



(12) 发明专利

(10) 授权公告号 CN 112053426 B

(45) 授权公告日 2022.02.11

(21) 申请号 202011102356.8

G06N 3/04 (2006.01)

(22) 申请日 2020.10.15

G06N 3/08 (2006.01)

(65) 同一申请的已公布的文献号

G06V 10/764 (2022.01)

申请公布号 CN 112053426 A

G06V 10/77 (2022.01)

(43) 申请公布日 2020.12.08

G06V 10/762 (2022.01)

G06V 10/82 (2022.01)

(73) 专利权人 南京航空航天大学

(56) 对比文件

地址 210016 江苏省南京市秦淮区御道街
29号

CN 111080627 A, 2020.04.28

CN 111028220 A, 2020.04.17

(72) 发明人 汪俊 隆昆 谢乾 鲁德宁

US 9905026 B1, 2018.02.27

李红卫. 基于三维点云的飞机机体结构铆钉轮廓提取算法研究. 《机电工程》. 2020, 第37卷 (第6期),

(74) 专利代理机构 南京钟山专利代理有限公司
32252

代理人 王磊

审查员 白桦

(51) Int. Cl.

G06T 15/04 (2011.01)

G06K 9/62 (2022.01)

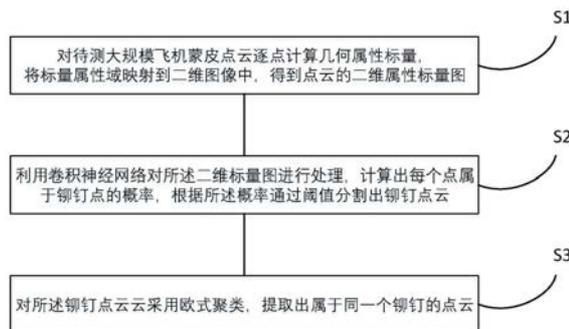
权利要求书3页 说明书6页 附图3页

(54) 发明名称

一种基于深度学习的大规模三维铆钉点云提取方法

(57) 摘要

本发明公开了一种基于深度学习的大规模三维铆钉点云提取方法,对待测飞机蒙皮点云逐点计算几何属性标量,将标量属性域映射到二维图像,得到点云的二维属性标量图;利用卷积神经网络对所述二维属性标量图进行处理,计算出每个点属于铆钉点的概率,根据计算出的概率通过阈值分割出铆钉点云;对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云。该基于深度学习的大规模三维铆钉点云提取方法利用注意机制综合考虑了局部点云的多种几何属性,并利用基于图像的深度学习代替直接对点云进行深度学习,有效提升了神经网络对局部细微特征的识别能力,从而能够从大片飞机蒙皮点云中准确提取出单个铆钉的小片点云。



1. 一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,包括:

S1:对待测飞机蒙皮点云逐点计算几何属性标量,将标量属性域映射到二维图像,得到点云的二维属性标量图;

S2:利用卷积神经网络对所述二维属性标量图进行处理,计算出每个点属于铆钉点的概率,根据计算出的概率通过阈值分割出铆钉点云;

S3:对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云;

所述S1包括:

S1.1:对点云中的每个点 p 构造 r -邻域 $P = \{p_1, p_2, \dots, p_n\}$,计算邻域中的几何属性作为邻域中心点的标量属性;

S1.2:将 r -邻域标准化为一个单位球,根据单位球内点集利用主成分分析法计算出投影平面 $\Gamma(p_0, v)$;

S1.3:将投影平面划分成 56×56 的网格,将所述领域内的点投影到所述平面网格中,网格中的投影点的像素值设置为一种几何属性的标量值,得到点云的二维属性标量图。

2. 根据权利要求1所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,S1.1所述点云的几何属性包括:点到投影平面的高度、密度、平均曲率和高斯曲率;

其中,点到投影平面的高度:

$$h_i = \frac{|v \cdot (p_i - p)|}{|v|}$$

其中, p_i 为 p 的 r -邻域中的点, v 为投影平面的法向量;

密度:

$$D_p = \frac{N_p}{\frac{4}{3} \cdot \pi \cdot r_d^3}$$

其中, $\frac{4}{3} \cdot \pi \cdot r_d^3$ 是以点 p 为球心、 r_d 为半径构造的球的体积, N_p 是所述球内点的数目;

平均曲率:

$$H = 0.5 \cdot (k_1 + k_2)$$

其中, k_1 和 k_2 是主曲率;

高斯曲率:

$$K = k_1 \cdot k_2。$$

3. 根据权利要求1-2任一所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,所述S2包括:

S2.1:搭建卷积神经网络模型,对卷积神经网络模型进行训练;

