



# (12)发明专利

(10)授权公告号 CN 111091554 B

(45)授权公告日 2020.08.28

(21)申请号 201911278053.9

G06T 5/00(2006.01)

(22)申请日 2019.12.12

(56)对比文件

(65)同一申请的已公布的文献号

CN 107292870 A,2017.10.24

申请公布号 CN 111091554 A

CN 103049762 A,2013.04.17

(43)申请公布日 2020.05.01

CN 109448006 A,2019.03.08

(73)专利权人 哈尔滨市科佳通用机电股份有限公司

JP H07298249 A,1995.11.10

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

周云燕.基于图像分析理论的机械故障诊断研究.《中国博士学位论文全文数据库 信息科技辑》.2009,

(72)发明人 付德敏

Yuanyi Zeng, Xiaoyu Chen, Yi Zhang等

(74)专利代理机构 哈尔滨市松花江专利商标事务所 23109

.Dense-U-Net: densely connected convolutional network for semantic segmentation with a small number of samples.《SPIE digital library》.2019,

代理人 杨立超

审查员 方源

(51)Int.Cl.

G06T 7/00(2017.01)

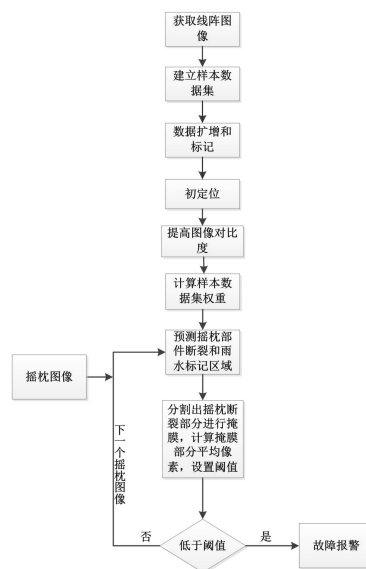
权利要求书3页 说明书6页 附图5页

(54)发明名称

铁路货车摇枕断裂故障图像识别方法

(57)摘要

铁路货车摇枕断裂故障图像识别方法,本发明涉及铁路货车故障图像识别方法。本发明的目的是为了解决现有铁路货车摇枕断裂故障检测准确率低及稳定性差的问题。过程为:步骤一、建立样本数据集;步骤二、对摇枕部件的区域进行初定位;步骤三、对初步截取出摇枕部件的区域图像进行自适应的提高对比度,使初步截取出摇枕部件的区域图像亮暗程度相同;步骤四、计算样本数据集权重;步骤五、将真实过车图像输入U-Dense型深度学习网络,基于步骤四得到的样本数据集权重,判别摇枕断裂故障。本发明用于摇枕断裂故障图像识别领域。



1. 铁路货车摇枕断裂故障图像识别方法, 其特征在于: 所述方法具体过程为:

步骤一、建立样本数据集;

步骤二、对摇枕部件的区域进行初定位;

步骤三、对初步截取出摇枕部件的区域图像进行自适应的提高对比度, 使初步截取出摇枕部件的区域图像亮暗程度相同;

步骤四、计算样本数据集权重;

步骤四一、采用随机方式初始化权重系数;

步骤四二、将样本数据进行灰度归一化处理, 即将样本数据灰度值归一化至0到1的范围内; 将归一化后的数据作为输入数据, 输入到U-Dense型深度学习网络中, 进行数据变换, 找到最优的权重系数的具体过程为:

U-Dense型深度学习网络包括卷积、池化、最大池化、批标准化和激活函数操作;

将样本数据进行灰度归一化处理, 即将样本数据灰度值归一化至0到1的范围内; 将归一化后的数据作为输入数据, 输入到U-Dense型深度学习网络中, 初始化权重, 输出预测图像, 将预测图像与真实标签图像进行差分对比, 并对交叉熵损失函数进行改进, 即公式 (1):

$$L = w_d * L_d + w_c * L_c \quad (1)$$

$$L_d = E[(-\ln(d_i))^{\gamma_d}]$$

$$L_c = w_l (-\ln(p_l(x)))^{\gamma_c}$$

$$w_l = \left( \frac{\sum_k f_k}{f_l} \right)^{0.5}$$

其中,  $L$  表示改进的损失函数,  $d_i$  表示Dice函数损失,  $L_c$  表示指数交叉熵损失函数,  $L_d$  表示指数log Dice损失,  $w_d$  表示log Dice损失的权重,  $w_c$  表示指数交叉熵损失的权重,  $E[\cdot]$  表示交叉熵损失,  $w_l$  表示权重;  $p_l(x)$  表示像素的预测概率值;  $\gamma_d, \gamma_c$  表示  $L_d, L_c$  指数交叉熵损失函数的权重;  $i$  表示标签,  $p_l$  表示当前标签的概率,  $f_k$  表示标签  $k$  出现的频率,  $f_l$  表示标签  $l$  出现的频率;

通过损失函数计算损失值, 通过优化器Adam进行优化权重;

如下公式 (2) 所示:

$$W = W_i - \eta \frac{\partial L}{\partial W} \quad (2)$$

式中,  $W$  为权重,  $W_i$  为上一次的权重或者初始权重,  $\eta$  为学习率;

