



(12) 发明专利

(10) 授权公告号 CN 110930377 B

(45) 授权公告日 2022.05.13

(21) 申请号 201911125639.1

(22) 申请日 2019.11.18

(65) 同一申请的已公布的文献号
申请公布号 CN 110930377 A

(43) 申请公布日 2020.03.27

(73) 专利权人 福州大学
地址 350108 福建省福州市闽侯县福州大
学城龙江北大道2号福州大学

(72) 发明人 钟尚平 陈雨寒 陈开志

(74) 专利代理机构 福州元创专利商标代理有限
公司 35100
专利代理师 陈明鑫 蔡学俊

(51) Int. Cl.
G06T 7/00 (2017.01)

(56) 对比文件

CN 108038850 A, 2018.05.15

CN 109559302 A, 2019.04.02

CN 109783906 A, 2019.05.21

US 2006228027 A1, 2006.10.12

户莹.基于深度学习的地下排水管道缺陷智能检测技术研究.《中国优秀硕士学位论文全文数据库(硕士)工程科技II辑》.2019,第C038-714页.

Jian Feng et al..Injurious or Noninjurious Defect Identification From MFL Images in Pipeline Inspection Using Convolutional Neural Network.《IEEE Transactions on Instrumentation and Measurement》.2017,第66卷(第7期),第1883-1892页.

审查员 傅志良

权利要求书2页 说明书6页 附图5页

(54) 发明名称

一种基于多任务学习的排水管道异常类型自动检测方法

(57) 摘要

本发明涉及一种基于多任务学习的排水管道异常类型自动检测方法。首先通过分析管道缺陷深度特征信息将特征空间存在重叠的类别划分到同一分组中;然后基于分组情况构建多任务学习深度神经网络,该网络将分类任务划分为两级任务,高级分类任务尝试区分不同分组的缺陷图像,低级任务拥有多个子任务,分别用于着重区分组内具有相似特征空间的缺陷类型,最终的缺陷分类结果来自条件概率。本发明通过引入多任务学习策略使得模型能够减少特征空间重叠带来的精度损失,提升模型的检测精度,从而实现更为有效的排水管道缺陷自动检测系统。



1. 一种基于多任务学习的排水管道异常类型自动检测方法,其特征在于,包括如下步骤:

步骤S1、建立训练数据集:从历史检测报告及排水管道机器人拍摄的视频中随机抽取视频帧形成管道图像集,对于管道图像集里的每个图像,按照城镇排水管道检测与评估技术规范中给出的管道评估方式对图像进行标注,形成管道图像集S和图像标签集 γ ,对于管道图像集S里的每个图像集X(n),有与之对应的图像标签集 γ , $\gamma = (\gamma(1), \gamma(2), \dots, \gamma(n))$, $\gamma(n)$ 表示第 $\omega(n)$ 张图像所属管道异常类型;按照70%,10%,20%的比例将所述管道图像集划分成训练集、验证集和测试集;在深度学习中,为避免出现过拟合,对训练集中的图像数据进行数据增强和标准化处理;

步骤S2、使用步骤S1得到的训练集图像通过梯度下降算法训练深度残差神经网络;

步骤S3、使用步骤S2中训练好的神经网络对步骤S1中的训练集图像进行识别,图像依次经过卷积层、池化层获取神经网络倒数第二层特征向量,通过特征向量构建缺陷的深度特征空间,基于深度特征空间构建深度特征直方图;

步骤S4、使用步骤S3中得到的各类别深度特征直方图进行相似性度量,一一对比不同类别深度特征直方图的相似性,根据相似性对缺陷进行分组;

步骤S5、使用步骤S4中分组结果构建多任务深度残差神经网络,使用步骤S1得到的训练集图像通过梯度下降算法训练神经网络;

步骤S6、使用步骤S4中训练好的神经网络对待识别的图像进行识别,图像依次经过卷积层、池化层和激活层后得到图像中包含缺陷的类型;

所述步骤S5中,使用步骤S4中分组结果构建多任务深度残差神经网络的方式如下:

以残差网络为主干网,不同任务之间共享前4个残差卷积块,在第4块残差卷积块后形成多任务分支;每个分支由一个残差卷积块,平均池化层,全连接层和一个softmax激活层组成;分支从根据分组结果从功能上划分为两大任务模块:高级任务模块和低级任务模块,高级任务模块的分类目标为对不同分组的缺陷图像进行分类,最终输出图像归属分组的概率;低级任务模块拥有多个子任务,每个子任务对组内不同缺陷进行分类,最终输出图像归属组内具体类别的概率;缺陷分类结果来自条件概率:

$$P(B) = \frac{P(A)P(B|A)}{P(A|B)}$$

式中, $P(A)$ 表示高级任务模块输出概率, $P(B|A)$ 表示低级任务模块输出概率,分好组后的缺陷一定会被划分至对应的组中,则条件概率 $P(A|B)$ 恒等于1,由此得到最终的分类结果;训练选用联合优化训练方法进行训练,联合优化的损失函数表示为如下形式:

$$E(x_i) = -\sum_i p_{high}(x_i) \log q_{high}(x_i) - \sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$$

式中, $\sum_i p_{high}(x_i) \log q_{high}(x_i)$ 为高级任务的交叉熵损失函数, $\sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$

为低级任务各子任务损失函数的和。

2. 根据权利要求1所述的一种基于多任务学习的排水管道异常类型自动检测方法,其特征在于,所述步骤S1中,管道异常类型划分为变形、沉积、错口、腐蚀、破裂、起伏、渗漏、树

根,依次对应的 γ 值为0,1,2...6,7。

3. 根据权利要求1所述的一种基于多任务学习的排水管道异常类型自动检测方法,其特征在于,所述步骤S1中,对训练集中的图像数据进行数据增强和标准化处理的过程具体包括以下步骤:

步骤S11、对训练集中的图像数据进行数据增强;所述进行数据增强的方法包括水平翻转、旋转、改变图像色彩、加入噪声;

步骤S12、将步骤S11中的进行数据增强后的图像集按短边等比例缩放至固定大小,范围为256~512之间;

步骤S13、对步骤S12缩小后的图片随机裁剪出224×224的子图;

步骤S14、对步骤S13中产生的子图进行标准化处理,具体采用以下公式:

$$x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

式中, x_i 表示一张图中的其中一个像素点; x_{\min} 表示图中所有像素的最小值点, x_{\max} 表示图中所有像素的最大值点。

4. 根据权利要求1所述的一种基于多任务学习的排水管道异常类型自动检测方法,其特征在于,所述步骤S2中,深度残差网络结构由5个残差卷积块组成,残差卷积块之间通过Shortcut的结构连接,每个残差卷积块由3个卷积层组成,使用1×1、3×3、1×1的3个卷积层串接在一起作为一个残差卷积块。

5. 根据权利要求1所述的一种基于多任务学习的排水管道异常类型自动检测方法,其特征在于,所述步骤S3中,构建深度特征直方图的方式如下:

步骤S31、使用步骤S1中划分好类别的训练集并采用步骤S2中训练好的神经网络提取深度特征,取步骤S2中网络倒数第二层2048维向量作为训练集中每张图像的深度特征向量;

步骤S32、将步骤S31中获取的深度特征向量按照类别组合在一起构成深度特征矩阵;

步骤S33、对步骤S32中每个类别的深度特征矩阵绘制深度特征直方图。

一种基于多任务学习的排水管道异常类型自动检测方法

技术领域

[0001] 本发明涉及一种基于多任务学习的排水管道异常类型自动检测方法。

背景技术

[0002] 现有的一种基于深度学习的排水管道异常类型自动检测方法,公开号为CN108038850A,该技术的问题及缺陷为:管道内部图像不同于一般的图像,其特殊性在于管道图像包含很丰富的细节,具有亮度低,背景单一,对比度弱,噪声多,变化性强的特点。同时由于几何形状,材料,缺陷性质,内部衬里,相机规格等的差异导致管道图像在视觉外观方面表现出大的变化。这就对分类模型的泛化性能方面提出了很高的要求,增加了分类任务的难度。并且,管道图像存在深度特征空间重叠的问题,主要表现在两个方面。首先是管道内部图像具有背景单一的特点。由于背景单一,导致不同类的图像可能存在大量的相似之处,仅有少数的细节不同用于判断缺陷的类型。其次,在实际情况中,缺陷可能是伴生发生的,少数图像中可能存在多个缺陷,多种缺陷同时发生,这就导致类在特征空间中出现了重叠,分类器无法对其做出正确的判断。在已有的分类模型中,类根据定义是互斥的,当类在特征空间中存在重叠时,就会发生分类错误。

发明内容

[0003] 本发明的目的在于克服上述问题,提供一种基于多任务学习的排水管道异常类型自动检测方法,将多任务学习策略和深度学习模型引入到排水管道缺陷检测中,从而提升模型的检测精度和泛化能力。