所述卷积神经网络模型包括第一卷积模块、域注意单元、第二卷积模块和一个全连接层;

S2.2:利用第一卷积模块对所述二维属性标量图进行处理,提取图像特征;

S2.3:利用域注意单元对提取的图像特征进行池化处理,得到组合后的特征;

S2.4:利用第二卷积模块和一个全连接层计算出每个点属于铆钉点的概率;

S2.5:根据计算出的概率按照设定阈值分割出铆钉点。

4. 根据权利要求3所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,所述S2.1搭建的卷积神经网络模型,配置第一卷积模块,所述第一卷积模块包括4个卷积层Conv1_1、Conv1_2、Conv2_1、Conv2_2,每2个卷积层后包括一个最大池化层pool1、pool2;

配置域注意单元,所述域注意单元包括3个卷积层Conv3_1、Conv3_2、Conv3_3和一个激活层Softmax;

配置第二卷积模块,所述第二卷积模块包括1个卷积层Conv4_1;

在第二卷积模块后配置一个全连接层FC_1;

训练过程中采用加权交叉熵损失惩罚错误分类。

5. 根据权利要求4所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,所述Conv1_1的卷积核大小为 3×3 ,卷积核的数量为16,步长为1;Conv1_2的卷积核大小为 3×3 ,卷积核的数量为32,步长为2;pool1的卷积核大小为 2×2 ,步长为2;Conv2_1的卷积核大小为 3×3 ,卷积核的数量为64,步长为1;Conv2_2的卷积核大小为 3×3 ,卷积核的数量为128,步长为1;pool2的卷积核大小为 2×2 ,步长为2;

Conv3_1卷积核大小为 3×3 ,卷积核的数量为64,步长为1;Conv3_2卷积核大小为 3×3 ,卷积核的数量为32,步长为1;Conv3_3卷积核大小为 3×3 ,卷积核的数量为2,步长为1;

Conv4_1卷积核大小为 3×3 ,卷积核数量为128,步长为1。

6. 根据权利要求4所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,所述加权交叉熵损失为:

$$H = \frac{1}{N} \sum_{i=1}^N w_r \cdot l_i \cdot \log(p(l_i)) + (1 - l_i) \cdot \log(1 - p(l_i))$$

其中, l_i 是点 p_i 的标签, $i=1,2,\dots,N$, l_i 为1表示铆钉点, l_i 为0表示非铆钉点, $p(l_i)$ 表示网络预测点 p_i 是铆钉点的概率, w_r 为铆钉点的交叉熵权重,定义为网络预测出的非铆钉点与铆钉点之比:

$$w_r = \frac{\sum_i [\hat{l}_i = 0]}{\sum_i [\hat{l}_i = 1]}$$

7. 根据权利要求3所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,S2.3所述利用域注意单元对提取的图像特征进行池化处理,得到组合后的特征,包括:

域注意单元利用注意机制给每种类型的图像特征 f_i 预测一个权重 w_i ,表征该种类型的特征的重要度,对该种特征进行加权:

$$f' = w_i \cdot f_i = \text{FAU}(f_i) \cdot f_i$$

其中, f_i 是经过第一卷积模块提取出的某一种类型的图像特征,FAU(\cdot)是域注意单元, w_i 是通过域注意单元计算出的权重, f' 是所述特征 f_i 经过加权之后的特征;

对所述加权之后的特征进行组合实现多种特征的池化操作:

$$F^* = \text{Conv}(\text{concat}[w_1 \cdot f_1; w_2 \cdot f_2; w_3 \cdot f_3; w_4 \cdot f_4])$$

其中 f_1, f_2, f_3, f_4 分别代表4种类型图像的特征, w_1, w_2, w_3, w_4 分别代表对应类型特征的权

重,concat(•)是特征组合操作,Conv(•)是通过卷积实现的池化操作。

8.根据权利要求3所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,S2.5中,设定概率阈值为0.5,将概率大于0.5的点标记为铆钉点,将概率小于等于0.5的点标记为非铆钉点。

9.根据权利要求1所述的一种基于深度学习的大规模三维铆钉点云提取方法,其特征在于,S3所述对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云,具体为:

根据分割结果,利用欧式聚类,将属于同一个铆钉的点聚类在一起,提取出单个铆钉点云。

一种基于深度学习的大规模三维铆钉点云提取方法

技术领域

[0001] 本发明属于计算机视觉领域和航空制造技术领域,具体涉及一种基于深度学习的大规模三维铆钉点云提取方法。

背景技术

[0002] 铆钉作为一种永久紧固件,因其具有的优良特性已广泛应用于飞机制造中。飞机蒙皮的铆接质量直接影响着飞机气动外形的可靠性,对飞机的飞行性能有着重要影响,对高速飞机的影响尤甚。此外,不良铆钉可能会通过增加雷达横截面来削弱隐形飞机的隐身性能。因此,飞机蒙皮表面铆钉的铆接质量检查是十分必要的。