根据公式 (1) 求出  $L$  带入公式 (2) 计算得到新的权重系数, 将权重系数进行更新, 完成一次训练迭代; 重复执行步骤四一至步骤四二, 将全部图像完成固定次数的迭代, 直到找到最优的权重系数;

步骤五、将真实过车图像输入U-Dense型深度学习网络, 基于步骤四得到的样本数据集权重, 判别摇枕断裂故障。

2. 根据权利要求1所述铁路货车摇枕断裂故障图像识别方法, 其特征在于: 所述步骤一中建立样本数据集; 具体过程为:

在铁路轨道两侧搭建成像设备, 货车通过设备后, 获取灰度图像;

建立样本数据集, 样本数据集包括: 灰度图像数据集与标记图像数据集;

所述灰度图像集为设备拍摄的灰度图像；

所述标记图像集为摇枕部件的分割图像，将图像标记为断裂处和雨水两类，通过人工标记的方式获取；

灰度图像数据集与标记图像数据集之间是一一对应的，即每个灰度图像对应一个标记图像；

对样本数据集进行数据扩增，扩增形式包括图像的旋转、平移、缩放、镜像操作。

3. 根据权利要求1或2所述铁路货车摇枕断裂故障图像识别方法，其特征在于：所述步骤二中对摇枕部件的区域进行初定位；具体过程为：

根据硬件设备、轴距信息及相關位置先验知识，从图像中初步截取出摇枕部件的区域。

4. 根据权利要求1所述铁路货车摇枕断裂故障图像识别方法，其特征在于：所述批标准化公式如下：

$$\begin{aligned}\mu_B &\leftarrow \frac{1}{m} \sum_{i=1}^m x_i \\ \sigma_B^2 &\leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \\ \hat{x}_i &\leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}}\end{aligned}$$

式中， $\mu_B$ 为对m个输入数据的集合 $B = \{x_1, x_2, \dots, x_m\}$ 求均值， $x_i$ 为第i个数据， $\hat{x}_i$ 为对输入数据进行均值为0，方差为1的正规化， $\sigma_B^2$ 为对m个输入数据的集合 $B = \{x_1, x_2, \dots, x_m\}$ 求方差 $\sigma_B^2$ ，m为输入数据的个数； $\varepsilon$ 是一个值。

5. 根据权利要求4所述铁路货车摇枕断裂故障图像识别方法，其特征在于：所述U-Dense激活函数是分段线性函数，所有的负值都是0，正值不变，激活函数如公式：

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

式中，x为自变量。

6. 根据权利要求5所述铁路货车摇枕断裂故障图像识别方法，其特征在于：所述U-Dense型深度学习网络步骤如下：

深度模块：输入N通道卷积特征图像，进行BatchNorm操作，后接ReLU激活函数，使用N通道的 $3 \times 3$ 大小的卷积核进行卷积，再次进行BatchNorm操作，后接ReLU激活函数，最后再接N通道的 $3 \times 3$ 大小的卷积核进行卷积，后接ReLU激活函数；

所述U-Dense型深度学习网络模型包括编码单元、解码单元和编码解码单元，所述编码单元采用4个下采样的编码单元，所述解码单元包括4个上采样的解码单元；

第一编码单元包含32通道的 $1 \times 1$ 大小的卷积核进行卷积，并使用BatchNorm函数正规化，后接ReLU激活函数，然后接DenseBlock，最后进行最大池化；

所述DenseBlock为深度模块；

第二编码单元包含64通道的DenseBlock，后接最大池化；

第三编码单元包含128通道的DenseBlock,后接最大池化;

第四编码单元包含256通道的DenseBlock,后接最大池化;

编码解码单元包含512通道的DenseBlock;

第一解码单元包含256通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第四编码单元融合;

第二解码单元包含128通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第三编码单元融合;

第三解码单元包含64通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第二编码单元融合;

第四解码单元包含32通道的 $1 \times 1$ 大小的卷积核进行卷积,后接ReLu激活函数,并与第一编码单元融合;

第一编码单元的输出作为第二编码单元的输入,第二编码单元的输出作为第三编码单元的输入,第三编码单元的输出作为第四编码单元的输入;

第四编码单元的输出作为编码解码单元的输入;编码解码单元的输出作为第一解码单元的输入,第一解码单元的输出作为第二解码单元的输入,第二解码单元的输出作为第三解码单元的输入,第三解码单元的输出作为第四解码单元的输入;

输出变换后的数据。

7.根据权利要求6所述铁路货车摇枕断裂故障图像识别方法,其特征在于:所述步骤五中将真实过车图像输入U-Dense型深度学习网络,基于步骤四得到的样本数据集权重,判别摇枕断裂故障;具体过程为:

将真实过车图像使用U-Dense型深度学习网络进行数据变换后,使用训练好的权重系数,预测出摇枕断裂区域和雨水区域,根据标记的像素值得到预测后的断裂部分的区域,将图像进行二值化,使得断裂部分的像素值为1,非断裂部分的像素值为0;对像素值为1的部分对照原图进行掩膜,判断掩膜区域的平均像素,设定像素阈值,若掩膜部分像素值小于设定阈值,则对此部分摇枕进行故障报警;若掩膜部分像素值大于等于设定阈值,则处理下一张摇枕图像。

