



(12) 发明专利申请

(10) 申请公布号 CN 112819096 A

(43) 申请公布日 2021.05.18

(21) 申请号 202110219351.1

(22) 申请日 2021.02.26

(71) 申请人 西北大学

地址 710069 陕西省西安市太白北路229号

(72) 发明人 张蕾 王晓宇 罗杰 卜起荣

冯筠

(74) 专利代理机构 西安恒泰知识产权代理事务

所 61216

代理人 孙雅静

(51) Int. Cl.

G06K 9/62 (2006.01)

G06K 9/46 (2006.01)

G06N 3/08 (2006.01)

G06N 3/04 (2006.01)

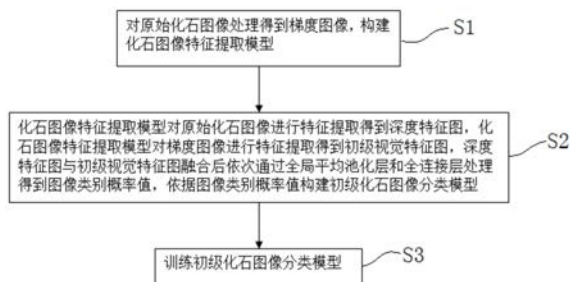
权利要求书2页 说明书10页 附图2页

(54) 发明名称

一种基于复合卷积神经网络的化石图像分类模型的构建方法

(57) 摘要

本发明公开了一种基于复合卷积神经网络的化石图像分类模型的构建方法,包括如下步骤:S1:对原始化石图像处理得到梯度图像,构建化石图像特征提取模型;S2:化石图像特征提取模型对原始化石图像进行特征提取得到深度特征图,化石图像特征提取模型对梯度图像进行特征提取得到初级视觉特征图,深度特征图与初级视觉特征图融合后依次通过全局平均池化层和全连接层处理得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型;S3:训练初级化石图像分类模型。本发明分别提取了原始化石图像的深度特征与对应梯度图像的初级视觉特征,通过特征融合,进一步提高了化石图像分类任务的准确性。



1. 一种基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,包括如下步骤:

S1:对原始化石图像处理得到梯度图像,构建化石图像特征提取模型;

S2:化石图像特征提取模型对原始化石图像进行特征提取得到深度特征图,化石图像特征提取模型对梯度图像进行特征提取得到初级视觉特征图,深度特征图与初级视觉特征图融合后依次通过全局平均池化层和全连接层处理得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型;

S3:训练初级化石图像分类模型。

2. 根据权利要求1所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述S2进一步包括:

S21:深度特征图与初级视觉特征图从通道维度进行融合得到融合特征图;

S22:融合特征图输入全局平均池化层输出得到特征向量;

S23:特征向量经过全连接层的卷积及分类得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型。

3. 根据权利要求1或2所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,利用Canny算子对原始化石图像处理得到梯度图像;

全连接层的分类通过Softmax分类器完成。

4. 根据权利要求1或2所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述S3进一步包括:

S31:构建目标损失函数;

S32:使用ResNet50深度残差网络初始化化石图像特征提取模型的网络参数,按照正态分布初始化全连接层的网络参数;

S33:对于待处理数据集中的原始化石图像,随机选择80%的原始化石图像作为训练集图像,10%的原始化石图像作为验证集图像;

S34:原始训练集图像和预处理后的训练集图像,输入化石图像分类模型中,采用批梯度下降的训练方法来最小化所述的目标损失函数值,得到训练好的化石图像分类网络的权重;

S35:通过预处理后的验证集图像的目标损失函数值进行反馈,若目标损失函数值小于训练好的化石图像分类网络的权重,则对化石图像分类网络的权重进行更新,否则保存化石图像分类网络的权重。

5. 根据权利要求4所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述S31进一步包括:

构建目标损失函数L,表示为:

$$L = -\theta \alpha (1-b)^\gamma \log(b) - (1-\theta) \log(b)$$

其中, $\alpha \in [0, 1]$ 为权重因子; $\gamma > 0$ 为调制因子; θ 是超参数; $b \in [0, 1]$ 表示估计概率。

6. 根据权利要求1或2所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述的化石图像特征提取模型的构建方法包括:

S1:建立可堆叠的复合卷积残差块,设置所述复合卷积残差块的基础通道数目及空洞卷积膨胀率;

S2:堆叠所述的复合卷积残差块形成不同深度的神经架构,神经架构的深度由不同任务所在的图像数据集确定;

S1中所述的复合卷积残差块设置:

第一层:1×1大小的卷积核,减少模型的计算参数;

第二层:3×3卷积运算,结合传统卷积和空洞卷积,传统卷积捕获连续的结构性依赖特征,空洞卷积捕获间隔距离较远的结构依赖关系;

第三层:1×1卷积核,还原特征图的数量。

7.根据权利要求6所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述的基础通道数目随神经架构的深度变深而线性增加。

8.根据权利要求1或2所述的基于复合卷积神经网络的化石图像分类模型的构建方法,其特征在于,所述的化石图像特征提取模型具有表1所示的结构:

表1化石图像特征提取模型网络结构

Layer Name	Output Size	Network Structure
Conv1	112×112	7×7, 64, stride 2 3×3 max pool, stride 2
HRes-Group1	56×56	$\left[\begin{array}{l} 1 \times 1 \text{ conv}2d, 64 \\ 3 \times 3 \text{ conv}2d, 32 \quad 3 \times 3 \text{ d - conv}2d, 32 \\ 1 \times 1 \text{ conv}2d, 256 \end{array} \right] \times 2$
HRes-Group2	28×28	$\left[\begin{array}{l} 1 \times 1 \text{ conv}2d, 128 \\ 3 \times 3 \text{ conv}2d, 64 \quad 3 \times 3 \text{ d - conv}2d, 64 \\ 1 \times 1 \text{ conv}2d, 512 \end{array} \right] \times 2$
HRes-Group3	14×14	$\left[\begin{array}{l} 1 \times 1 \text{ conv}2d, 256 \\ 3 \times 3 \text{ conv}2d, 128 \quad 3 \times 3 \text{ d - conv}2d, 128 \\ 1 \times 1 \text{ conv}2d, 1024 \end{array} \right] \times 2$
HRes-Group4	7×7	$\left[\begin{array}{l} 1 \times 1 \text{ conv}2d, 512 \\ 3 \times 3 \text{ conv}2d, 256 \quad 3 \times 3 \text{ d - conv}2d, 256 \\ 1 \times 1 \text{ conv}2d, 1024 \end{array} \right] \times 2$

9.一种化石图像分类方法,其特征在于,包括:预处理待测化石图像得到梯度图像;

将待测化石图像与对应的梯度图像输入权利要求1-8任一所述的基于复合卷积神经网络的化石图像分类模型的构建方法构建得到的化石图像分类模型对其类别进行预测分类,得到化石图像所属类别。

10.一种计算机可读存储介质,其特征在于,所述计算机可读存储介质存储有计算机指令,所述计算机指令用于使所述计算机执行如权利要求1-8任一所述的基于复合卷积神经网络的化石图像分类模型的构建方法。

一种基于复合卷积神经网络的化石图像分类模型的构建方法

技术领域

[0001] 本发明涉及图像处理技术领域,涉及图像分类方法,具体涉及一种基于复合卷积神经网络的化石图像分类模型的构建方法。

背景技术

[0002] 在以往的微体化石分类工作中,所使用的方法通常是人工分拣,但是由于微体化石个体过于细小,在肉眼观察下是很难发现或是分类,所以是在人工通过显微镜进行观察后分类。随着考古发掘等工作的进行,不断有着新类型的微体化石种类被发现出来,这就使得总体样本种类数增加,人工分拣挑选等工作的效率更加低下。整个过程枯燥乏味且随着时间会增加出错概率,同时长时间的高强度观测会对观测人员的视力等身体健康条件等造成严重损伤。

[0003] 随着人工智能的发展,深度学习的研究取得了很大的进步,逐渐在日常工作中起着愈发重要的作用,并在图像分类任务中取得了越来越显著的效果。它可以通过少量样本数据进行学习,通过网络模型自动获取最为合适的特征以供分类使用,不需要人为进行合适的特征挑选,并且可以获得较高的分类准确率。通过利用卷积神经网络对于微体化石图像进行分类,在节省了大量的人工资源的同时,可以保证较高的分类准确率和极高的工作效率,对考古工作提供一定的参考价值。

[0004] 现有的研究技术主要包括:基于图像特征的方法与基于深度学习的方法。传统的基于图像特征的化石图像分类方法,需要经过复杂的特征提取与特征优化步骤,算法复杂度较高;而现有的基于深度学习的化石图像模型,仅仅从原始图像中提取特征,没有从图像梯度变化的角度进行初级视觉特征的增强,且网络层数较深,容易过度拟合化石图像分类任务。