[0003] 然而,飞机蒙皮上铆钉蒙皮数目非常多,超过数千个,现有方法很难逐个检测铆钉。基于图像处理的方法可以较好地识别出图像中的铆钉,但是图像缺乏三维信息,识别出铆钉之后无法进行后续诸如铆钉齐平度的测量。

[0004] 随着三维扫描技术的发展,采用3D扫描仪可以直接获取带有铆钉的飞机蒙皮的表面3D信息。然而,飞机蒙皮表面的铆钉点和非铆钉点的差异非常细微,直接利用传统方法检测飞机表面蒙皮点云中的铆钉点的检测质量较差,利用深度学习方法直接从大片点云中提取铆钉将很难识别出点云中的铆钉,因为神经网络中的最大池化操作提取的是全局特征,忽视了局部细微特征。

发明内容

[0005] 本发明所要解决的技术问题是针对上述现有技术的不足,提供一种基于深度学习的大规模三维铆钉点云提取方法。

[0006] 为实现上述技术目的,本发明采取的技术方案为:

[0007] 一种基于深度学习的大规模三维铆钉点云提取方法,包括:

[0008] S1:对待测飞机蒙皮点云逐点计算几何属性标量,将标量属性域映射到二维图像,得到点云的二维属性标量图;

[0009] S2:利用卷积神经网络对所述二维属性标量图进行处理,计算出每个点属于铆钉点的概率,根据计算出的概率通过阈值分割出铆钉点云;

[0010] S3:对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云。

[0011] 为优化上述技术方案,采取的具体措施还包括:

[0012] 上述的S1包括:

[0013] S1.1:对点云中的每个点 p 构造 r -邻域 $P = \{p_1, p_2, \dots, p_n\}$,计算邻域中的几何属性作为邻域中心点的标量属性;

[0014] S1.2:将 r -邻域标准化为一个单位球,根据单位球内点集利用主成分分析法(PCA)计算出投影平面 $\Gamma(p_0, v)$;

[0015] S1.3:将投影平面划分成 56×56 的网格,将所述领域内的点投影到所述平面网格中,网格中的投影点的像素值设置为一种几何属性的标量值,得到点云的二维属性标量图。

[0016] 上述的S1.1所述点云的几何属性包括：点到投影平面的高度、密度、平均曲率和高斯曲率；

[0017] 其中，点到投影平面的高度：

$$[0018] \quad h_i = \frac{|v \cdot (p_i - p)|}{|v|}$$

[0019] 其中， p_i 为 p 的 r -邻域中的点， v 为投影平面的法向量。

[0020] 密度：

$$[0021] \quad D_p = \frac{N_p}{\frac{4}{3} \cdot \pi \cdot r_d^3}$$

[0022] 其中， $\frac{4}{3} \cdot \pi \cdot r_d^3$ 是以点 p 为球心、 r_d 为半径构造的球的体积， N_p 是所述球内点的数目。

[0023] 平均曲率：

$$[0024] \quad H = 0.5 \cdot (k_1 + k_2)$$

[0025] 其中， k_1 和 k_2 是主曲率。

[0026] 高斯曲率：

$$[0027] \quad K = k_1 \cdot k_2。$$

[0028] 上述的S2包括：

[0029] S2.1:搭建卷积神经网络模型,对卷积神经网络模型进行训练；

[0030] 所述卷积神经网络模型包括第一卷积模块、域注意单元、第二卷积模块和一个全连接层；

[0031] S2.2:利用第一卷积模块对所述二维属性标量图进行处理,提取图像特征；

[0032] S2.3:利用域注意单元 (FAU) 对提取的图像特征进行池化处理,得到组合后的特征；

[0033] S2.4:利用第二卷积模块和一个全连接层计算出每个点属于铆钉点的概率；

[0034] S2.5:根据计算出的概率按照设定阈值分割出铆钉点。

[0035] 上述的S2.1搭建的卷积神经网络模型,配置第一卷积模块,所述第一卷积模块包括4个卷积层Conv1_1、Conv1_2、Conv2_1、Conv2_2,每2个卷积层后包括一个最大池化层pool1、pool2；