## 铁路货车摇枕断裂故障图像识别方法

### 技术领域

[0001] 本发明涉及铁路货车故障图像识别方法。

### 背景技术

[0002] 摇枕是铁路车辆(客车、货车)行走部分中第二大铸钢件,是直接影响列车行车安全的重要零部件之一。根据摇枕受力情况,中部弯矩最大,因此弯曲应力最大,摇枕中央部位裂纹发生率最高。

[0003] 货车摇枕断裂故障是一种危及行车安全的故障,在摇枕断裂的故障检测中,采用人工检查图像的方式进行故障检测。由于检车人员在工作过程中极易出现疲劳、遗漏等人为因素可能造成漏检、错检的出现,影响行车安全。

### 发明内容

[0004] 本发明的目的是为了解决现有铁路货车摇枕断裂故障检测准确率低及稳定性差的问题,而提出铁路货车摇枕断裂故障图像识别方法。

[0005] 铁路货车摇枕断裂故障图像识别方法具体过程为:

[0006] 步骤一、建立样本数据集;

[0007] 步骤二、对摇枕部件的区域进行初定位;

[0008] 步骤三、对初步截取出摇枕部件的区域图像进行自适应的提高对比度,使初步截取出摇枕部件的区域图像亮暗程度相同;

[0009] 步骤四、计算样本数据集权重;

[0010] 步骤四一、采用随机方式初始化权重系数;

[0011] 步骤四二、将样本数据进行灰度归一化处理,即将样本数据灰度值归一化至0到1的范围内;将归一化后的数据作为输入数据,输入到U-Dense型深度学习网络中,进行数据变换,找到最优的权重系数;

[0012] 步骤五、将真实过车图像输入U-Dense型深度学习网络,基于步骤四得到的样本数据集权重,判别摇枕断裂故障。

[0013] 本发明的有益效果为:

[0014] 根据图像信息进行故障的自动识别的方式可提高故障检测准确率及稳定性。近几年,深度学习与人工智能不断发展,在技术上不断成熟。因而,采用深度学习进行摇枕故障识别,可以有效提高检测准确率及稳定性。

[0015] 在铁路轨道旁搭载成像设备,货车通过设备后,获取货车两侧线阵图像。基于深度学习分割网络,对获取图像中摇枕部件的断裂处进行分割。分割后,根据先验知识使用高级图像处理算法和模式识别方法对分割区域进行故障分析,判断其是否发生断裂。对摇枕图像上发生断裂的区域进行上传报警,工作人员依据报警位置进行相应的处理,保证列车安全运行。

[0016] 本发明利用图像自动识别的方式代替人工检测,提高检测效率、准确率。

[0017] 本发明将深度学习算法应用到摇枕断裂故障自动识别中,提高整体算法的鲁棒性及精度。

[0018] 本发明改进交叉熵损失函数,减小类别不平衡的影响,提高目标识别的准确率。

### 附图说明

[0019] 图1为故障识别流程图;

[0020] 图2为权重系数计算流程图;

[0021] 图3为U-Dense型深度学习网络模型图;

[0022] 图4为DenseBlock (深度模块) 流程图;

[0023] 图5为铁路货车摇枕示意图。

### 具体实施方式

[0024] 具体实施方式一:结合图1、图5说明本实施方式,本实施方式铁路货车摇枕断裂故障图像识别方法具体过程为:

[0025] 步骤一、建立样本数据集;

[0026] 步骤二、对摇枕部件的区域进行初定位;

[0027] 步骤三、对初步截取出摇枕部件的区域图像进行自适应的提高对比度,使初步截取出摇枕部件的区域图像亮暗程度相同;

[0028] 由于各个站点的成像设备角度距离有所不同,采集到的图像的亮暗程度不同,一些图像太暗导致不能清晰的观测到摇枕的断裂区域,因此进入深度学习网络前,对图像进行自适应的提高对比度。

[0029] 步骤四、计算样本数据集权重;如图2、图3、图4;

[0030] 步骤四一、采用随机方式初始化权重系数;

[0031] 步骤四二、将样本数据进行灰度归一化处理,即将样本数据灰度值归一化至0到1的范围内;将归一化后的数据作为输入数据,输入到U-Dense型深度学习网络中,进行数据变换,找到最优的权重系数;

[0032] 步骤五、将真实过车图像输入U-Dense型深度学习网络,基于步骤四得到的样本数据集权重,判别摇枕断裂故障。

[0033] 具体实施方式二:本实施方式与具体实施方式一不同的是,所述步骤一中建立样本数据集;具体过程为:

[0034] 在铁路轨道两侧搭建成像设备,货车通过设备后,获取高清灰度图像;图像为清晰的灰度图像。由于货车部件可能受到雨水、泥渍、油渍、黑漆等自然条件或者人为条件的影响。并且,不同站点拍摄的图像可能存在差异。因此,摇枕部件图像之间千差万别。所以,在收集摇枕图像数据的过程中,要保证多样性,尽量将各种条件下的摇枕图像全部收集。

