

基于FPGA的高速公路机电设备智能监测系统*

郑桔浩

(广东罗阳高速公路有限公司 阳春 529600)

摘要: 针对高速公路机电设备维护过程中人工效率低、管理不够精确的问题,设计一种基于FPGA的高速公路机电设备智能监测系统。首先,该系统以FPGA为主控芯片,结合STM32模块对设备状态信息进行多种传感器数据采集,其中传感器输出的信号利用放大滤波电路进行了调理。其次,利用分层卷积深度学习对采集到获得机电设备状态数据进行分析。通过残差网络替换传统的特征提取网络并建立候选区域的损失函数模型,实现了机电设备故障智能监测。实验结果表明,相比其他监测方法,该系统在噪声干扰下的故障漏警率得到大幅降低,仅为0.16%,满足了自动化管理工作的需求。

关键词: 公路机电;设备智能监测;FPGA;STM32;卷积神经网络

中图分类号: TN914;TP23.1 **文献标识码:** A **国家标准学科分类代码:** 510.50

Intelligent monitoring system of expressway electromechanical equipment based on FPGA

Zheng Zhihao

(Guangdong Luo Yang Expressway Co., Ltd., Yangchun 529600, China)

Abstract: Aiming at the problems of low labor efficiency and inaccurate management in the maintenance process of expressway electromechanical equipment, an intelligent monitoring system of expressway electromechanical equipment based on FPGA is designed. At first, the system uses FPGA as the main control chip, and combines STM32 module to collect a variety of sensor data for equipment status information, in which the signal output by the sensor is conditioned by the amplification filter circuit. Secondly, hierarchical convolution deep learning is used to analyze the collected state data of electromechanical equipment. By replacing traditional feature extraction network with residual network and establishing loss function model of candidate region, intelligent fault detection of electromechanical equipment is realized. Experimental results show that, compared with other monitoring methods, the system's failure alarm rate under noise interference is greatly reduced to only 0.16%, which meets the requirements of automatic management.

Keywords: road electromechanical; intelligent monitoring of equipment; FPGA; STM32; convolution neural network

0 引言

随着我国经济的快速发展,高速公路的里程数也得到突飞猛进的增长,截止2017年已经突破了约14万公里。公路配套机电系统的管理与维护一直是交通公路运营相关部分的主要工作,这也是高速交通安全的重要保障。这项工作需要对机电设备的运行环境和工作参数等多种状态数据进行实时采集。传统的人工观测与采集方式存在工作低下,人工成本较高的问题。

因此,研究人员开始尝试将先进的传感器技术与无线通信技术应用到高速公路机电设备监测领域。例如,徐碧

赢等^[1]提出了基于ZigBee的终端采集设备,采用传感器和通讯模块构建成建立监控网络,在缩减所需人力物力的同时保证了采集的安全可靠性。但是该系统仅完成了数据的直接采集、传输与显示,对采集信号的没有分析处理。徐红辉^[2]提出了一种高速公路机电设备运行状态无线监测方法,利用主特征向量描述系统运行状态,从而提高监测准确率。随着人工智能技术的进步,各种智能化监测系统被应用到工业领域。王振祥等^[3]在上述主特征向量分析的基础上,提出了一种基于无线射频和BP神经网络的高速公路机电设备运行故障智能识别方法。该方法采用多维传感器进行数据采集,并采用BP神经网络分类器实现故障智能识别。

收稿日期:2020-12-04

* 基金项目:广东省普通高校重点科研平台和项目(2019GCZX006)资助

但是上述智能监测方法的抗干扰性和精度不够理想,无法满足实际应用需求。针对以上问题,本文通过 FPGA 主控芯片^[4]结合放大滤波电路进行机电设备传感信号的采集与调理,从硬件方面有效抑制噪声干扰。此外,利用 FPGA 加速深度学习的优势,通过先进的分层卷积深度学习^[5-7]实现故障智能识别,从软件方面进一步提高故障监测的准确度。实验结果表明,相比基于主特征向量或者 BP

神经网络的系统,该系统的在噪声干扰下的故障漏警率得到大幅降低,获得了较好的机电设备故障监测效果。

1 系统硬件电路设计

本文系统以 FPGA 为主控芯片,结合 STM32 模块对设备状态信息进行多种传感器数据采集,系统整体电路设计如图 1 所示。




图 1 系统整体电路设计

1.1 信号调理电路设计

选取了振动、温湿度、电压等传感器进行公路机电设备状态监测,其中电压传感器型号为 DL-PT202 D,数字式温湿度传感器型号为 AM2313,振动传感器型号为 801S, A/D 转换模块型号为 AD7606。为了将 A/D 转换的量程最大化,利用了差动放大电路实现 $\pm 5\text{ V}$ 的电压范围。因此,采用稳压源 TL431 提供 2.5 V 参考电压。

