



(12)发明专利申请

(10)申请公布号 CN 111080612 A

(43)申请公布日 2020.04.28

(21)申请号 201911272607.4

G06N 3/04(2006.01)

(22)申请日 2019.12.12

G06N 3/08(2006.01)

(71)申请人 哈尔滨市科佳通用机电股份有限公司

地址 150060 黑龙江省哈尔滨市经开区哈平路集中区潍坊路2号

(72)发明人 庞博

(74)专利代理机构 哈尔滨市松花江专利商标事务所 23109

代理人 时起磊

(51)Int.Cl.

G06T 7/00(2017.01)

G06K 9/32(2006.01)

G06K 9/54(2006.01)

G06K 9/62(2006.01)


权利要求书2页 说明书5页 附图5页

(54)发明名称

一种货车轴承破损检测方法

(57)摘要

一种货车轴承破损检测方法,属于货运列车检测技术领域。本发明是为了解决基于人工的货车轴承破损检测存在耗时长、效率低的问题,以及基于图像的货车轴承破损检测存在准确率低的问题。本发明采集图像并提取出货车轴承区域对应的图像,作为待识别的货车轴承区域图像;将待识别的货车轴承区域图像输入到训练好的Mask-RCNN网络中进行推测,获取每张图片的预测结果,包括:多个ROI的类别、边框坐标、分割坐标以及置信度分数;结合故障位置先验信息以及轴承辅助类别信息对故障的置信度分数进一步实现货车轴承破损的检测。主要用于货车轴承破损检测。



1. 一种货车轴承破损检测方法,其特征在于,包括以下步骤:

采集图像并提取出货车轴承区域对应的图像,作为待识别的货车轴承区域图像;将待识别的货车轴承区域图像输入到训练好的Mask-RCNN网络中进行推测,获取每张图片的预测结果,包括:多个ROI的类别、边框坐标、分割坐标以及置信度分数;结合故障位置先验信息以及轴承辅助类别信息对故障的置信度分数进一步实现货车轴承破损的检测;

所述练好的Mask-RCNN网络的损失函数如下:

$$L=L_{cls}+L_{box}+L_{mask}$$

其中,L表示整体损失, L_{cls} 、 L_{box} 和 L_{mask} 分别表示类别损失、边框损失和分割损失;

$$L_{cls}=-\frac{1}{N}\sum_{i=1}^N w_i \sum_{k=1}^K p_{ik}^* \log(p_{ik})$$

其中,N表示样本数目,K表示类别数目, p_{ik}^* 表示样本i为类别k的真实概率, p_{ik} 表示模型预测样本i为类别k的输出概率; w_i 表示样本i的权重因子,当样本i的真实类别不为故障类别时 $w_i=1$,否则其计算公式如下所示:

$$w_i=\frac{N_{pos}+N_{neg}}{N_{pos}}=\frac{N}{N_{pos}}$$

其中, N_{pos} 与 N_{neg} 分别表示正样本数目与负样本数目。

2. 根据权利要求1所述的一种货车轴承破损检测方法,其特征在于,所述Mask-RCNN网络分为三部分:骨干网、RPN网络和前端网络;

所述骨干网络采取ResNet50-FPN的结构,提取输入图像中不同层次的特征,并输出特征图金字塔;

所述RPN网络对骨干网络输出的特征图金字塔,首先做 3×3 的卷积变换,然后对特征图金字塔提取ROI,作为RPN网络的输出;

在进入前端网络之前,对ROI采取ROIAlign变换,将结果输入到前端网络中;

所述前端网络产生类别、边框以及分割的最后结果。

3. 根据权利要求1或2所述的一种货车轴承破损检测方法,其特征在于,所述练好的Mask-RCNN网络确定过程包括以下步骤:

采集图像并提取出货车轴承区域对应的图像,根据得到的货车轴承区域图像建立原始数据集,包括故障数据集和正常数据集,故障数据集作为正样本集,正常数据集作为负样本集;

对原始数据集中的样本进行标注;

所述对原始数据集中的样本进行标注的过程包括:

对真实故障进行的标注、对固定噪音进行的标注、对轴承轮廓进行的标注;