[0035] 在不同类型的转向架中,摇枕部件的形态会不同。但由于不同类型间出现的频率差别较大,某些较不常见转向架类型的摇枕部件收集较为困难。因此,将全部类型的摇枕部件统称为一类,全部按照一类来建立样本数据集。

[0036] 建立样本数据集,样本数据集包括:灰度图像数据集与标记图像数据集;

[0037] 所述灰度图像集为设备拍摄的高清灰度图像;

[0038] 所述标记图像集为摇枕部件的分割图像,由于摇枕断裂处有大量雨水的痕迹与断裂处图像相似,因此将图像标记为断裂处和雨水两类,通过人工标记的方式获取;

[0039] 灰度图像数据集与标记图像数据集之间是一一对应的,即每个灰度图像对应一个标记图像;

[0040] 样本数据集的建立虽然包括各种条件下的图像,但为提高算法的稳定性,仍需要对样本数据集进行数据扩增,扩增形式包括图像的旋转、平移、缩放、镜像等操作,每种操作都是在随机条件下进行的,这样可以最大程度的保证样本的多样性和适用性。

[0041] 其它步骤及参数与具体实施方式一相同。

[0042] 具体实施方式三:本实施方式与具体实施方式一或二不同的是,所述步骤二中对摇枕部件的区域进行初定位;具体过程为:

[0043] 根据硬件设备、轴距信息及相关位置等先验知识,从侧部相机的图像中初步截取出摇枕部件的区域。

[0044] 其它步骤及参数与具体实施方式一或二相同。

[0045] 具体实施方式四:本实施方式与具体实施方式一至三之一不同的是,所述步骤四二中将样本数据进行灰度归一化处理,即将样本数据灰度值归一化至0到1的范围内;将归一化后的数据作为输入数据,输入到U-Dense型深度学习网络中,进行数据变换,找到最优的权重系数;具体过程为:

[0046] U-Dense型深度学习网络包括卷积(convolution)、池化(Pooling)、最大池化(max-pooling)、批标准化(Batch Norm)和激活函数(Relu)作用等操作;

[0047] 卷积是一个二维的滤波器矩阵(卷积核)与一个待处理的二维图像进行逐个元素相乘再求和的操作;

[0048] 池化是将输入图像进行降维,减少像素信息,只保留重要信息;

[0049] 最大池化(max-pooling)保留了每块内的最大值;

[0050] 批标准化(Batch Norm)是进行使数据分布的均值为0,方差为1的正规化,能够调整各层的激活值分布使其拥有适当的广度。

[0051] 将样本数据进行灰度归一化处理,即将样本数据灰度值归一化至0到1的范围内;将归一化后的数据作为输入数据,输入到U-Dense型深度学习网络中,初始化权重,输出预测图像,将预测图像与真实标签图像进行差分对比,并对交叉熵损失函数进行改进,即公式(1):

$$[0052] \quad L = w_d * L_d + w_c * L_c \quad (1)$$

$$[0053] \quad L_d = E[(-\ln(d_i))^{\gamma_d}]$$

$$[0054] \quad L_c = w_1 (-\ln(p_1(x)))^{\gamma_c}$$

$$[0055] \quad w_l = \left( \frac{\sum_k f_k}{f_l} \right)^{0.5}$$

[0056] 其中,L表示改进的损失函数, $d_i$ 表示Dice函数损失, $L_c$ 表示指数交叉熵损失函数, $L_d$ 表示指数log Dice损失, $w_d$ 表示log Dice损失的权重, $w_c$ 表示指数交叉熵损失的权重, $E[\cdot]$ 表示交叉熵损失, $w_1$ 表示权重,可以通过 $w_1$ 调节类别不平衡时各类别的影响; $p_1(x)$ 表示像素的预测概率值, $\gamma_d, \gamma_c$ 表示 $L_d, L_c$ 指数交叉熵损失函数的权重, $i$ 表示标签, $p_1$ 表示当前标签的概率, $f_k$ 表示标签k出现的频率, $f_l$ 表示标签l出现的频率;

[0057] 通过损失函数计算损失值,通过优化器Adam进行优化权重;Adam优化器具有高效、占用内存小、适合大规模数据等优点。

[0058] 如下公式(2)所示:

$$[0059] \quad W = W_i - \eta \frac{\partial L}{\partial W} \quad (2)$$

[0060] 式中,W为权重, $W_i$ 为上一次的权重或者初始权重, $\eta$ 为学习率,学习率设定为0.0001,高学习率意味着在权重更新中采取更大的步骤,因此模型可能花费较少的时间来收敛于最优权重集合。但是,如果学习率过高,可能导致跳跃过大,不够精确,无法达到最佳点。

[0061] 根据公式(1)求出L带入公式(2)计算得到新的权重系数,将权重系数进行更新,完成一次训练迭代;程序将重复执行步骤四一至步骤四二,将全部图像完成固定次数的迭代,但是并不是每次迭代都要更新权重,只有损失函数更低的权重才会被更新,直到找到最优的权重系数。