差动放大电中输入电压 V_{in} 和输出电压 V_{out} 之间关系如下:

$$2.5 - V_{out} = \left(2.5 - \frac{R_4}{R_2 + R_4} V_{in}\right) \cdot \frac{R_1 + R_3}{R_1} \quad (1)$$

电路的放大倍数 A 的计算方法为:

$$A = \frac{R_4}{R_2 + R_4} \cdot \frac{R_1 + R_3}{R_1} \quad (2)$$

根据电路对称原则,当 $R_1 = R_2$, $R_3 = R_4$ 时,则:

$$A = \frac{R_4}{R_1} = \frac{8}{5} \quad (3)$$

$$A = \frac{R_4}{R_2 + R_4} \cdot \frac{R_1 + R_3}{R_1} \quad (4)$$

由于差动放大电路的输出信号包含放大的高频噪声干扰,因此采用了低通滤波芯片 MAX296 在 A/D 转换之前进行噪声去除。

该模块电路的时钟频率 f_{osc} 为:

$$f_{osc} = \frac{10^5}{3C_{osc}} \quad (5)$$

其中, C_{osc} 表示所需电容大小。系统所需的时钟频率 $f_{osc} = 500\text{ kHz}$, 因此 $C_{osc} = 67\text{ pF}$ 。电容 C_{10} 就是所需的 C_{osc} , 其值约等于 67 pF , 电容 C_{11} 负责隔离信号的直流分量。

由于受到高速公路室外环境的影响,机电设备状态监测中传感器的输出信号会具有毛刺,这主要是噪声干扰导致的。RC 滤波可以将毛刺进行消除,从而避免在比较电路中出现多次键相信号,造成误判。

1.2 A/D 转换模块设计

本文系统的 A/D 转换模块选用了 16 bit 分辨率的 AD7606, 该芯片为逐次逼近型 ADC。设置 ADIN1 ~ ADIN8 为信号输入端, 信号输入范围为 $\pm 5\text{ V}$, 片内基准电压为 2.5 V , 并行接口方式。

1.3 FPGA 模块设计

该系统选用的 FPGA 处理器为成本最低、功耗最低的 Cyclone 系列^[8-9] EP2C8Q208C。FPGA 的外围电路具有电源、时钟复位等模块。

选择并行传输方式实现 STM32 与 FPGA 之间的 FIFO 读取。对不同读取地址范围, 片选引脚在 NE1 和 NOE 之间使能, 例如地址范围是 $0x60000000 \sim 0x63FFFFFF$ 时, 使能 NE1, 支持 64 MB FIFO 读取。FPGA 与 STM32 连接方式如图 2 所示。




图 2 FPGA 与 STM32 连接方式

系统软件功能主要分为 2 个部分。第 1 部分负责 A/D 读取和缓存数据,第 2 部分负责数据处理,实现故障监测,也是最重要的部分。在第 2 部分中利用分层卷积深度学习对采集到获得机电设备状态数据进行分析。通过残差网络替换传统的特征提取网络并建立候选区域的损失函数模型,实现了机电设备故障智能监测。

2 基于深度学习模型的系统故障智能监测

2.1 分层卷积深度学习模型

本模型选取深度学习表现较好的 YOLO v3^[10-11] 的 Darknet53 前 52 层作为特征提取层,其结合了 Darknet-19 以及其他新型残差网络的优势^[12]。模型输入为 A/D 转换模块的输出信号,具体为振动、温湿度、电压等传感器的采集数据,由 FPGA FIFO 读取获得。利用连续的 3×3 和 1×1 规模的卷积层进行组合,分层网络结构如表 1 所示。

表 1 分层网络结构

	类型	尺寸	过滤	步长
1×	卷积	3×3	32	1
	卷积	3×3	64	2
	卷积	1×1	32	1
	卷积	3×3	64	1
	残差	—	—	—
2×	卷积	3×3	256	2
	卷积	1×1	64	1
	卷积	3×3	128	1
	残差	—	—	—
8×	卷积	3×3	256	2
	卷积	1×1	128	1
	卷积	3×3	256	1
	残差	—	—	—
8×	卷积	3×3	512	2
	卷积	1×1	256	1
	卷积	3×3	512	1
	残差	—	—	—
4×	卷积	3×3	1024	2
	卷积	1×1	512	1
	卷积	3×3	1024	1
	残差	—	—	—

