



(12)发明专利申请

(10)申请公布号 CN 110648311 A
(43)申请公布日 2020.01.03

(21)申请号 201910825578.3

(22)申请日 2019.09.03

(71)申请人 南开大学

地址 300350 天津市津南区海河教育园区
同砚路38号

(72)发明人 杨巨峰 伍小平 梁杰

(74)专利代理机构 天津耀达律师事务所 12223
代理人 张耀

(51)Int.Cl.

G06T 7/00(2017.01)

G06T 7/194(2017.01)

G06N 3/04(2006.01)

G06N 3/08(2006.01)


权利要求书1页 说明书4页 附图2页

(54)发明名称

一种基于多任务学习的痤疮图像病灶分割与计数网络模型

(57)摘要

本发明公开了一种基于多任务学习的痤疮图像病灶分割与计数网络模型,属于计算机视觉技术领域。设计了一种多任务学习深度卷积神经网络架构,用于痤疮图像中病灶的分割和数量统计。这种深度卷积神经网络框架以多任务学习的方式共享相关任务之间的表征,利用隐含在多个相关任务的训练信号中的特定领域信息来提高泛化能力,提升模型的分割与计数性能。同时本方法在网络框架中的分割分支利用得到的病灶候选框生成病灶的位置掩码,用于屏蔽具有干扰性的背景区域,从而帮助计数分支得到更精确的计数结果。最终使用计数结果对病灶候选框进行进一步筛选,生成病灶的分割结果,得到的网络模型用于痤疮图像的病灶分割和计数。



1. 一种基于多任务学习的痤疮图像病灶分割与计数网络模型,其特征在于,该网络模型通过计算机系统实现,包括以下模块,

a. 图像特征提取模块:用户输入一张任意尺寸的痤疮图像到深度卷积神经网络模型中,此网络模型对痤疮图形进行特征提取得到卷积特征图;

b. 病灶分割模块:将步骤a得到的卷积特征图通过一个全连接层回归得到存在痤疮病灶的候选框;

c. 病灶计数模块:利用步骤b得到的候选框,生成痤疮图像中病灶的位置掩码,将该位置掩码调整至与步骤a中的卷积特征图一致大小,并进行逐元素相乘操作,得到局部卷积特征,可以有效减少背景信息干扰,然后利用一个新的全连接层回归得到更精确的痤疮图像中病灶的计数结果;

d. 病灶计数筛选模块:将步骤b产生的候选框按置信度从高至低的顺序进行排列,利用步骤c产生的病灶计数结果对候选框进行筛选,得到最终的分割结果;

以上步骤b和c中结合了分割与计数两种损失,痤疮分割损失使用均方和误差损失函数,病灶计数损失使用平均绝对误差损失函数,网络模型平等对待两种损失,同时学习优化痤疮病灶的分割与计数两种任务,通过小批次随机梯度下降优化器训练整个深度卷积神经网络。

2. 根据权利要求1所述的基于多任务学习的痤疮图像病灶分割与计数网络模型,其特征在于:病灶分割模块和病灶计数模块为两个分支结构,两个分支共享卷积层的表示信息,第一个分支用于痤疮分割任务,使用一个全连接层将特征向量映射为49个病灶候选框及其对应的置信度;第二个分支用于痤疮病灶计数任务,使用一个全连接层直接从特征向量上进行痤疮病灶数量的回归,然后通过一个ReLU激活层保证预测结果的非负性。

3. 根据权利要求1或2所述的基于多任务学习的痤疮图像病灶分割与计数网络模型,其特征在于:病灶的分割与计数任务所产生的结果相互之间存在着交互,病灶的分割过程中产生的候选框作为位置掩码的生成依据,表示痤疮图像中对应空间位置上是否存在病灶,通过在卷积特征图上与该掩码逐元素相乘,得到局部的卷积特征图,从而有效地减少背景信息对痤疮病灶计数任务的干扰;计数任务得到的病灶计数结果可以进一步作为病灶候选框的筛选依据,通过选取置信度相对较高的候选框,得到更加可靠准确的病灶分割结果。