[0036] 配置域注意单元,所述域注意单元包括3个卷积层Conv3_1、Conv3_2、Conv3_3和一个激活层Softmax；

[0037] 配置第二卷积模块,所述第二卷积模块包括1个卷积层Conv4_1；

[0038] 在第二卷积模块后配置一个全连接层FC_1；

[0039] 训练过程中采用加权交叉熵损失惩罚错误分类。

[0040] 上述的Conv1_1的卷积核大小为 3×3 ,卷积核的数量为16,步长为1;Conv1_2的卷积核大小为 3×3 ,卷积核的数量为32,步长为2;pool1的卷积核大小为 2×2 ,步长为2;Conv2_1的卷积核大小为 3×3 ,卷积核的数量为64,步长为1;Conv2_2的卷积核大小为 3×3 ,

卷积核的数量为128,步长为1;pool2的卷积核大小为 2×2 ,步长为2;

[0041] Conv3_1卷积核大小为 3×3 ,卷积核的数量为64,步长为1;Conv3_2卷积核大小为 3×3 ,卷积核的数量为32,步长为1;Conv3_3卷积核大小为 3×3 ,卷积核的数量为2,步长为1;

[0042] Conv4_1卷积核大小为 3×3 ,卷积核数量为128,步长为1。

[0043] 上述的加权交叉熵损失为:

$$[0044] \quad H = \frac{1}{N} \sum_{i=1}^N w_r \cdot l_i \cdot \log(p(l_i)) + (1 - l_i) \cdot \log(1 - p(l_i))$$

[0045] 其中, l_i ($i=1,2,\dots,N$)是点 p_i 的标签(1表示铆钉点,0表示非铆钉点), $p(l_i)$ 表示网络预测点 p_i 是铆钉点的概率, w_r 为铆钉点的交叉熵权重,定义为网络预测出的非铆钉点与铆钉点之比:

$$[0046] \quad w_r = \frac{\sum_i [\hat{l}_i = 0]}{\sum_i [\hat{l}_i = 1]}$$

[0047] 上述的S2.3所述利用域注意单元(FAU)对提取的图像特征进行池化处理,得到组合后的特征,包括:

[0048] 域注意单元利用注意机制给每种类型的图像特征 f_i 预测一个权重 w_i ,表征该种类型的特征的重要度,对该种特征进行加权:

$$[0049] \quad f' = w_i \cdot f_i = \text{FAU}(f_i) \cdot f_i$$

[0050] 其中, f_i 是经过第一卷积模块提取出的某一种类型的图像特征,FAU(\cdot)是域注意单元, w_i 是通过域注意单元计算出的权重, f' 是所述特征 f_i 经过加权之后的特征;

[0051] 对所述加权之后的特征进行组合实现多种特征的池化操作:

$$[0052] \quad F^* = \text{Conv}(\text{concat}[w_1 \cdot f_1; w_2 \cdot f_2; w_3 \cdot f_3; w_4 \cdot f_4])$$

[0053] 其中 f_1, f_2, f_3, f_4 分别代表4种类型图像的特征, w_1, w_2, w_3, w_4 分别代表对应类型特征的权重,concat(\cdot)是特征组合操作,Conv(\cdot)是通过卷积实现的池化操作。

[0054] 上述的S2.5中,设定概率阈值为0.5,将概率大于0.5的点标记为铆钉点,将概率小于等于0.5的点标记为非铆钉点。

[0055] 上述的S3所述对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云,具体为:

[0056] 根据分割结果,利用欧式聚类,将属于同一个铆钉的点聚类在一起,提取出单个铆钉点云。

[0057] 本发明具有以下有益效果:

[0058] 1、本发明的点云特征提取方法组合了点云的多种几何属性并采用基于图像的卷积操作能够很好地提取点云的局部细微特征,能够有效地识别出并分割出单个铆钉点云。

[0059] 2、本发明基于深度学习方法,大多数参数可以自动优化,避免了传统方法中许多手动调控的参数,从而将优化问题简单化。此外,只要训练好分类器,就能在后续检测中直接使用分类器检测铆钉,使处理任务的速度更快,能有效提高工作效率。

附图说明

[0060] 图1是本发明实施例提供的一种基于深度学习的大规模三维铆钉点云提取方法的流程图；

[0061] 图2是本发明实施例中提供的带有铆钉的飞机表面蒙皮扫描点云图；

[0062] 图3是本发明实施例提供的单个铆钉点云的侧视图；

[0063] 图4是本发明实施例提供的从点云中提取二维标量图像的示意图；

[0064] 图5是本发明实施例提供的一种基于深度学习的大规模三维铆钉点云提取方法的卷积神经网络结构图；

[0065] 图6是本发明实施例提供的域注意单元的原理图；

[0066] 图7是本发明实施例提供的铆钉提取结果图。

具体实施方式

[0067] 以下结合附图对本发明的实施例作进一步详细描述。

[0068] 带有铆钉的飞机蒙皮扫描点云如图2所示,图3展示了单个铆钉点云的侧视图。为了解决现有方法中难以准确提取出带有三维信息的飞机蒙皮铆钉的问题,参见图1,本发明的一种基于深度学习的大规模三维铆钉点云提取方法,包括:

[0069] S1:对待测大规模飞机蒙皮点云逐点计算几何属性标量,将标量属性域映射到二维图像,得到点云的二维属性标量图;

[0070] S2:利用卷积神经网络对所述二维属性标量图进行处理,计算出每个点属于铆钉点的概率,根据计算出的概率通过阈值分割出铆钉点云;

[0071] S3:对分割出的铆钉点云采用欧式聚类,聚类出属于同一个铆钉的点云。

[0072] 如图4所示,实施例中,所述S1包括:

[0073] S1.1:对点云中的每个点 p 构造 r -邻域 $P = \{p_1, p_2, \dots, p_n\}$,计算邻域中的几何属性作为邻域中心点的标量属性;

[0074] 具体地,邻域半径 r 为1.5倍的铆钉头半径;

[0075] S1.2:将 r -邻域标准化为一个单位球,根据单位球内点集利用主成分分析法(PCA)计算出投影平面 $\Gamma(p_0, v)$;

[0076] S1.3:将投影平面划分成 56×56 的网格,将所述领域内的点投影到所述平面网格中,网格中的投影点的像素值设置为一种几何属性的标量值,得到维度为 56×56 点云的二维属性标量图。

[0077] 实施例中,S1.1所述点云的几何属性包括:点到投影平面的高度、密度、平均曲率和高斯曲率;

[0078] 其中,点到投影平面的高度:

$$[0079] \quad h_i = \frac{|v \cdot (p_i - p)|}{|v|}$$

[0080] 其中, p_i 为 p 的 r -邻域中的点, v 为投影平面的法向量。

[0081] 密度:

$$[0082] \quad D_p = \frac{N_p}{\frac{4}{3} \cdot \pi \cdot r_d^3}$$

[0083] 其中, $\frac{4}{3} \cdot \pi \cdot r_d^3$ 是以点p为球心、 r_d 为半径构造的球的体积, N_p 是所述球内点的数目。

[0084] 具体地, r_d 为0.5倍的铆钉头理论半径。

[0085] 平均曲率:

$$[0086] \quad H = 0.5 \cdot (k_1 + k_2)$$

[0087] 其中, k_1 和 k_2 是主曲率。

[0088] 高斯曲率:

$$[0089] \quad K = k_1 \cdot k_2。$$

[0090] 实施例中, 所述S2包括:

[0091] S2.1: 搭建卷积神经网络模型, 对卷积神经网络模型进行训练;

[0092] 所述卷积神经网络模型包括第一卷积模块、域注意单元、第二卷积模块和一个全连接层;

[0093] S2.2: 利用第一卷积模块对所述二维属性标量图进行处理, 提取图像特征;

[0094] S2.3: 利用域注意单元 (FAU) 对提取的图像特征进行池化处理, 得到组合后的特征;

[0095] S2.4: 利用第二卷积模块和一个全连接层计算出每个点属于铆钉点的概率;

[0096] S2.5: 根据计算出的概率按照设定阈值分割出铆钉点。

[0097] 如图5所示, 实施例中, 所述S2.1搭建的卷积神经网络模型, 配置第一卷积模块, 所述第一卷积模块包括4个卷积层Conv1_1、Conv1_2、Conv2_1、Conv2_2, 每2个卷积层后包括一个最大池化层pool1、pool2;

[0098] 具体地, Conv1_1的卷积核大小为 3×3 , 卷积核的数量为16, 步长为1; Conv1_2的卷积核大小为 3×3 , 卷积核的数量为32, 步长为2; pool1的卷积核大小为 2×2 , 步长为2; Conv2_1的卷积核大小为 3×3 , 卷积核的数量为64, 步长为1; Conv2_2的卷积核大小为 3×3 , 卷积核的数量为128, 步长为1; pool2的卷积核大小为 2×2 , 步长为2。

[0099] 配置域注意单元, 所述域注意单元包括3个卷积层Conv3_1、Conv3_2、Conv3_3和一个激活层Softmax;

[0100] 具体地, Conv3_1卷积核大小为 3×3 , 卷积核的数量为64, 步长为1; Conv3_2卷积核大小为 3×3 , 卷积核的数量为32, 步长为1; Conv3_3卷积核大小为 3×3 , 卷积核的数量为2, 步长为1。