[0004] 为实现上述目的,本发明的技术方案是:一种基于多任务学习的排水管道异常类型自动检测方法,包括如下步骤:

[0005] 步骤S1、建立训练数据集:从历史检测报告及排水管道机器人拍摄的视频中随机抽取视频帧形成管道图像集,对于管道图像集里的每个图像,按照城镇排水管道检测与评估技术规程中给出的管道评估方式对图像进行标注,形成管道图像集S和图像标签集 γ ,对于管道图像集S里的每个图像集 $X(n)$,有与之对应的图像标签集 γ , $\gamma = (\gamma(1), \gamma(2), \dots, \gamma(n))$, $\gamma(n)$ 表示第 $\omega(n)$ 张图像所属管道异常类型;按照70%,10%,20%的比例将所述管道图像集划分成训练集、验证集和测试集;在深度学习中,为避免出现过拟合,对训练集中的图像数据进行数据增强和标准化处理;

[0006] 步骤S2、使用步骤S1得到的训练集图像通过梯度下降算法训练深度残差神经网络;

[0007] 步骤S3、使用步骤S2中训练好的神经网络对步骤S1中的训练集图像进行识别,图像依次经过卷积层、池化层获取神经网络倒数第二层特征向量,通过特征向量构建缺陷的深度特征空间,基于深度特征空间构建深度特征直方图;

[0008] 步骤S4、使用步骤S3中得到的各类别深度特征直方图进行相似性度量,一一对比不同类别深度特征直方图的相似性,根据相似性对缺陷进行分组;

[0009] 步骤S5、使用步骤S4中分组结果构建多任务深度残差神经网络,使用步骤S1得到的训练集图像通过梯度下降算法训练神经网络;

[0010] 步骤S6、使用步骤S4中训练好的神经网络对待识别的图像进行识别,图像依次经过卷积层、池化层和激活层后得到图像中包含缺陷的类型。

[0011] 在本发明一实施例中,所述步骤S1中,管道异常类型划分为变形、沉积、错口、腐蚀、破裂、起伏、渗漏、树根,依次对应的 γ 值为0,1,2...6,7。

[0012] 在本发明一实施例中,所述步骤S1中,对训练集中的图像数据进行数据增强和标准化处理的过程具体包括以下步骤:

[0013] 步骤S11、对训练集中的图像数据进行数据增强;所述进行数据增强的方法包括水平翻转、旋转、改变图像色彩、加入噪声;

[0014] 步骤S12、将步骤S11中的进行数据增强后的图像集按短边等比例缩放至固定大小,范围为256~512之间;

[0015] 步骤S13、对步骤S12缩小后的图片随机裁剪出 224×224 的子图;

[0016] 步骤S14、对步骤S13中产生的子图进行标准化处理,具体采用以下公式:

$$[0017] \quad x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

[0018] 式中, x_i 表示一张图中的其中一个像素点; x_{\min} 表示图中所有像素的最小值点, x_{\max} 表示图中所有像素的最大值点。

[0019] 在本发明一实施例中,所述步骤S2中,深度残差网络结构由5个残差卷积块组成,残差卷积块之间通过Shortcut的结构连接,每个残差卷积块由3个卷积层组成,使用 1×1 、 3×3 、 1×1 的3个卷积层串接在一起作为一个残差卷积块。

[0020] 在本发明一实施例中,所述步骤S3中,构建深度特征直方图的方式如下:

[0021] 步骤S31、使用步骤S1中划分好类别的训练集并采用步骤S2中训练好的神经网络提取深度特征,取步骤S2中网络倒数第二层2048维向量作为训练集中每张图像的深度特征向量;

[0022] 步骤S32、将步骤S31中获取的深度特征向量按照类别组合在一起构成深度特征矩阵;

[0023] 步骤S33、对步骤S32中每个类别的深度特征矩阵绘制深度特征直方图。

[0024] 在本发明一实施例中,所述步骤S4中,根据相似性对缺陷进行分组的方式如下:

[0025] 使用常态分布比对下的巴氏距离作为评估不同类深度特征空间重叠程度的依据,依次计算每两类之间深度特征直方图的巴氏距离,将阈值小于0.1的类别划分至同一组;用于计算直方图相识度的巴氏距离可描述为,对于直方图H1和H2:

$$[0026] \quad D_B(H_1, H_2) = \sqrt{1 - \frac{1}{\sqrt{H_1 H_2 N^2}} \sum_I \sqrt{H_1(I) H_2(I)}}$$