4. 根据权利要求1所述的基于多任务学习的痤疮图像病灶分割与计数网络模型,其特征在于:步骤b的病灶分割模块是使用一个全连接层将其映射为预测的候选框坐标位置和对置信度,计算均方和误差损失:

$$L_{seg}(\{p_i\}, \{t_i\}) = L_{conf}(p_i, p_i^*) + \lambda p_i^* L_{box}(t_i, t_i^*)$$

其中, i 表示图像中预测的一个病灶候选框的索引, p_i 表示第 i 个候选框的置信度预测结果, p_i^* 对应其真实的标签, t_i 为预测候选框的4个参数坐标的向量, t_i^* 是正样本的真实坐标。

5. 根据权利要求1所述的基于多任务学习的痤疮图像病灶分割与计数网络模型,其特征在于:步骤c中通过使用外接矩形对第一个分支产生的所有候选框进行截取,获得一个覆盖了痤疮病灶区域的位置掩码,然后在卷积特征图的各个通道上与该掩码进行逐元素相乘的操作,得到局部卷积特征。

一种基于多任务学习的痤疮图像病灶分割与计数网络模型

技术领域

[0001] 本发明属于计算机视觉技术领域,特别涉及到一种通过计算机网络模型实现基于多任务学习的痤疮图像病灶分割与计数的方法。

背景技术

[0002] 寻常痤疮(俗称痤疮)是最常见的皮肤病之一,其流行高峰期在青春期,以脸部出现粉刺、丘疹等病灶为主要特点。而希望通过人工的方式快速地获取痤疮图像中病灶的具体位置和数量信息是耗时的,因为痤疮发生的病灶位置不固定并且其数量从若干至几十个不等。因此,一种基于多任务学习的痤疮图像病灶分割与计数算法的开发会快速有效地产生辅助信息,即病灶的分割信息和计数信息。

[0003] 近年来,痤疮病灶分析取得了长足的进展。以手工特征为代表,例如,Abas 等2016年在SPIE发表的论文“Acne image analysis:Lesion localization and classification”中利用基于熵的滤波和阈值法检测痤疮病灶的位置,然后利用离散小波帧和灰度共现矩阵提取特征。近年来,深度学习(deep learning,DL)技术在医学图像处理领域表现出了强大的性能,如常见的胸腔疾病分析和生物医学分割。对于痤疮图像病灶分割与计数的多任务框架,广泛使用的深度卷积神经网络可以作为其基础部分。

[0004] 对于痤疮病灶数量的计数,我们可以通过深度卷积神经网络或者现有成熟的对象位置检测框架来选择回归的方式,与之最接近的是人群计数任务。人群计数使用了多种技术,从基于方向梯度直方图的头部位置检测器到基于卷积神经网络的回归。Zhang等2016年在CVPR发表的论文“Single-image crowd counting via multi-column convolutional neural network”中,首先研究了全卷积神经网络中基于热力图的人群计数,随后Marsden等2017年在CVPR 发表的论文“Fully convolutional crowd counting on highly congested scenes”中,研究了全卷积神经网络中基于热力图的人群计数,观察到显著的性能提升。Sam等2017年在CVPR发表的论文“Switching convolutional neural network for crowd counting”中,提出了一种新的人群计数模型切换技术,该技术首先对图像区域的人群密度进行估计,然后使用针对检测到的人群密度进行优化的网络进行基于热力图的计数。