[0062] 其它步骤及参数与具体实施方式一至三之一相同。

[0063] 具体实施方式五:本实施方式与具体实施方式一至四之一不同的是,所述批标准化(Batch Norm)公式如下:

$$[0064] \quad \mu_B \leftarrow \frac{1}{m} \sum_{i=1}^m x_i$$

$$[0065] \quad \sigma_B^2 \leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2$$

$$[0066] \quad \hat{x}_i \leftarrow \frac{x_i - \mu_B}{\sqrt{\sigma_B^2 + \varepsilon}}$$

[0067] 式中, $\mu_B$ 为对m个输入数据的集合 $B = \{x_1, x_2, \dots, x_m\}$ 求均值, $x_i$ 为第i个数据, $\hat{x}_i$ 为对输入数据进行均值为0,方差为1的正规化, $\sigma_B^2$ 为对m个输入数据的集合 $B = \{x_1, x_2, \dots, x_m\}$ 求方差 $\sigma_B^2$ ,m为输入数据的个数; $\varepsilon$ 是一个微小值,为了防止分母为0。

[0068] 这里对mini-batch的m个输入数据的集合 $B = \{x_1, x_2, \dots, x_m\}$ 求均值 $\mu_B$ 和方差 $\sigma_B^2$ ;然后对输入数据进行均值为0,方差为1的正规化;

[0069] 其它步骤及参数与具体实施方式一至四之一相同。

[0070] 具体实施方式六:本实施方式与具体实施方式一至五之一不同的是,所述U-Dense激活函数(The Rectified Linear Unit,修正线性单元)是分段线性函数,所有的负值都是0,正值不变,这种操作被称为单侧抑。激活函数如公式:

$$[0071] \quad \text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases}$$

[0072] 式中,x为自变量,表示神经元输入经过加权后的输出;

[0073] 相比于其他激活函数,对于线性函数而言,ReLU的表达力更强,尤其体现在深度网络中;而对于非线性函数而言,ReLU由于非负区间的梯度为常数,因此不存在梯度消失问



题,使得模型的收敛速度维持在一个稳定状态。

[0074] 其它步骤及参数与具体实施方式一至五之一相同。

[0075] 具体实施方式七:本实施方式与具体实施方式一至六之一不同的是,所述U-Dense型深度学习网络步骤如下:

[0076] 深度模块(DenseBlock):输入N通道卷积特征图像,进行BatchNorm操作,后接ReLU激活函数,使用N通道的 $3 \times 3$ 大小的卷积核进行卷积,再次进行BatchNorm操作,后接ReLU激活函数,最后再接N通道的 $3 \times 3$ 大小的卷积核进行卷积,后接ReLU激活函数;

[0077] 所述U-Dense型深度学习网络模型包括编码单元、解码单元和编码解码单元,所述编码单元采用4个下采样的编码单元,所述解码单元包括4个上采样的解码单元;

[0078] 第一编码单元包含32通道的 $1 \times 1$ 大小的卷积核进行卷积,并使用BatchNorm函数正规化,后接ReLU激活函数,然后接DenseBlock(输入N通道卷积特征图像,进行BatchNorm操作,后接ReLU激活函数,使用N通道的 $3 \times 3$ 大小的卷积核进行卷积,再次进行BatchNorm操作,后接ReLU激活函数,最后再接N通道的 $3 \times 3$ 大小的卷积核进行卷积,后接ReLU激活函数;),最后进行最大池化;

[0079] 所述DenseBlock为深度模块;

[0080] 第二编码单元包含64通道的DenseBlock,后接最大池化;

[0081] 第三编码单元包含128通道的DenseBlock,后接最大池化;

[0082] 第四编码单元包含256通道的DenseBlock,后接最大池化;

[0083] 编码解码单元包含512通道的DenseBlock;

[0084] 第一解码单元包含256通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第四编码单元融合;

[0085] 第二解码单元包含128通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第三编码单元融合;

[0086] 第三解码单元包含64通道的 $3 \times 3$ 大小的卷积核的转置卷积,后接DenseBlock,并与第二编码单元融合;

[0087] 第四解码单元包含32通道的 $1 \times 1$ 大小的卷积核进行卷积,后接ReLU激活函数,并与第一编码单元融合;

[0088] 第一编码单元的输出作为第二编码单元的输入,第二编码单元的输出作为第三编码单元的输入,第三编码单元的输出作为第四编码单元的输入;

[0089] 第四编码单元的输出作为编码解码单元的输入;编码解码单元的输出作为第一解码单元的输入,第一解码单元的输出作为第二解码单元的输入,第二解码单元的输出作为第三解码单元的输入,第三解码单元的输出作为第四解码单元的输入;

[0090] 输出变换后的数据。

[0091] 其它步骤及参数与具体实施方式一至六之一相同。

[0092] 具体实施方式八:本实施方式与具体实施方式一至七之一不同的是,所述步骤五中将真实过车图像输入U-Dense型深度学习网络,基于步骤四得到的样本数据集权重,判别摇枕断裂故障;具体过程为:

[0093] 将真实过车图像使用U-Dense型深度学习网络进行数据变换后,使用训练好的权重系数,预测出摇枕断裂区域和雨水区域,根据标记的像素值得到预测后的断裂部分的区

