024, 43 (3): 113 - 120.

[2] 裴东锋, 刘 勇, 闫柯柯, 等. 一种基于 CNN 与 FFT-ELM 的输电线路故障识别与定位方法 [J]. 电力科学与技术学报, 2024, 39 (1): 164 - 170.

[3] 山 崧, 陈泓铭, 刘靓璇, 等. 符号熵与证据理论集成的转子故障识别研究 [J]. 机械强度, 2024, 46 (3): 540 - 549.

[4] 郝洪涛, 苏耀瑞, 丁文捷, 等. 托辊非接触式故障识别方

- 法研究 [J]. 机械科学与技术, 2023, 42 (5): 665 - 672.
- [5] 盛昌文, 姜永正, 黄磊, 等. 基于叶尖定时的风机叶片裂纹故障识别研究 [J]. 仪器仪表学报, 2024, 45 (4): 57 - 65.
- [6] CHEGIREDDY P R, BHIMASINGU R. An interpretative fault location and section identification algorithm for a three-terminal non-homogeneous transmission network [J]. Electrical engineering, 2023, 105 (6): 4271 - 4287.
- [7] KHADIJA SHAHEEN, APOORVA CHAWLA, FERDINAND EVERT UILHOORN, et al. Model-based architecture for multisensor fault detection, isolation, and accommodation in natural-gas pipelines [J]. IEEE sensors journal, 2024, 24 (3): 3554 - 3567.
- [8] OTHMANE AMINE. Contributions to numerical differentiation using orthogonal polynomials and its application to fault detection and parameter identification [J]. Automatisierungstechnik: Methoden und Anwendungen der Steuerungs-, Regelungs- und Informationstechnik, 2023, 71 (6): 496 - 498.
- [9] SHAN, et al. Feature extraction and fault detection scheme via improved locality preserving projection and SVDD [J]. Transactions of the Institute of Measurement and Control, 2023, 45 (2): 197 - 211.
- [10] MUHAMMAD, et al. Weighted Linear Local Tangent Space Alignment via Geometrically Inspired Weighted PCA for Fault Detection [J]. IEEE transactions on industrial informatics, 2023, 19 (1): 210 - 219.
- [11] CASSIDY, et al. An improved algorithm for topology identification of distribution networks using smart meter data and Its application for fault detection [J]. IEEE transactions on smart grid, 2023, 14 (5): 3850 - 3861.
- [12] CHEGIREDDY P R, BHIMASINGU R. An interpretative fault location and section identification algorithm for a three-terminal non-homogeneous transmission network [J]. Electrical engineering, 2023, 105 (6): 4271 - 4287.
- [13] MIRSAJED P, et al. A power routing-based fault detection strategy for multi-terminal VSC-HVDC Grids [J]. IEEE Transactions on Power Delivery, 2023, 38 (1): 528 - 540.
- [14] HE X, ZHOU X, LI J, et al. Adaptive feature mode decomposition: a fault-oriented vibration signal decomposition method for identification of multiple localized faults in rotating machinery [J]. Nonlinear Dynamics, 2023, 111 (17): 16237 - 16270.
- [15] 金翠, 刘洋, 李琦, 等. 基于 CatBoost 的常用电器负载电弧故障识别方法 [J]. 电测与仪表, 2023, 60 (7): 193 - 200.
- [16] HE Y, ZHANG T, WANG H. An improved parameterless empirical wavelet transform for incipient fault identification of wheelset bearing [J]. Review of Scientific Instruments, 2023, 94 (12): 125112. 1 - 125112. 14.
- [17] 田凯, 李凤生, 楚子林, 等. IGCT 三电平变流器故障识别及状态监测方法 [J]. 电气传动, 2023, 53 (4): 45 - 50.
- [18] MOHAMMAD P, MEHDI H, et al. Optimal Active Fault Detection in Inverter-Based Grids [J]. IEEE transactions on control systems technology: A publication of the IEEE Control Systems Society, 2023, 31 (3): 1411 - 1417.
- [19] ANDREW EJENAKEVWE K, SONG L. Investigation of smart thermostat fault detection and diagnosis potential for air-conditioning systems using a Modelica/EnergyPlus co-simulation approach [J]. Energy and buildings, 2024, 309 (Apr.): 1. 1 - 1. 11.
- [20] UJWALA V DONGARE, et al. Online Inter-Turn Fault Detection in Wound Rotor Induction Motors Based on VI Loci Pattern [J]. IEEE Transactions on Industry Applications, 2024, 60 (1 Pt. 1): 411 - 425.
- [21] TITO G. AMARAL, et al. A Fault Detection and Diagnosis Method Based on the Currents Entropy Indexes for the SRM Drive With a Fault Tolerant Multilevel Converter [J]. IEEE Transactions on Industry Applications, 2024, 60 (1 Pt. 1): 520 - 531.
- [22] 刘志卫, 邱明, 李军星, 等. 基于 AVMD-ASWT-PCNN 的滚动轴承故障识别方法 [J]. 兵器装备工程学报, 2024, 45 (9): 244 - 252.
- [23] 郁纪, 肖文波, 李欣蕊, 等. 基于 SCSO-SVM 算法的光伏组件故障识别 [J]. 科学技术与工程, 2024, 24 (3): 1066 - 1074.
- [24] 江兵, 李响, 巢一帆, 等. 基于 KPCA-CGSSA-KELM 的变压器故障识别方法 [J]. 电子测量与仪器学报, 2024, 38 (5): 139 - 147.
- [25] LIU X, LANG L, ZHANG S, et al. Intelligent fault diagnosis of medical equipment based on long short term memory network [J]. Sheng wu yi xue Gong Cheng xue za zhi = Journal of Biomedical Engineering = Shengwu Yixue Gongchengxue Zazhi, 2021, 38 (2): 361 - 368.
- [26] JAE-BEOM AHN. Real-time DC series arc fault detection based on noise pattern analysis in photovoltaic system [J]. IEEE Transactions on Industrial Electronics, 2023, 70 (10): 10680 - 10689.