[0005] 多任务学习算法同时优化多个学习任务,挖掘任务间的共性和差异性,提高任务的泛化性能。例如,Luong等2016年在ICLR发表的论文“Multitask sequence to sequence learning”中,将多任务学习与编码器-解码器模型集成,在任务之间共享编码器和解码器的参数。多任务学习在计算机视觉和多媒体的许多其它领域也很流行。例如,Yuan等2016年在IEEE transactions on cybernetics发表的论文“Hyperspectral image classification via multitask joint sparse representation and stepwise mrf optimization”中,提出了一种用于高光谱图像的光谱空间分析策略,主要利用多任务学习的优势,联合学习稀疏表示和逐步的马尔科夫随机场。当需要同时优化若干单个任务时,多任务学习的应用进一步促进了模型的泛化性能。通过共享相关任务直接的表示特征,达到

多个任务同时预测的同时还减少了模型参数的规模,使得多个任务学习的过程和结果更加高效。

[0006] 上述领域的一些最新成果激发了我们的灵感,也为我们开发基于多任务学习的高效分割与计数方法提供了坚实的技术基础。

发明内容

[0007] 本发明需要解决的技术问题是输入一张任意尺寸的痤疮图像,系统可以同时预测痤疮的分割和病灶的计数结果。

[0008] 为了实现本发明的目的,我们依靠以下技术方案来实现:

[0009] 一种基于多任务学习的痤疮图像病灶分割与计数网络模型,包括图像特征提取模块、病灶分割模块、病灶计数模块、病灶计数筛选模块,各模块中:

[0010] a. 图像特征提取模块:用户输入一张任意尺寸的痤疮图像到深度卷积神经网络模型中,此网络模型对痤疮图形进行特征提取得到卷积特征图;

[0011] b. 病灶分割模块:将步骤a得到的卷积特征图通过一个全连接层回归得到存在痤疮病灶的候选框;

[0012] c. 病灶计数模块:利用步骤b得到的候选框,生成痤疮图像中病灶的位置掩码,将该位置掩码调整至与步骤a中的卷积特征图一致大小,并进行逐元素相乘操作,得到局部卷积特征,可以有效减少背景信息干扰,然后利用一个新的全连接层回归得到更精确的痤疮图像中病灶的计数结果;

[0013] d. 病灶计数筛选模块:将步骤b产生的候选框按置信度从高至低的顺序进行排列,利用步骤c产生的病灶计数结果对候选框进行筛选,得到最终的分割结果;

[0014] e. 此网络模型结合了分割与计数两种损失,痤疮分割损失使用均方和误差损失函数,病灶计数损失使用平均绝对误差损失函数,网络模型平等对待两种损失,同时学习优化痤疮病灶的分割与计数两种任务,通过小批次随机梯度下降优化器训练整个深度卷积神经网络。

[0015] 本发明网络模型中,病灶分割模块和病灶计数模块为两个分支结构,两个分支共享卷积层的表示信息,第一个分支用于痤疮分割任务,使用一个全连接层将特征向量映射为49个病灶候选框及其对应的置信度;第二个分支用于痤疮病灶计数任务,使用一个全连接层直接从特征向量上进行痤疮病灶数量的回归,然后通过一个ReLU激活层保证预测结果的非负性。

[0016] 病灶的分割与计数任务所产生的结果相互之间存在着交互,病灶的分割过程中产生的候选框作为位置掩码的生成依据,表示痤疮图像中对应空间位置上是否存在病灶,通过在卷积特征图上与该掩码逐元素相乘,得到局部的卷积特征图,从而有效地减少背景信息对痤疮病灶计数任务的干扰;计数任务得到的病灶计数结果可以进一步作为病灶候选框的筛选依据,通过选取置信度相对较高的候选框,得到更加可靠准确的病灶分割结果。

[0017] 本发明的有益效果为:本发明能够简单地嵌入到面向广大人群使用的计算机辅助系统中,对于医疗影像处理任务都适用,有效辅助和加快痤疮图像中病灶的分割和计数过程。本发明以多任务学习的方式同时进行痤疮图像的病灶分割与计数任务,在有效减少了深度网络模型的参数量的同时也提升了系统的性能表现。总的来说,本发明为痤疮图像病