[0027] 式中,H1和H2表示将要对比的直方图,H1(I)和H2(I)表示直方图中的每个像素点的值。

[0028] 在本发明一实施例中,所述步骤S5中,使用步骤S4中分组结果构建多任务深度残差神经网络的方式如下:

[0029] 以残差网络为主干网,不同任务之间共享前4个残差卷积块,在第4块残差卷积块后形成多任务分支;每个分支由一个残差卷积块,平均池化层,全连接层和一个softmax激活层组成;分支从根据分组结果从功能上划分为两大任务模块:高级任务模块和低级任务模块,高级任务模块的分类目标为对不同分组的缺陷图像进行分类,最终输出图像归属分组的概率;低级任务模块拥有多个子任务,每个子任务对组内不同缺陷缺陷进行分类,最终输出图像归属组内具体类别的概率;缺陷分类结果来自条件概率:

$$[0030] \quad P(B) = \frac{P(A)P(B|A)}{P(A|B)}$$

[0031] 式中, $P(A)$ 表示高级任务模块输出概率, $P(B|A)$ 表示低级任务模块输出概率,分好组后的缺陷一定会被划分至对应的组中,则条件概率 $P(A|B)$ 恒等于1,由此得到最终的分类结果;训练选用联合优化训练方法进行训练,联合优化的损失函数可表示为如下形式:

$$[0032] \quad E(x_i) = -\sum_i p_{high}(x_i) \log q_{high}(x_i) - \sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$$

[0033] 式中, $\sum_i p_{high}(x_i) \log q_{high}(x_i)$ 为高级任务的交叉熵损失函数, $\sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$

为低级任务各子任务损失函数的和。

[0034] 相较于现有技术,本发明具有以下有益效果:本发明提供了一种基于多任务学习的排水管道异常类型自动检测方法,目前的方法需要复杂的手工特征提取和大量的图像预处理,方法的通用性不高。并且管道图像中存在缺陷特征重叠问题,增加分类任务的难度。本发明设计了一种基于多任务学习的深度残差网络用于管道缺陷的自动化分类。首先,通过分析管道缺陷深度特征信息将特征空间存在重叠的类别划分到同一分组中。然后将分类任务划分为两级任务,高级分类任务尝试区分不同分组的缺陷图像,低级任务拥有多个子任务,分别用于着重区分组内具有相似特征空间的缺陷类型。最终的缺陷分类结果来自条件概率。

[0035] 本发明的基于多任务学习的排水管道异常类型自动检测方法,通过分析管道图像特点,引入多任务学习策略来提升模型性能。本发明与现有技术相比,具有以下优势:

[0036] (1) 同传统手工提取特征方法相比,本方法具有更好的泛化性能。

[0037] (2) 同以往深度学习方法相比,本方法具有更好的检测精度。

附图说明

[0038] 图1为本发明整体流程图。

[0039] 图2为本发明所使用的用于提取图像深度特征的深度残差神经网络结构示意图。

[0040] 图3为各残差卷积块之间Shortcut连接。

[0041] 图4为构建深度特征直方图流程图。

[0042] 图5为本发明用于分类任务的改进深度残差神经网络结构示意图。

[0043] 图6为本发明多任务模块示意图。

具体实施方式

[0044] 下面结合附图,对本发明的技术方案进行具体说明。

[0045] 如图1所示,本发明提供了一种基于多任务学习的排水管道异常类型自动检测方法,包括如下步骤:

[0046] 步骤S1、建立训练数据集:从历史检测报告及排水管道机器人拍摄的视频中随机抽取视频帧形成管道图像集,对于管道图像集里的每个图像,按照城镇排水管道检测与评估技术规程中给出的管道评估方式对图像进行标注,形成管道图像集S和图像标签集 γ ,对于管道图像集S里的每个图像集 $X(n)$,有与之对应的图像标签集 γ , $\gamma = (\gamma(1), \gamma(2), \dots, \gamma(n))$, $\gamma(n)$ 表示第 $\omega(n)$ 张图像所属管道异常类型;管道异常类型可划分为变形、沉积、错口、腐蚀、破裂、起伏、渗漏、树根,依次对应的 γ 值为0,1,2...6,7;按照70%,10%,20%的比例将所述管道图像集划分成训练集、验证集和测试集;在深度学习中,为避免出现过拟合,对训练集中的图像数据进行数据增强和标准化处理;