模型卷积核在浅层提取的为浅层特征,而随着卷积层深度加深,提取的细节信息更加充分。提取的特征信号的大小会随着层数加深变得更小,直接使用最后一层的卷积特征有利于故障信号的识别,但对监测振动故障则不适合。综上,本文选择 Res5 生成的特征信号作为 F1;选择 F1 经过 up-sample 操作然后与 Res3 生成的特征信号联结作为 F2;选择 F2 经过 up-sample 与 Res2 生成的特征矩阵

作为 F3,分别输入到候选区域网络,同时也作为监测子网的输入。

2.2 损失函数

故障智能监测模型的关键是损失函数计算。由于机电设备故障大致可分为电气和机械故障两类,因此为了进一步降低噪声对故障监测模型的干扰,根据上述分层模型将损失函数分为了两部分。

1) 候选区域损失函数:候选区域损失函数分为两部分^[13]:分类损失 L_{cls} 和边框回归损失 L_{reg} ,损失函数如下:

$$L_n(\{p_i^n\} \{t_i^n\} | \mathbf{M}) = L_{\text{cls}}(p_i^n, p_i^{*n}) + \lambda L_{\text{reg}}(t_i, t_i^{*n}) \quad (6)$$

式中: i 代表小批次处理中第 i 个候选框索引; p_i 代表第 i 个候选框为机电设备故障的概率,如果 i 是监测到故障,则 p_i^* 为 1,反之为 0。式(7)和(8)为分类损失函数 L_{cls} 和回归损失函数 L_{reg} :

$$L_{\text{cls}}(p_i, p_i^*) = -\log[p_i p_i^* + (1 - p_i^*)(1 - p_i)] \quad (7)$$

$$L_{\text{reg}}(t_i, t_i^*) = \frac{1}{3} R(t_i - t_i^*) \quad (8)$$

式中: R 表示 smooth_{L1} 函数^[14]; $t_i = \{t_x, t_y, t_w, t_h\}$ 预测参数化候选框的坐标; $t_i^* = \{t_x^*, t_y^*, t_w^*, t_h^*\}$ 对应的是真实边界的坐标。

候选区域的 3 条支路总损失函数为:

$$L(\mathbf{M}) = \sum_{n=1}^3 \sum_{i \in S^n} \eta_n l_n(\{p_i^n\} \{t_i^n\}) \quad (9)$$

式中: $\mathbf{M}$ 为候选区域网络的学习参数^[15]; n 代表支路数, $n \in [1, 3]$; η_n 代表第 n 条支路损失权重; S^n 为第 n 条支路的训练样本集。

2) 监测子网络损失函数:监测子网络对于目标监测任务损失函数与候选区域定义类似,设 $\mathbf{M}'$ 为监测子网络所需要学习的参数,公式如下:

$$l_k(\{p_i^k\} \{t_i^k\}) = L_{\text{cls}}(p_i, p_i^*) + \lambda L_{\text{reg}}(t_i, t_i^*) \quad (10)$$

$$L(\mathbf{M}') = \sum_{k=1}^3 \sum_{i \in S^k} \gamma_k l_k(\{p_i^k\} \{t_i^k\} | \mathbf{M}') \quad (11)$$

式中: p_i^k 是 0 或 1,代表第 i 个建议区域为设备故障的概率; t_i 为向量,代表预测的候选框坐标。 t_i^* 是对应的真实边界的坐标向量, $k \in [1, 3]$,代表监测网络的第 k 条支路; γ_k 代表第 k 条支路的损失权重; S^k 为第 k 条支路的训练样本集;

结合上述分析,判断机电设备故障的监测网络模型的总体损失函数为:

$$L(\mathbf{M}, \mathbf{M}') = L(\mathbf{M}) + L(\mathbf{M}') \quad (12)$$

3 实验结果与分析

系统测试过程中首先安装振动、温湿度、电压等采集传感器,电压传感器型号为 DL-PT202 D,数字式温湿度传感器型号为 AM2313,振动传感器型号为 801S。然后连接

调理电路,再连接 A/D 转换模块,A/D 转换模块型号为 AD7606。最后与 FPGA 相连,FPGA 型号为 Cyclone 系列 EP2C8Q208C。整体系统实物如图 3 所示。




图 3 系统实物

3.1 系统通信测试

首先对 FPGA 是否成功读取 A/D 模块数据进行验证。主要利用 Altera 公司的 Quartus II 软件进行逻辑分析,前两个通道的参考电压分别为 2.5 和 1.2 V,第 3 个通道接地,其余悬空。经过计算,各个通道的电压值均约等于其参考电压,也就是说 FPGA 读取成功,逻辑分析结果如图 4 所示。