所述固定噪音包括轴承上编号和轴承上的锁。

4. 根据权利要求3所述的一种货车轴承破损检测方法,其特征在于,所述的故障数据集的构建过程中需要进行图像增强操作;图像增强操作包括对比度增强、锐度变化、直方图均衡化、模糊处理、平移、旋转、高斯噪音、缩放,以及对比度增强、锐度变化、直方图均衡化、模糊处理、平移、旋转、高斯噪音、缩放的随机组合操作。

5. 根据权利要求3所述的一种货车轴承破损检测方法,其特征在于,所述提取出货车轴

承区域对应的图像的过程包括以下步骤：

根据货车的轴距以及货车轴承区域所在位置先验信息，确定货车轴承区域并提取出货车轴承区域图像。

6. 根据权利要求5所述的一种货车轴承破损检测方法，其特征在于，所述采集图像的过程是通过线阵相机进行的。

一种货车轴承破损检测方法

技术领域

[0001] 本发明涉及一种货车轴承破损检测方法。属于货运列车检测技术领域。

背景技术

[0002] 铁路货车一直一来承担着重要的运输角色,铁路部门需要经常对铁路货车进行安全检查,以保证铁路货车的安全稳定运行。在铁路货车的检测中,为了不影响铁路货车的正常行驶和调度安排,同时为了提高检测效率,目前大多是依靠人工查看图像的检测方式进行检测的,这样会消耗大量的人力成本和时间成本,而且这种检测技术完全依赖于检测人员的责任心和精力,一旦查看的图像过多,其检测错误率和漏检率就会明显上升。

[0003] 在对铁路货车的例行检查中,轴承破损检查是一项重要的内容。在基于图像的轴承破损的检测技术中,由于轴承的部件结构在轴承端面上十分不易辨认,所以现有的基于图像的对货车轴承破损检测技术准确率很低,不能实现自动化检测,所以现有的情况下大多是采用人工检查辨认的方式。同时由于轴承端面一致都是暴露在空气中的,由于风沙天气等因素的影响,使得基于图像的检测技术难上加难。例如轴承端面会出现尘土、污渍的影响,导致图像十分不易辨认和识别,所以现有的基于图像的检测技术的准确率极低,有待于进一步改进。

发明内容

[0004] 本发明是为了解决基于人工的货车轴承破损检测存在耗时长、效率低的问题,以及基于图像的货车轴承破损检测存在准确率低的问题。

[0005] 一种货车轴承破损检测方法,包括以下步骤:

[0006] 采集图像并提取出货车轴承区域对应的图像,作为待识别的货车轴承区域图像;将待识别的货车轴承区域图像输入到训练好的Mask-RCNN网络中进行推测,获取每张图片的预测结果,包括:多个ROI的类别、边框坐标、分割坐标以及置信度分数;结合故障位置先验信息以及轴承辅助类别信息对故障的置信度分数进一步实现货车轴承破损的检测;

[0007] 所述练好的Mask-RCNN网络的损失函数如下:

$$[0008] \quad L = L_{cls} + L_{box} + L_{mask}$$

[0009] 其中,L表示整体损失, L_{cls} 、 L_{box} 和 L_{mask} 分别表示类别损失、边框损失和分割损失;

$$[0010] \quad L_{cls} = -\frac{1}{N} \sum_{i=1}^N w_i \sum_{k=1}^K p_{ik}^* \log(p_{ik})$$

[0011] 其中,N表示样本数目,K表示类别数目, p_{ik}^* 表示样本i为类别k的真实概率, p_{ik} 表示模型预测样本i为类别k的输出概率; w_i 表示样本i的权重因子,当样本i的真实类别不为故障类别时 $w_i = 1$,否则其计算公式如下所示:

$$[0012] \quad w_i = \frac{N_{pos} + N_{neg}}{N_{pos}} = \frac{N}{N_{pos}}$$

- [0013] 其中, N_{pos} 与 N_{neg} 分别表示正样本数目与负样本数目。
- [0014] 进一步地,所述Mask-RCNN网络分为三部分:骨干网、RPN网络和前端网络;
- [0015] 所述骨干网络采取ResNet50-FPN的结构,提取输入图像中不同层次的特征,并输出特征图金字塔;
- [0016] 所述RPN网络对骨干网络输出的特征图金字塔,首先做 3×3 的卷积变换,然后对特征图金字塔提取ROI,作为RPN网络的输出;
- [0017] 在进入前端网络之前,对ROI采取ROIAlign变换,将结果输入到前端网络中;
- [0018] 所述前端网络产生类别、边框以及分割的最后结果。
- [0019] 进一步地,所述练好的Mask-RCNN网络确定过程包括以下步骤:
- [0020] 采集图像并提取出货车轴承区域对应的图像,根据得到的货车轴承区域图像建立原始数据集,包括故障数据集和正常数据集,故障数据集作为正样本集,正常数据集作为负样本集;
- [0021] 对原始数据集中的样本进行标注;
- [0022] 所述对原始数据集中的样本进行标注的过程包括:
- [0023] 对真实故障进行的标注、对固定噪音进行的标注、对轴承轮廓进行的标注;
- [0024] 所述固定噪音包括轴承上编号和轴承上的锁。
- [0025] 进一步地,所述的故障数据集的构建过程中需要进行图像增强操作;图像增强操作包括对比度增强、锐度变化、直方图均衡化、模糊处理、平移、旋转、高斯噪音、缩放,以及对对比度增强、锐度变化、直方图均衡化、模糊处理、平移、旋转、高斯噪音、缩放的随机组合操作。
- [0026] 进一步地,所述提取出货车轴承区域对应的图像的过程包括以下步骤:
- [0027] 根据货车的轴距以及货车轴承区域所在位置先验信息,确定货车轴承区域并提取出货车轴承区域图像。
- [0028] 进一步地,所述采集图像的过程是通过线阵相机进行的。
- [0029] 有益效果:
- [0030] 1、本发明能够实现基于图像自动识别的方式代替人工检测,能够自动识别车辆故障并报警,利用本发明无需人工逐张浏览图片,人工只需对报警图片进行故障确认即可完成检车作业,可节省大量的动态检车人员,提高作业效率。相比现有的人工检测,检测效率至少提高数十倍,并且图像的数量增加,效率还会进一步提高;而且利用本发明进行检测,作业标准统一,不再受人员素质和责任心影响,能够有效提高作业质量,能够极大的降低漏检率和误检率,利用本发明进行检测的漏检率几乎为0。
- [0031] 2、本发明的故障检测方法比传统的手工标准特征提取的机器视觉检测方法具有灵活性高和鲁棒性好的优点。

附图说明

- [0032] 图1为训练阶段流程示意图;
- [0033] 图2为目标区域粗定位示意图;
- [0034] 图3为样本标注示例图;
- [0035] 图4为Mask RCNN网络结构图;

[0036] 图5为货车轴承破损检测阶段流程示意图。

具体实施方式

[0037] 具体实施方式一：

[0038] 本实施方式所述的一种货车轴承破损检测方法，实施过程分为两大阶段：训练阶段和推理阶段。

[0039] 1、训练阶段，如图1所示：

[0040] 1.1、图像收集

[0041] 采用线阵相机，即线扫描相机，进行图像采集，通过被测物的移动速度计算线阵相机的拍摄频率，进行连续的多次拍照，将所拍下的多幅“条”形图像，合并成一张完整的图，这样可实现无缝拼接，生成视野大、精度高的二维图像。

[0042] 1.2、目标区域粗定位

[0043] 根据货车的轴距以及货车轴承区域所在位置等先验信息，从二维图像中确定货车轴承区域并提取出货车轴承区域图像，以此减少计算量并提高识别的速度和精度。该过程如图2所示。

[0044] 1.3、样本集构建

[0045] 1.3.1、获取原始样本集

[0046] 根据得到的货车轴承区域图像建立原始数据集，包括小批量的故障数据集（正样本集）和大批量的正常数据集（负样本集）。

[0047] 1.3.2、数据增强

[0048] 本发明对于小批量的故障数据集采取了图像增强方法，包括对比度增强、锐度变化、直方图均衡化、模糊处理、平移、旋转、高斯噪音、缩放等处理手段。

[0049] 1.3.3、样本标注

[0050] 在样本标注时，针对图像中发生破损的位置采用Labelme标注工具对故障轮廓进行标注，并将标签命名为bad；除对真实故障（图3中红色标注的bad）进行标注外，在轴承图像中经常会出现一些对最后影响故障检测的施封锁连接处和轴承盖上铸造编码两类干扰项，这两类干扰会在检测时造成很多误故障识别，因此还对图像这两类干扰项，也就是图像中的固定噪音的外轮廓进行了标注，如图3中，轴承上编号标签为number类别和锁标签为lock类别都属于固定噪音，对其外轮廓标注可提高模型的准确率。除此之外，还对轴承的轮廓进行了标注，轴承轮廓标注如图3中outline类别在图像中白色虚线所示，以此获取模型输出故障与轴承轮廓的相对位置，进而结合故障可能发生位置的先验信息对模型输出的故障分数进行提权或降权计算。