[0101] 配置第二卷积模块, 所述第二卷积模块包括1个卷积层Conv4_1;

[0102] 具体地, Conv4_1卷积核大小为 3×3 , 卷积核数量为128, 步长为1。

[0103] 在第二卷积模块后配置一个全连接层FC_1;

[0104] 训练过程中采用加权交叉熵损失惩罚错误分类。

[0105] 所述加权交叉熵损失为:

$$[0106] \quad H = \frac{1}{N} \sum_1^N w_r \cdot l_i \cdot \log(p(l_i)) + (1 - l_i) \cdot \log(1 - p(l_i))$$

[0107] 其中, l_i ($i=1, 2, \dots, N$) 是点 p_i 的标签 (1 表示铆钉点, 0 表示非铆钉点), $p(l_i)$ 表示网络预测点 p_i 是铆钉点的概率, w_r 为铆钉点的交叉熵权重, 定义为网络预测出的非铆钉点与铆钉点之比:

$$[0108] \quad w_r = \frac{\sum_i [\hat{l}_i = 0]}{\sum_i [\hat{l}_i = 1]}。$$

[0109] 实施例中, 根据概率通过阈值分割出铆钉点, 具体地, 概率阈值为 0.5, 将概率大于 0.5 的点标记为铆钉点, 将概率小于等于 0.5 的点标记为非铆钉点。

[0110] 实施例中, S2.3 所述利用域注意单元 (FAU) 对提取的图像特征进行池化处理, 得到组合后的特征, 域注意单元的原理如图 6 所示, 包括:

[0111] 域注意单元利用注意机制给每种类型的图像特征 f_i 预测一个权重 w_i , 表征该种类型的特征的重要度, 对该种特征进行加权:

$$[0112] \quad f' = w_i \cdot f_i = \text{FAU}(f_i) \cdot f_i$$

[0113] 其中, f_i 是经过第一卷积模块提取出的某一种类型的图像特征, $\text{FAU}(\cdot)$ 是域注意单元, w_i 是通过域注意单元计算出的权重, f' 是所述特征 f_i 经过加权之后的特征;

[0114] 对所述加权之后的特征进行组合实现多种特征的池化操作:

$$[0115] \quad F^* = \text{Conv}(\text{concat}[w_1 \cdot f_1; w_2 \cdot f_2; w_3 \cdot f_3; w_4 \cdot f_4])$$

[0116] 其中 f_1, f_2, f_3, f_4 分别代表 4 种类型图像的特征, w_1, w_2, w_3, w_4 分别代表对应类型特征的权重, $\text{concat}(\cdot)$ 是特征组合操作, $\text{Conv}(\cdot)$ 是通过卷积实现的池化操作。

[0117] 实施例中, S3 所述对分割出的铆钉点云采用欧式聚类, 聚类出属于同一个铆钉的点云, 具体为:

[0118] 根据分割结果, 利用欧式聚类, 将属于同一个铆钉的点聚类在一起, 提取出单个铆钉点云, 铆钉提取结果如图 7 所示。

[0119] 本实施例的基于大规模点云的铆钉提取方法把直接对点云的学习转化为对图像进行学习同时利用注意机制综合考虑了多种几何属性信息, 增加了网络对局部细微特征的提取能力, 能有效从大片点云中准确提取出单个铆钉点云。

[0120] 以上仅是本发明的优选实施方式, 本发明的保护范围并不仅局限于上述实施例, 凡属于本发明思路下的技术方案均属于本发明的保护范围。应当指出, 对于本技术领域的普通技术人员来说, 在不脱离本发明原理前提下的若干改进和润饰, 应视为本发明的保护范围。