发明内容

[0005] 本发明的目的在于针对化石图像分类任务的算法复杂度较高、训练速度较慢、易发生过拟合、检测精度较低的问题,提出一种基于复合卷积神经网络的化石图像分类模型的构建方法。

[0006] 为了实现上述任务,本发明采用以下技术方案:

[0007] 一种基于复合卷积神经网络的化石图像分类模型的构建方法,包括如下步骤:

[0008] S1:对原始化石图像处理得到梯度图像,构建化石图像特征提取模型;

[0009] S2:化石图像特征提取模型对原始化石图像进行特征提取得到深度特征图,化石图像特征提取模型对梯度图像进行特征提取得到初级视觉特征图,深度特征图与初级视觉特征图融合后依次通过全局平均池化层和全连接层处理得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型;

[0010] S3:训练初级化石图像分类模型。

[0011] 可选的,所述S2进一步包括:

- [0012] S21:深度特征图与初级视觉特征图从通道维度进行融合得到融合特征图;
- [0013] S22:融合特征图输入全局平均池化层输出得到特征向量;
- [0014] S23:特征向量经过全连接层的卷积及分类得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型。
- [0015] 可选的,利用Canny算子对原始化石图像处理得到梯度图像;
- [0016] 全连接层的分类通过Softmax分类器完成。
- [0017] 可选的,所述S3进一步包括:
- [0018] S31:构建目标损失函数;
- [0019] S32:使用ResNet50深度残差网络初始化化石图像特征提取模型的网络参数,按照正态分布初始化全连接层的网络参数;
- [0020] S33:对于待处理数据集中的原始化石图像,随机选择80%的原始化石图像作为训练集图像,10%的原始化石图像作为验证集图像;
- [0021] S34:原始训练集图像和预处理后的训练集图像,输入化石图像分类模型中,采用批梯度下降的训练方法来最小化所述的目标损失函数值,得到训练好的化石图像分类网络的权重;
- [0022] S35:通过预处理后的验证集图像的目标损失函数值进行反馈,若目标损失函数值小于训练好的化石图像分类网络的权重,则对化石图像分类网络的权重进行更新,否则保存化石图像分类网络的权重。
- [0023] 可选的,所述S31进一步包括:
- [0024] 构建目标损失函数L,表示为:
- [0025] $L = -\theta a (1-b)^{\gamma} \log(b) - (1-\theta) \log(b)$
- [0026] 其中, $a \in [0,1]$ 是一个权重因子,用于调节和平衡不同类别样本的重要程度; $\gamma > 0$ 是一个调制因子,用于调整易分类样本的权重; θ 是用于调整两种损失函数权重的超参数; $b \in [0,1]$ 表示模型对样本真实标签的估计概率。
- [0027] 可选的,所述的化石图像特征提取模型的构建方法包括:
- [0028] S1:建立可堆叠的复合卷积残差块,设置所述复合卷积残差块的基础通道数目及空洞卷积膨胀率;
- [0029] S2:堆叠所述的复合卷积残差块形成不同深度的神经架构,神经架构的深度由不同任务所在的图像数据集确定;
- [0030] S1中所述的复合卷积残差块设置:
- [0031] 第一层:1×1大小的卷积核,减少模型的计算参数;
- [0032] 第二层:3×3卷积运算,结合传统卷积和空洞卷积,传统卷积捕获连续的结构性依赖特征,空洞卷积捕获间隔距离较远的结构依赖关系;
- [0033] 第三层:1×1卷积核,还原特征图的数量。
- [0034] 可选的,所述的基础通道数目随神经架构的深度变深而线性增加。
- [0035] 可选的,所述的化石图像特征提取模型具有表1所示的结构:
- [0036] 表1化石图像特征提取模型网络结构

Layer Name	Output Size	Network Structure
Conv1	112×112	7×7, 64, stride 2 3×3 max pool, stride 2
[0037] HRes-Group1	56×56	$\left[\begin{array}{cc} 1 \times 1 \text{ conv2d}, 64 & \\ 3 \times 3 \text{ conv2d}, 32 & 3 \times 3 \text{ d-conv2d}, 32 \end{array} \right] \times 2$ $1 \times 1 \text{ conv2d}, 256$
HRes-Group2	28×28	$\left[\begin{array}{cc} 1 \times 1 \text{ conv2d}, 128 & \\ 3 \times 3 \text{ conv2d}, 64 & 3 \times 3 \text{ d-conv2d}, 64 \end{array} \right] \times 2$ $1 \times 1 \text{ conv2d}, 512$
HRes-Group3	14×14	$\left[\begin{array}{cc} 1 \times 1 \text{ conv2d}, 256 & \\ 3 \times 3 \text{ conv2d}, 128 & 3 \times 3 \text{ d-conv2d}, 128 \end{array} \right] \times 2$ $1 \times 1 \text{ conv2d}, 1024$
HRes-Group4	7×7	$\left[\begin{array}{cc} 1 \times 1 \text{ conv2d}, 512 & \\ 3 \times 3 \text{ conv2d}, 256 & 3 \times 3 \text{ d-conv2d}, 256 \end{array} \right] \times 2$ $1 \times 1 \text{ conv2d}, 1024$