[0047] 步骤S2、使用步骤S1得到的训练集图像通过梯度下降算法训练深度残差神经网络;

[0048] 步骤S3、使用步骤S2中训练好的神经网络对步骤S1中的训练集图像进行识别,图像依次经过卷积层、池化层获取神经网络倒数第二层特征向量,通过特征向量构建缺陷的深度特征空间,基于深度特征空间构建深度特征直方图;

[0049] 步骤S4、使用步骤S3中得到的各类别深度特征直方图进行相似性度量,一一对比不同类别深度特征直方图的相似性,根据相似性对缺陷进行分组;

[0050] 步骤S5、使用步骤S4中分组结果构建多任务深度残差神经网络,使用步骤S1得到的训练集图像通过梯度下降算法训练神经网络;

[0051] 步骤S6、使用步骤S4中训练好的神经网络对待识别的图像进行识别,图像依次经过卷积层、池化层和激活层后得到图像中包含缺陷的类型。

[0052] 本实例中,所述步骤S1中,对训练集中的图像数据进行数据增强和标准化处理的过程具体包括以下步骤:

[0053] 步骤S11、对训练集中的图像数据进行数据增强;所述进行数据增强的方法包括水平翻转、旋转、改变图像色彩、加入噪声;

[0054] 步骤S12、将步骤S11中的进行数据增强后的图像集按短边等比例缩放至固定大小,范围为256~512之间;

[0055] 步骤S13、对步骤S12缩小后的图片随机裁剪出 224×224 的子图;

[0056] 步骤S14、对步骤S13中产生的子图进行标准化处理,具体采用以下公式:

$$[0057] \quad x_i^* = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}}$$

[0058] 式中, x_i 表示一张图中的其中一个像素点; x_{\min} 表示图中所有像素的最小值点, x_{\max} 表示图中所有像素的最大值点。

[0059] 本实例中,所述步骤S2中,深度残差网络结构(如图2所示)由5个残差卷积块组成,残差卷积块之间通过Shortcut的结构连接(如图3所示),每个残差卷积块由3个卷积层组成,使用 1×1 、 3×3 、 1×1 的3个卷积层串接在一起作为一个残差卷积块。详细参数设置见表1。

[0060] 表1

Layer	Block1	Block2	Block3	Block4	Block5_x	pooling/FC
Output	112×112	56×56	28×28	14×14	7×7	1×1
Filters	7×7×64 stride 2	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	1000-d

[0062] 本实例中,所述步骤S3中,构建深度特征直方图的方式(如图4所示)如下:

[0063] 步骤S31、使用步骤S1中划分好类别的训练集并采用步骤S2中训练好的神经网络提取深度特征,取步骤S2中网络倒数第二层2048维向量作为训练集中每张图像的深度特征向量;

[0064] 步骤S32、将步骤S31中获取的深度特征向量按照类别组合在一起构成深度特征矩阵;

[0065] 步骤S33、对步骤S32中每个类别的深度特征矩阵绘制深度特征直方图。

[0066] 本实例中,所述步骤S4中,根据相似性对缺陷进行分组的方式如下:

[0067] 使用常态分布比对下的巴氏距离作为评估不同类深度特征空间重叠程度的依据,依次计算每两类之间深度特征直方图的巴氏距离,将阈值小于0.1的类别划分至同一组;用于计算直方图相识度的巴氏距离可描述为,对于直方图H1和H2:

$$[0068] \quad D_B(H_1, H_2) = \sqrt{1 - \frac{1}{\sqrt{H_1 H_2 N^2}} \sum_I \sqrt{H_1(I) H_2(I)}}$$

[0069] 式中,H1和H2表示将要对比的直方图,H1(I)和H2(I)表示直方图中的每个像素点的值。

[0070] 本实例中,所述步骤S5中,使用步骤S4中分组结果构建多任务深度残差神经网络的方式(如图5所示)如下:

[0071] 网络以残差网络为主干网,不同任务之间共享前4个残差卷积块,在第4块残差卷积块后形成多任务分支;每个分支由一个残差卷积块,平均池化层,全连接层和一个softmax激活层组成;分支从根据分组结果从功能上划分为两大任务模块(如图6所示):高级任务模块和低级任务模块,高级任务模块的分类目标为对不同分组的缺陷图像进行分类,最终输出图像归属分组的概率;低级任务模块拥有多个子任务,每个子任务对组内不同缺陷缺陷进行分类,最终输出图像归属组内具体类别的概率;缺陷分类结果来自条件概率:

$$[0072] \quad P(B) = \frac{P(A)P(B|A)}{P(A|B)}$$

[0073] 式中,P(A)表示高级任务模块输出概率,P(B|A)表示低级任务模块输出概率,分好组后的缺陷一定会被划分至对应的组中,则条件概率P(A|B)恒等于1,由此得到最终的分类结果;训练选用联合优化训练方法进行训练,联合优化的损失函数可表示为如下形式:

$$[0074] \quad E(x_i) = -\sum_i p_{high}(x_i) \log q_{high}(x_i) - \sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$$

[0075] 式中, $\sum_i p_{high}(x_i) \log q_{high}(x_i)$ 为高级任务的交叉熵损失函数, $\sum_{t=1}^n \sum_i p_{low}^{(t)}(x_i) \log q_{low}^{(t)}(x_i)$