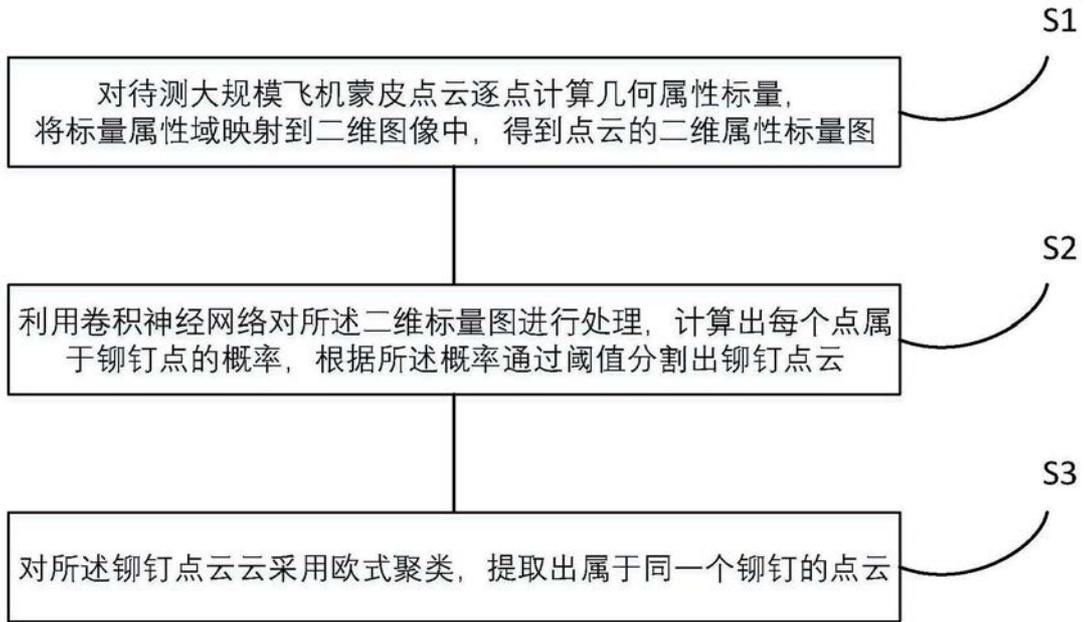


图1

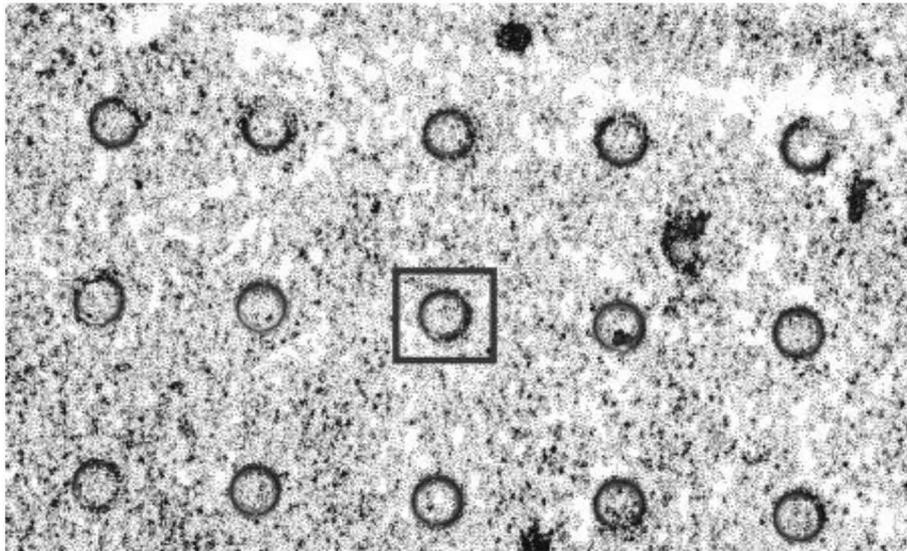


图2



图3

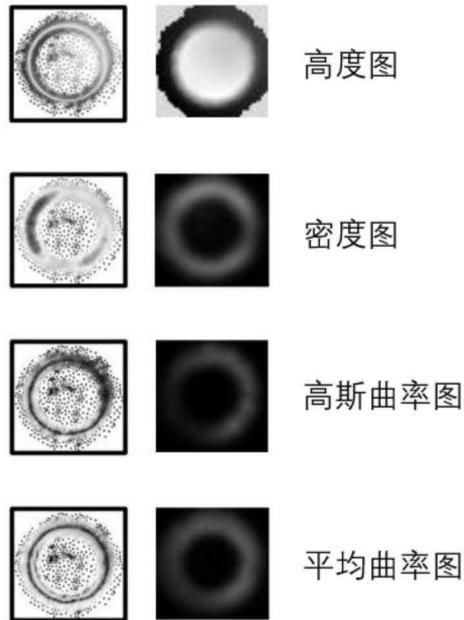