域,将图像进行二值化,使得断裂部分的像素值为1,非断裂部分的像素值为0;对像素值为1的部分对照原图进行掩膜,判断掩膜区域的平均像素,由于正常摇枕的像素高于断裂处摇枕的像素,设定像素阈值,若掩膜部分像素值小于设定阈值,则对此部分摇枕进行故障报警;若掩膜部分像素值大于等于设定阈值,则处理下一张摇枕图像。

[0094] 其它步骤及参数与具体实施方式一至七之一相同。

[0095] 本发明还可有其它多种实施例,在不背离本发明精神及其实质的情况下,本领域技术人员当可根据本发明作出各种相应的改变和变形,但这些相应的改变和变形都应属于本发明所附的权利要求的保护范围。

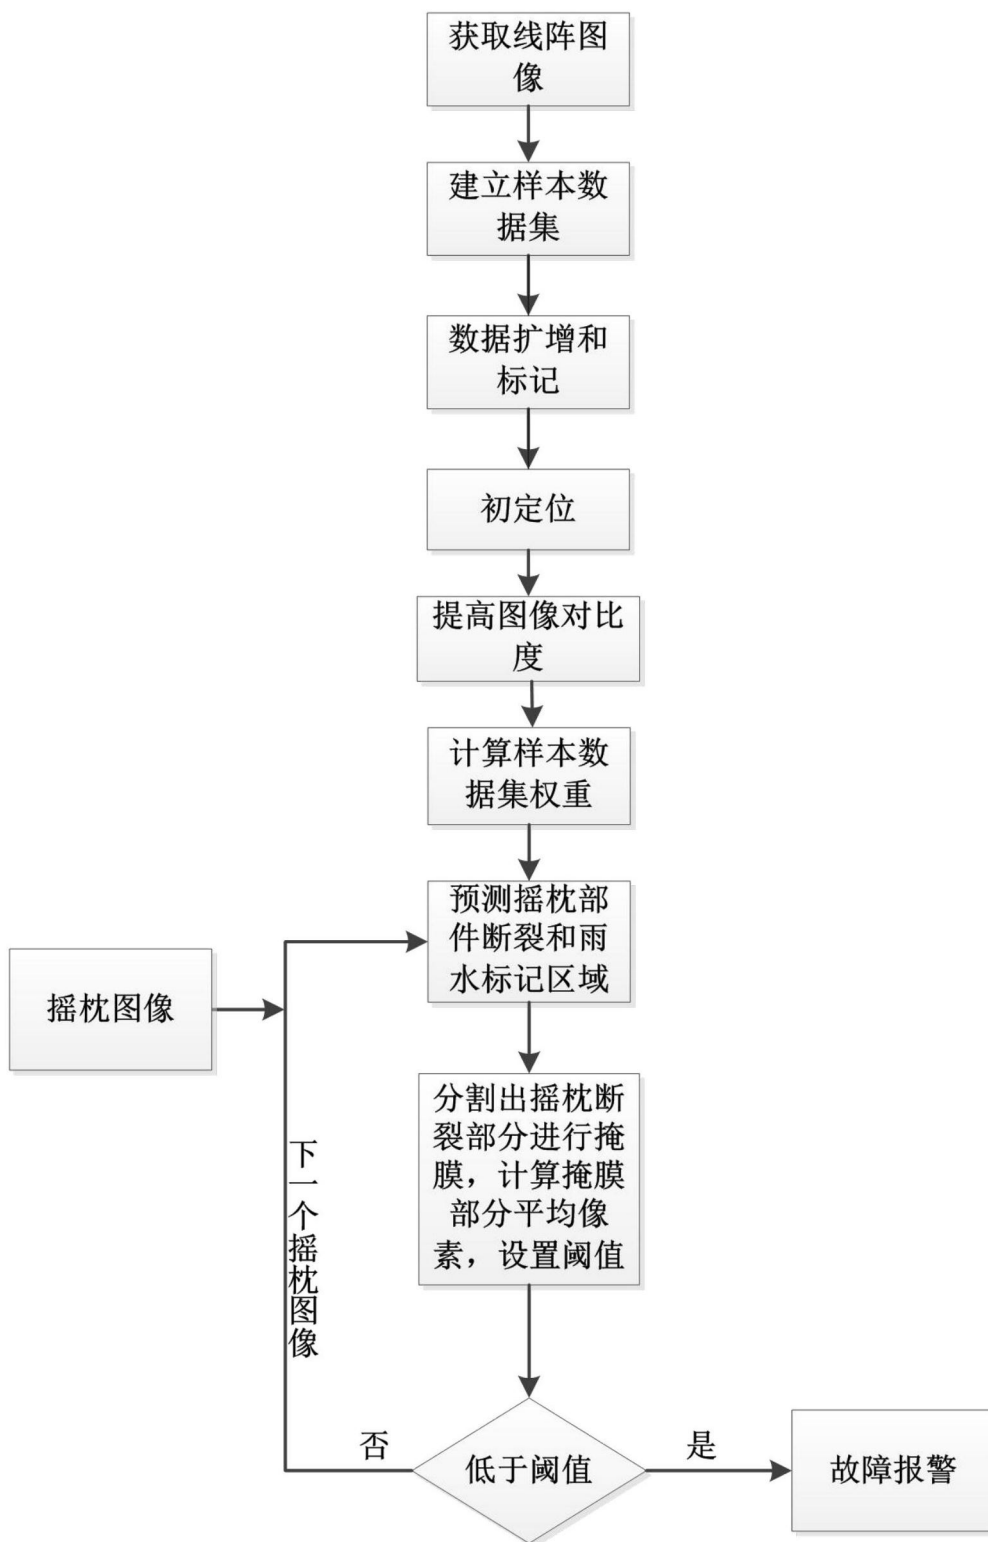