灶分割与计数任务提供了一个全新的方案,相信该方法同样能应用到很多其它计算机视觉任务中。

附图说明

[0018] 下面结合附图和具体实施方式对本发明作进一步详细的说明:

[0019] 图1为基于多任务学习的痤疮图像病灶分割与计数方法的架构图。

[0020] 图2为基于多任务学习的痤疮图像病灶分割与计数方法的流程图。

[0021] 图3为基于多任务学习的痤疮图像病灶分割与计数方法的实例图。

具体实施方式

[0022] 本发明设计了一种新的深度卷积神经网络多任务学习架构,即在网络模型的卷积层相同之后包含两个分支,第一个分支为分割分支,第二个分支为计数分支,它们结合了痤疮病灶分割和计数两个任务。并采取有效措施使得这两个任务的结果相互促进,通过从分割分支获取的候选框生成覆盖了痤疮病灶区域的位置掩码,有效减少背景信息对计数分支的干扰。并进一步使用计数分支预测的计数结果对候选框进行筛选,从而得到最终的痤疮图像病灶分割结果。下面结合附图,对本发明的具体实施方式作进一步详细描述。以下实施例用于说明本发明,但不用来限制本发明的范围。

[0023] 参照图1,表示本发明改进的深度卷积神经网络架构,下面详述设计过程:

[0024] 本网络模型的基本架构可以是任意的卷积神经网络,所起的是特征提取的作用,以下以He Kaiming等2016在CVPR发表的“Deep residual learning for image recognition”文章中提到的ResNet-50为例。在卷积层共享的基础上,网络对输入的痤疮图像进行特征提取得到特征卷积图,然后包含两个分支部分。

[0025] 第一个分支用于痤疮分割任务,使用一个全连接层将其映射为预测的候选框坐标位置和对置信度,计算均方和误差损失:

$$[0026] \quad L_{seg}(\{p_i\}, \{t_i\}) = L_{conf}(p_i, p_i^*) + \lambda p_i^* L_{box}(t_i, t_i^*)$$

[0027] 其中, i 表示图像中预测的一个病灶候选框的索引, p_i 表示第 i 个候选框的置信度预测结果, p_i^* 对应其真实的标签,当预测的候选框与真实的病灶位置重叠率(两个框面积的交集除以并集)超过0.7时表示正样本,其值为1,否则为0。 t_i 为预测候选框的4个参数坐标的向量, t_i^* 是正样本的真实坐标。候选框置信度损失使用对数损失函数:

$$L_{conf}(p_i, p_i^*) = -\log [p_i^* p_i + (1 - p_i^*)(1 - p_i)], \text{ 候选框坐标的损失使用平滑L1损失:}$$

$$L_{box}(t_i, t_i^*) = \text{smooth}_{L_1}(t_i, t_i^*), \text{ 令 } x = t_i - t_i^*, \text{ 则:}$$

$$[0028] \quad \text{smooth}_{L_1}(x) = \begin{cases} 0.5x^2 & \text{if } |x| < 1 \\ |x| - 0.5 & \text{otherwise} \end{cases}$$

[0029] 候选框的置信度和候选框坐标的损失通过平衡参数 λ 进行加权,通过参数验证,我们设置此参数值为10。

[0030] 第二个分支用于痤疮病灶计数任务。为了降低背景信息的干扰,首先使用外接矩

形对第一个分支产生的所有候选框进行截取,获得一个覆盖了痤疮病灶区域的位置掩码,然后在卷积特征图的各个通道上与该掩码进行逐元素相乘的操作,得到局部卷积特征。然后通过一个全局平均池化层得到特征向量表示,通过一个全连接层和一个ReLU激活层回归预测痤疮病灶的数量 c ,并根据真实痤疮病灶数量 c^* 计算平均绝对误差损失