图 4 逻辑分析结果

3.2 故障监测实例分析

选取某高速公路维护段的 2 台 PLC 控制箱为现场故障监测对象。电压、振动等多种传感器采集了 10 周内的 1 000 份有效样本,样本运行状态参数如表 2 所示。

表 2 样本运行状态参数

设备运行状态	样本数量
正常	750
异常	250

为验证本文故障智能监测模型的有效性,选取漏警率作为评估指标,在相同的实验环境和测试样本下,与基于主特征向量和基于 BP 神经网络的公路机电设备故障监测系统进行了对比分析。漏警率的计算方式如下:

$$\text{漏警率} = 1 - \frac{\text{判断为异常的异常数}}{\text{异常数}} \quad (13)$$

两种不同监测系统的漏警率对比结果如表 3 所示。

表 3 两种不同监测系统的漏警率对比结果

告警次数	漏警率/%		
	主特征向量	BP 神经网络	分层卷积深度学习
150	0.48	0.31	0.16
250	0.49	0.33	0.16
350	0.51	0.32	0.15
450	0.50	0.34	0.16
550	0.52	0.34	0.15

由表 3 可以看出,本文故障智能监测系统在不同告警次数时,漏警率明显一直低于其他两种模型,且较低效果较为明显,分别降低约 70% 和 50% 左右,最终的漏警率数值稳定在 0.16%。这说明有效抑制了噪声干扰,实现了准确的设备运行状态监测。

4 结 论

本文采用 FPGA 开发板设计了一种基于分层卷积深度学习的高速公路机电设备智能监测系统。现场测试结果表明,系统硬件设计能够确保 FPGA 正确读取 A/D 模块数据,逻辑分析结果较为准确;10 周 1 000 份样本测试结果得出,该系统的漏警率仅为 0.16%,有效避免了噪声的干扰。但是,该系统仍有不足之处,例如测试样本数量不够大、机电设备种类单一的问题,后续考虑使用并行计算能力更强的 FPGA 在更多种类机电设备上进行进一步验证。

参考文献

- [1] 徐碧赢,孙慧.基于 ZigBee 的终端采集设备的研究与实现[J].电子设计工程,2018,26(4):150-153.
- [2] 徐红辉.高速公路机电设备运行状态无线监测方法仿真[J].计算机仿真,2019,36(11):121-125.
- [3] 王振祥,邵宗翰.基于无线射频的高速公路机电设备运行故障智能识别方法[J].自动化与仪器仪表,2019(11):52-55.
- [4] 周兴达,蒋永恒,王帅,等.基于 FPGA 的无人机 BLDC 电调模块设计与实现[J].电子设计工程,2019,27(3):169-172,177.
- [5] REN M J, LIN F U, XIAO G B, et al. Non-lambertian photometric stereo vision algorithm based on a multi-scale convolution deep learning architecture[J]. Entia Sinica Technologica, 2020, 50(3):323-334.
- [6] WANG H, ZHU D S, TANG W. An algorithm of strip surface defect detection based on grayscale projection[J]. Journal of Northeastern University(Natural Ence), 2008, 29(3):375-377.
- [7] 杨涵.基于深度学习的人脸识别算法研究[J].电子设计工程,2019,27(19):155-159.
- [8] 郭天伟,齐金山,杨海东,等.基于深度学习与特征融合

- 的人脸识别算法[J].微型电脑应用,2020,36(11):5-8,22.
- [9] 杨坤,王志斌.基于 FPGA 的数字程控中频放大电路设计[J].国外电子测量技术,2020,39(2):111-117.
- [10] ZHANG Q X, LIN G H, ZHANG Y M, et al. Wildland forest fire smoke detection based on faster R-CNN using synthetic smoke images [J]. Procedia Engineering, 2018, 211:441-446.
- [11] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39 (6): 1137-1149.
- [12] LYU Y, ZHANG C, YUN W, et al. The delineation and grading of actual crop production units in modern smallholder areas using RS data and mask R-CNN[J]. Remote Sensing, 2020, 12(7):1074-1086.
- [13] XUE Y, HUANG N, TU S, et al. Immature mango detection based on improved YOLOv2[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(7):173-179.
- [14] 安华,王国锋,王喆,等.基于深度学习理论的刀具状态监测及剩余寿命预测方法[J].电子测量与仪器学报,2019,33(9):64-70.
- [15] 钟惠英.基于深度学习的动态手势识别方法[J].电子测量技术,2020,43(2):128-132.

作者简介

郑桔浩,本科,中级工程师,主要研究方向为交通运输工程。

E-mail: vb6985@163.com