图1

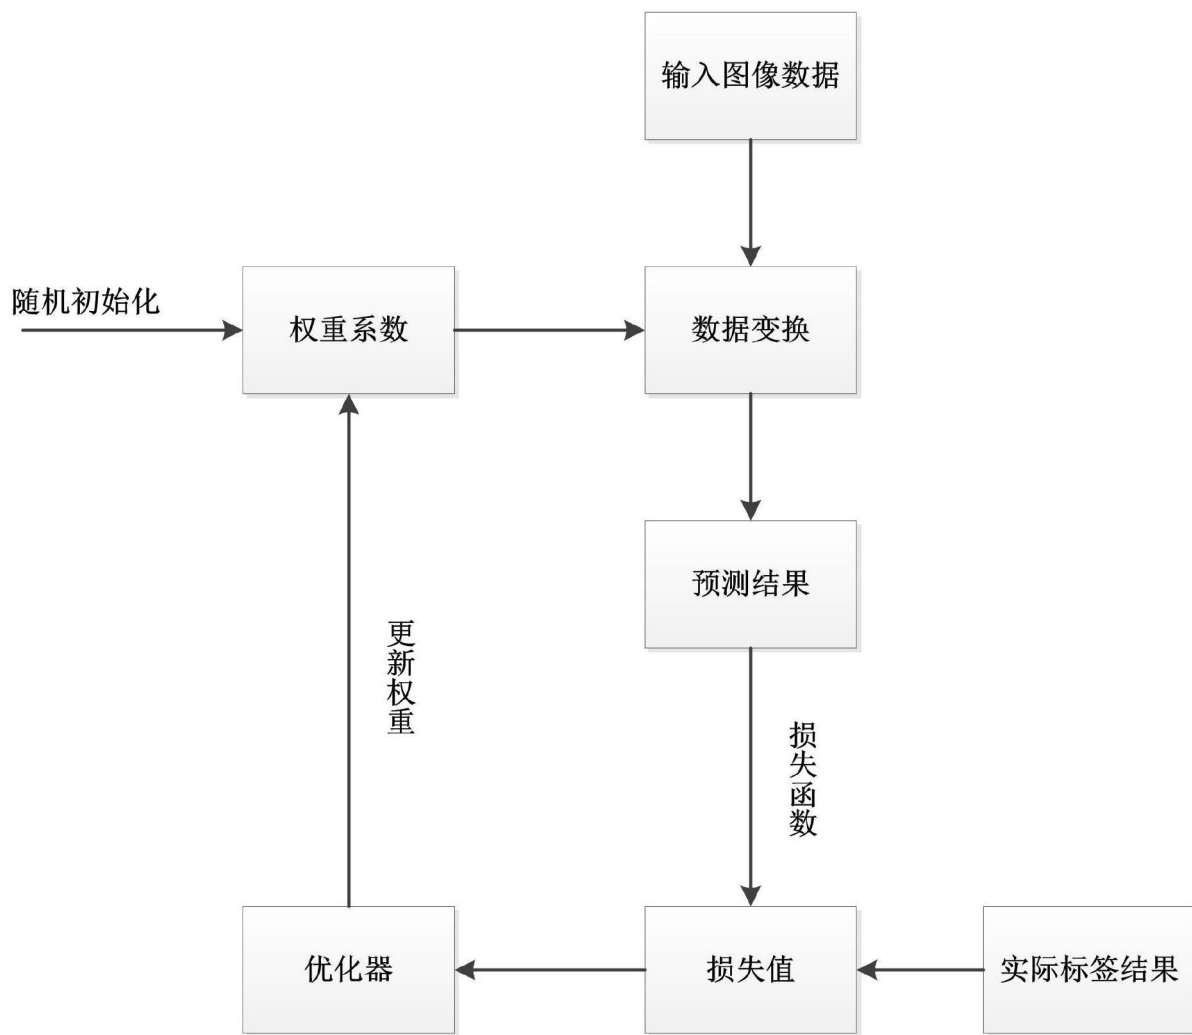


图2

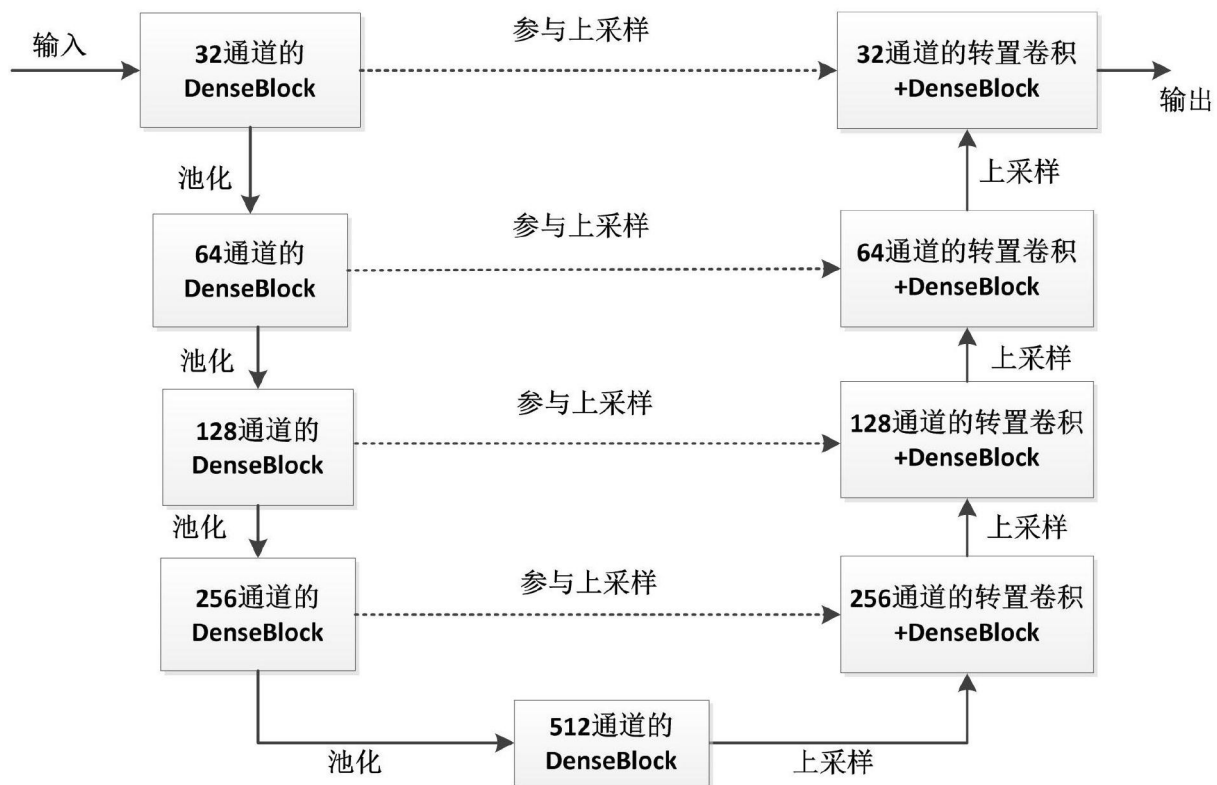


图3

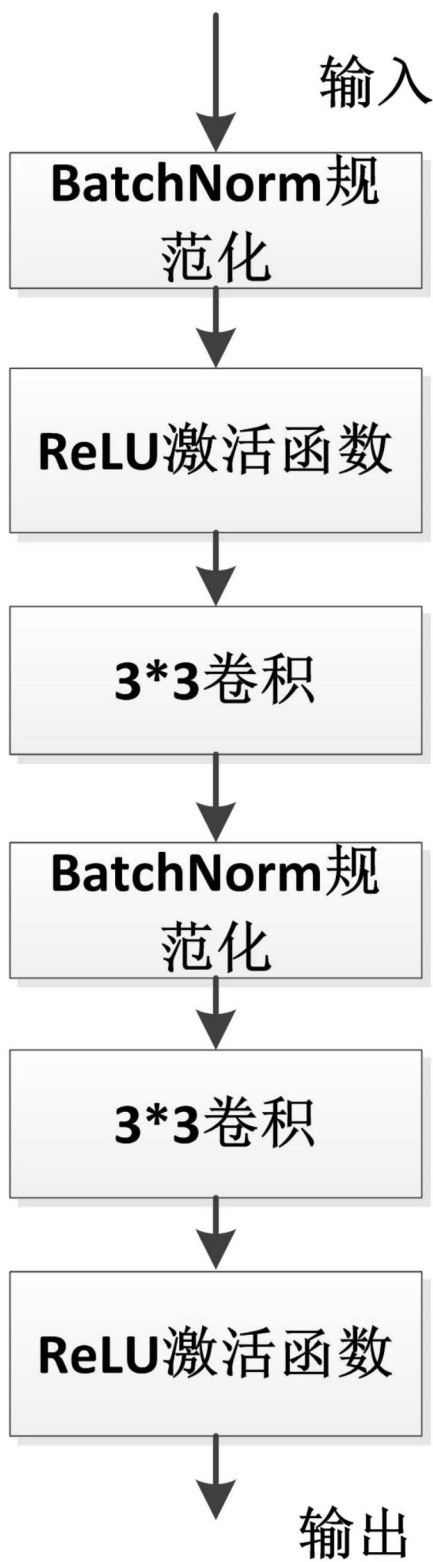


图4




图5