$L_{cou}(c, c^*) = \text{smooth}_{L_1}(c, c^*)$ 。预测的痤疮病灶数量 c 可以对第一个分支的得到的候选框进一步筛选,首先将每个候选框对应的置信度按从大至小的顺序排列,选择前 c 个置信度对应的候选框最为模型最终的病灶分割结果。

[0031] 网络模型的两个分支损失采用多任务的结合方式进行统一优化:

$$[0032] \quad L = L_{\text{seg}} + \alpha L_{\text{cou}}$$

[0033] 其中 α 为平衡分割分支和计数分支的权重因子,因为两个分支同等重要,所以我们设定 $\alpha = 1$ 。

[0034] 参照图2本发明的方法流程图和图3本发明的实例图,下面详述使用过程:

[0035] 首先对图3第一行进行分析,对于用户输入的任意尺寸的痤疮图像3(a),先将该图像送入训练好的深度神经网络中,网络提取出图像的卷积特征表示,即网络最后一层卷积特征图。

[0036] 痤疮病灶分割分支利用一个全连接层以回归的方式得到大量病灶的候选框 (b) 以及对应的置信度。然后将所得到的候选框的最大外接矩形作为病灶位置掩码(c),该掩码反映了痤疮图像中病灶的存在位置,并屏蔽了具有干扰性的背景区域。接着将该掩码与卷积特征图在各通道上逐元素相乘得到局部卷积特征。

[0037] 痤疮病灶计数分支在分割分支的局部卷积特征的基础上,使用一个新的全连接层进行回归得到痤疮病灶的计数结果(e),然后通过ReLU层得到非负结果3。

[0038] 最终对痤疮病灶分割分支生成的候选框对应的置信度按从大至小顺序排列,选取前3个置信度最大的候选框作为最终的分割结果(d)。

[0039] 图3中的第二行和第三行与第一行效果相同,都是用于展示本发明的实际应用效果,另外这三行的输入图像(a)中所包含的痤疮病灶数量是不同的,分别为3、15和32个病灶,而中间过程(b-c)与最终结果(d-e)证明本发明在不同场景下都是有效的。

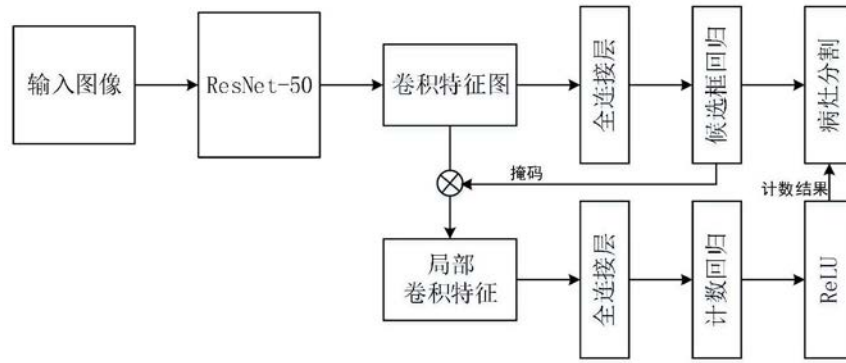


图1

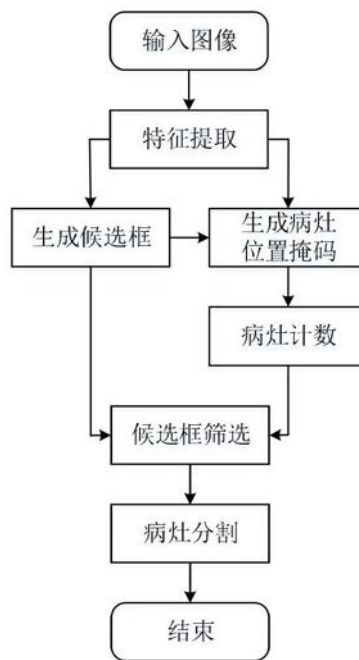


图2




图3