为低级任务各子任务损失函数的和。

[0076] 以上是本发明的较佳实施例,凡依本发明技术方案所作的改变,所产生的功能作用未超出本发明技术方案的范围时,均属于本发明的保护范围。



图1

224×224×3




图2




图3

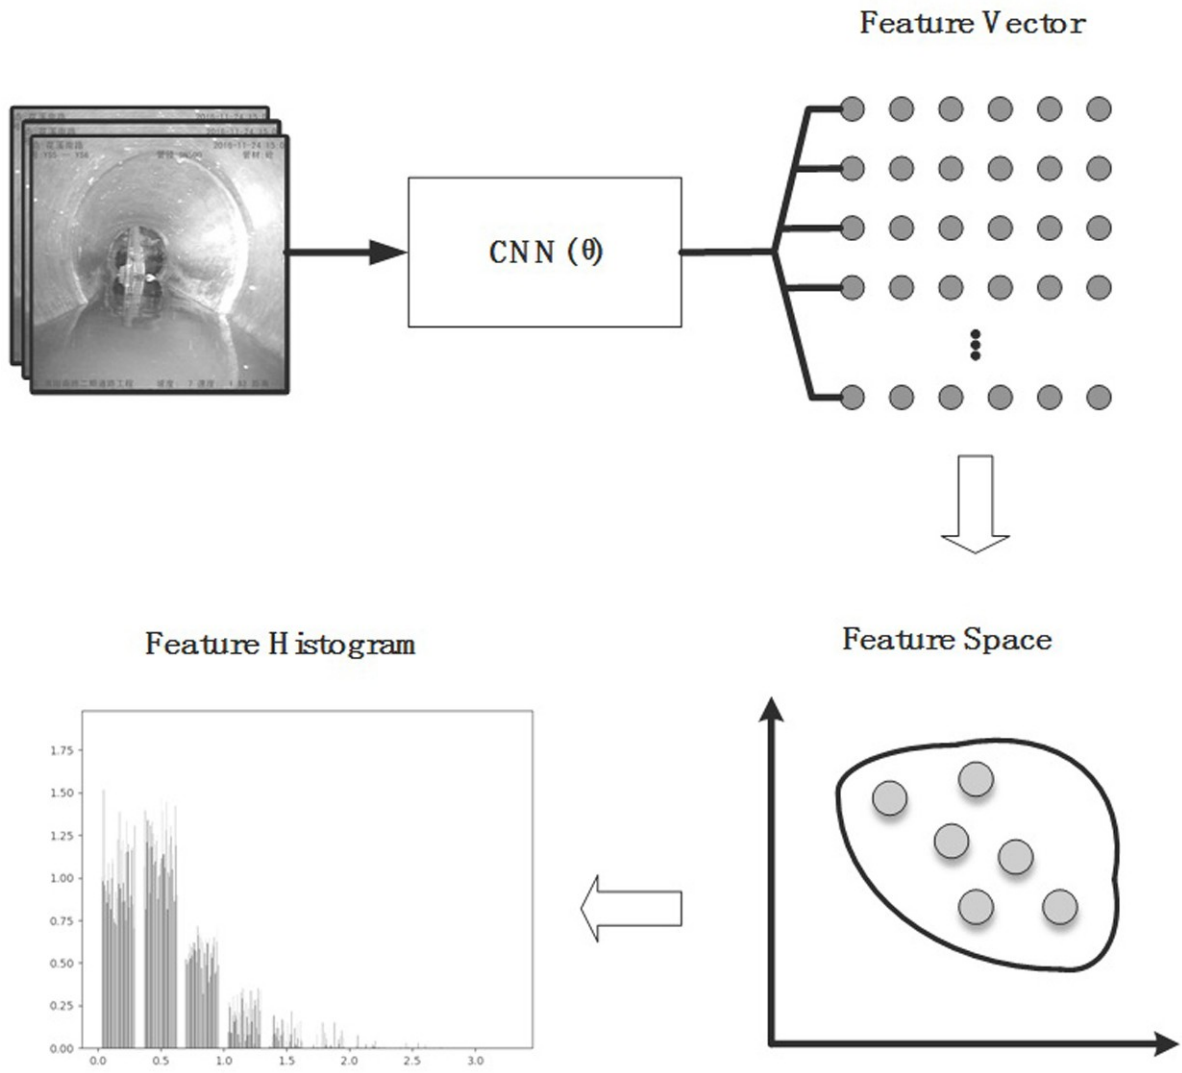


图4

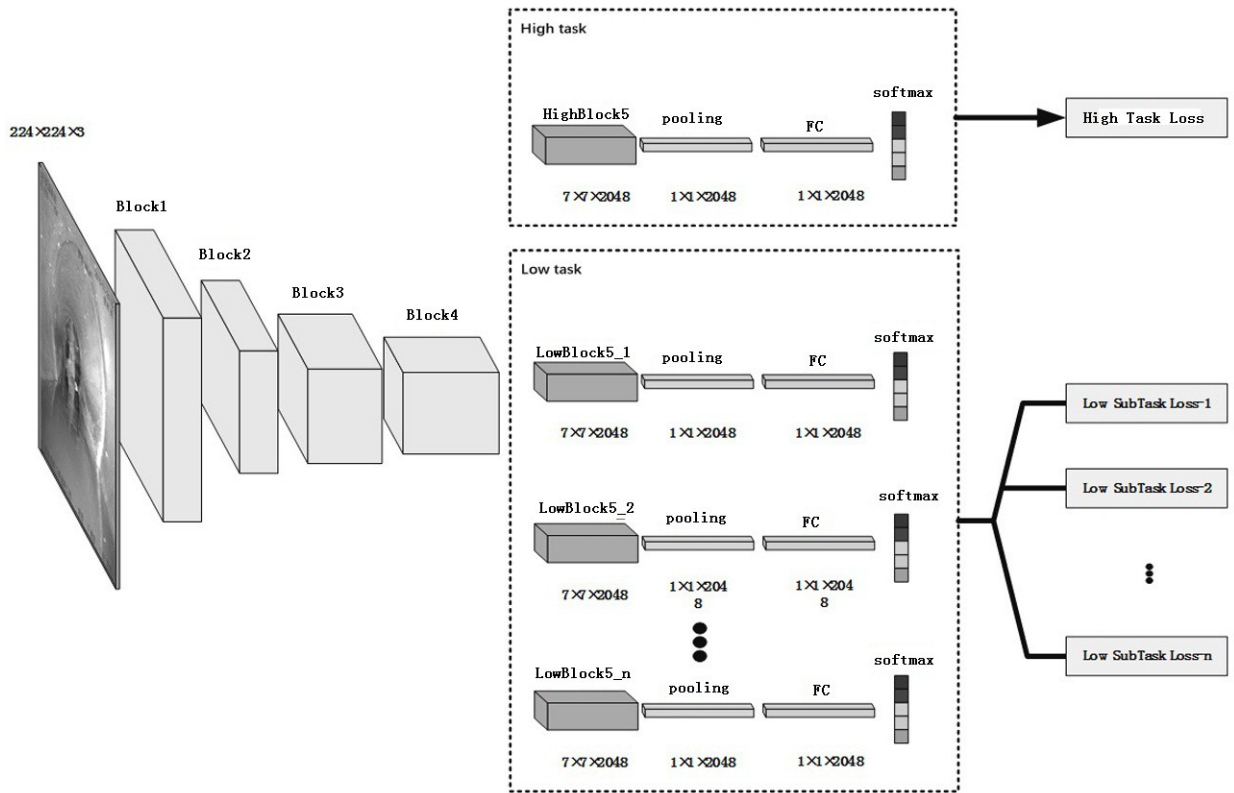


图5

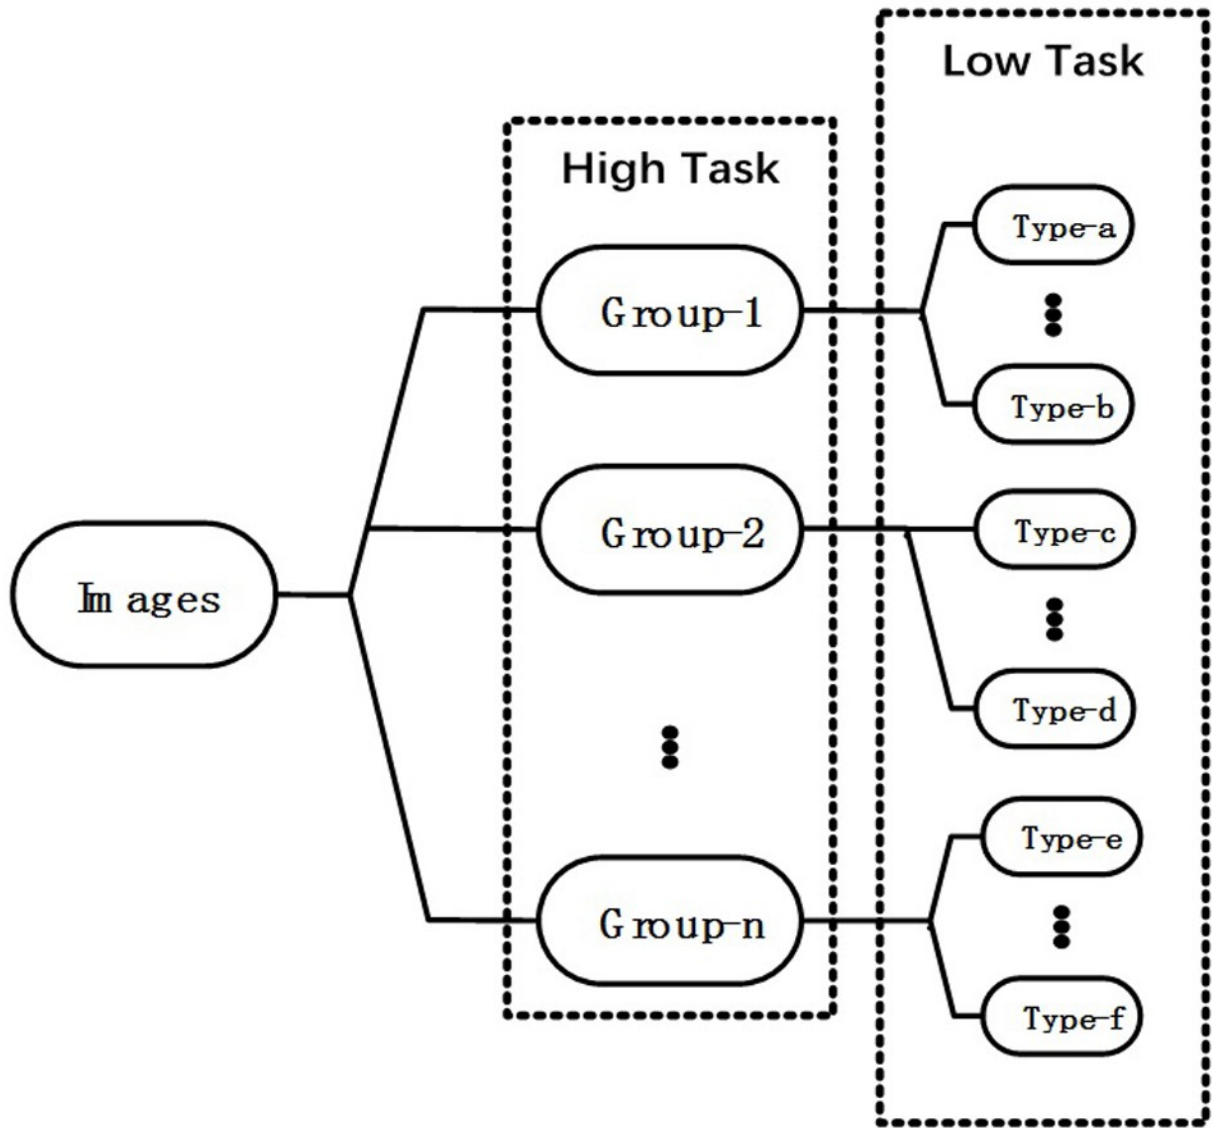


图6