图4

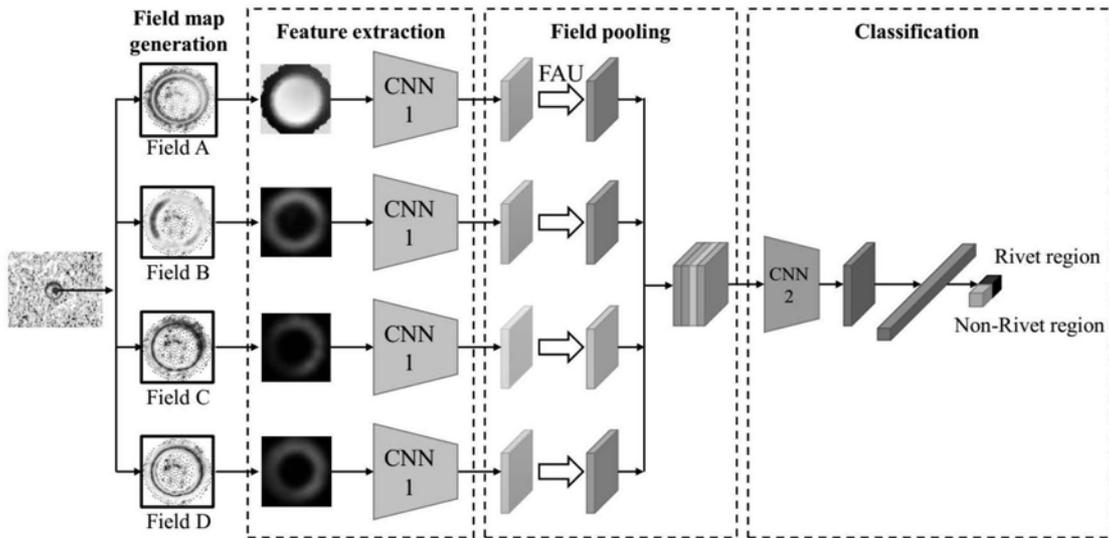


图5

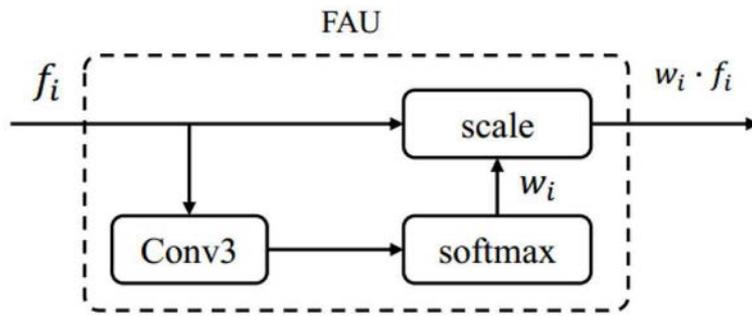


图6

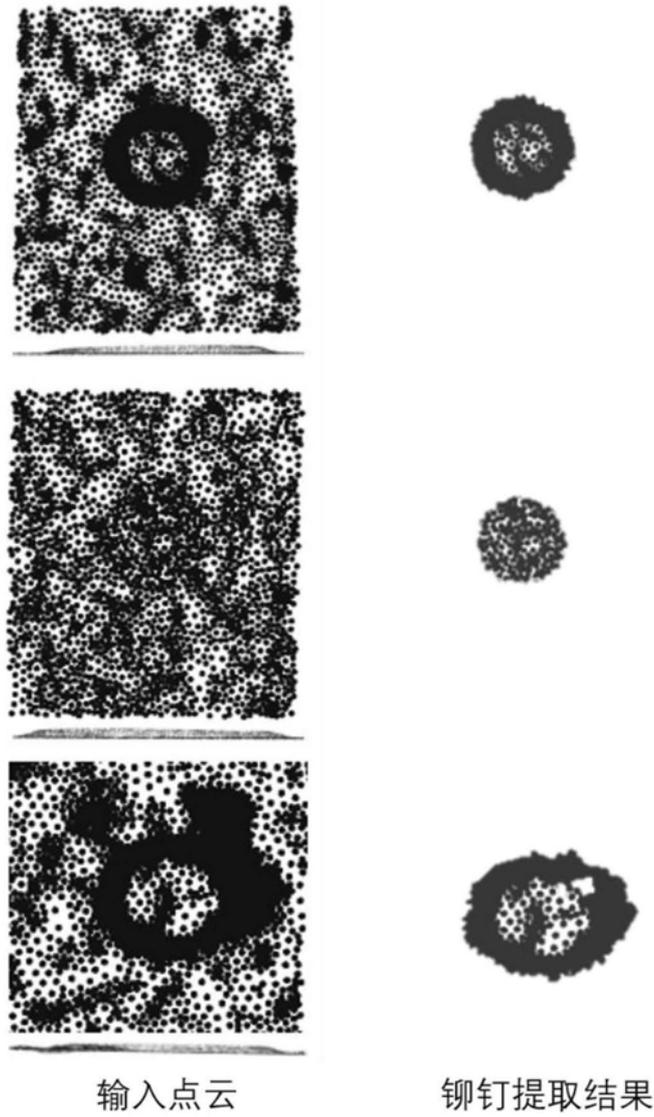


图7