[0051] 1.4、改进损失函数

[0052] 本发明使用了Mask-RCNN网络，并在其原有的网络的基础上，对其损失函数进行了改进，以此解决模型训练过程中存在的大量负样本带来的样本不均衡问题。Mask RCNN网络的原始整体损失函数如下所示：

[0053] $L = L_{cls} + L_{box} + L_{mask}$

[0054] 其中，L表示整体损失， L_{cls} 、 L_{box} 和 L_{mask} 分别表示类别损失、边框损失和分割损失。本发明对Mask RCNN网络的损失函数改进只针对于 L_{cls} ，其原始计算公式如下所示：

$$[0055] \quad L_{cls} = -\frac{1}{N} \sum_{i=1}^N \sum_{k=1}^K p_{ik}^* \log(p_{ik})$$

[0056] 其中,N表示样本数目,K表示类别数目, p_{ik}^* 表示样本i为类别k的真实概率, p_{ik} 表示模型预测样本i为类别k的输出概率。

[0057] 本发明在原 L_{cls} 的基础上,增加了权重因子,对故障类别的损失进行放大,其公式如下所示:

$$[0058] \quad L_{cls} = -\frac{1}{N} \sum_{i=1}^N w_i \sum_{k=1}^K p_{ik}^* \log(p_{ik})$$

[0059] 其中, w_i 表示样本i的权重因子,当样本i的真实类别不为故障类别时 $w_i=1$,否则其计算公式如下所示:

$$[0060] \quad w_i = \frac{N_{pos} + N_{neg}}{N_{pos}} = \frac{N}{N_{pos}}$$

[0061] 其中, N_{pos} 与 N_{neg} 分别表示正样本数目与负样本数目。

[0062] 如图4所示,本发明采用的Mask-RCNN具体网络结构可分为三部分:

[0063] 1.4.1、骨干网络

[0064] 骨干网络采取ResNet50-FPN的结构,提取输入图像中不同层次的特征,并输出特征图金字塔。

[0065] 1.4.2、RPN网络

[0066] RPN网络对骨干网络输出的特征图金字塔,首先做 3×3 的卷积变换,其目的是进一步整合特征图信息,接下来RPN网络对特征图金字塔提取ROI(兴趣区域),作为RPN网络的输出。

[0067] 1.4.3、前端网络

[0068] RPN网络输出的ROI大小不一,因此在进入前端网络之前,对ROI采取ROIAlign变换,将其结果输入到前端网络中,由前端网络产生类别、边框以及分割的最后结果。

[0069] 1.5、测试集上验证

[0070] 在测试集合上验证Mask-RCNN网络的模型准确率,并得到最终的Mask-RCNN网络训练权重。

[0071] 2、推测阶段的具体实施方式如图5所示:

[0072] 2.1、图像采集

[0073] 此步骤与训练阶段的图像采集过程相同。

[0074] 2.2、目标区域粗定位

[0075] 此步骤与训练阶段的图像采集过程相同,得到待识别的货车轴承区域图像。

[0076] 2.3、模型推理

[0077] 将训练阶段得到的Mask-RCNN网络权重加载到内存中,建立推测模型。

[0078] 将待识别的货车轴承区域图像输入到Mask-RCNN网络中进行推测,并获取每张图片的预测结果,包括:多个ROI的类别、边框坐标、分割坐标以及置信度分数。

[0079] 2.4、进行检测

[0080] 对预测结果,结合故障位置先验信息以及轴承辅助类别信息对故障的置信度分数

进行提权或降权处理。

[0081] 2.5、生成故障码

[0082] 根据检测结果生成故障码,并上传至报警平台,交由工作人员进行二次审核。




图1




图2



图3




图4




图5