[0038] 一种化石图像分类方法,包括:预处理待测化石图像得到梯度图像;

[0039] 将待测化石图像与对应的梯度图像输入本发明所述的基于复合卷积神经网络的化石图像分类模型的构建方法构建得到的化石图像分类模型对其类别进行预测分类,得到化石图像所属类别。

[0040] 一种计算机可读存储介质,所述计算机可读存储介质存储有计算机指令,所述计算机指令用于使所述计算机执行本发明所述的基于复合卷积神经网络的化石图像分类模型的构建方法。

[0041] 本发明与现有技术相比具有以下技术特点:

[0042] (1) 本发明在构建特征提取网络方面,提出了可堆叠的复合卷积残差块,用于堆叠形成不同深度的神经架构,具体深度由不同任务所在的图像数据集而定。该模块结合了传统卷积和空洞卷积,前者捕获连续的结构性依赖特征,后者捕获间隔距离较远的结构依赖关系,在不增加参数量的情况下增大感受野。

[0043] (2) 本发明在构建化石分类模型方面,分别提取了原始化石图像的深度特征与化石梯度图像的初级视觉特征,如图像的结构成分、边缘纹理等信息,通过特征之间的融合,进一步提高了化石图像分类任务的准确性。

[0044] (3) 本发明针对现有的化石图像分类模型所使用的分类损失函数不能很好的解决样本类别数量不均衡问题和缓解过拟合问题,构建了一种新的目标损失函数,使得模型能够在减小易分类样本损失比重的同时,更加关注难分类样本,有效的提高了化石图像分类模型的准确性。

附图说明

[0045] 附图是用来提供对本公开的进一步理解,并且构成说明书的一部分,与下面的具体实施方式一起用于解释本公开,但并不构成对本公开的限制。在附图中:

[0046] 图1为本发明基于复合卷积神经网络的化石图像分类模型的构建方法流程图;

[0047] 图2为本发明的化石图像特征提取模型的构建方法流程图;

[0048] 图3为本发明的复合卷积残差块的结构示意图;

[0049] 图4为本发明的化石图像特征提取模型对原始化石图像提取深度特征示意图。

具体实施方式

[0050] 为了对发明的技术特征、目的和效果有更加清楚的理解,现对照附图说明本发明的具体实施方式。

[0051] 结合图1、2和3,本发明的基于复合卷积神经网络的化石图像分类模型的构建方法,包括如下步骤:

[0052] S1:对原始化石图像处理得到梯度图像,构建化石图像特征提取模型;本发明所用的原始化石图像为JPEG格式;本发明所指的梯度图像是指使用Canny算子对原始化石图像的灰度图像计算得到的图像。

[0053] S2:化石图像特征提取模型对原始化石图像进行特征提取得到深度特征,化石图像特征提取模型对梯度图像进行特征提取得到初级视觉特征,深度特征与初级视觉特征融合后依次通过全局平均池化层和全连接层处理得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型;本发明所指的初级视觉特征是指从原始化石图像对应的梯度图像中提取到的颜色、边缘纹理、结构关系等特征;深度特征是指从原始化石图像中所提取到的抽象语义特征,将化石图像特征提取模型各个阶段提取到的深度特征进行可视化,如图4所示。

[0054] S3:训练初级化石图像分类模型,此处的训练过程包括对化石图像特征提取模型的训练,本发明中将化石图像特征提取模型嵌入到化石图像分类模型中,共同形成最终的化石图像分类模型。

[0055] 在本公开的实施例中,S2进一步包括:

[0056] S21:深度特征图与初级视觉特征图从通道维度进行融合得到融合特征图;

[0057] S22:融合特征图输入全局平均池化层输出得到特征向量;

[0058] S23:特征向量经过全连接层的卷积及分类得到图像类别概率值,依据图像类别概率值构建初级化石图像分类模型。

[0059] 具体的,利用Canny算子对原始化石图像处理得到梯度图像;全连接层的分类通过Softmax分类器完成。

[0060] 在本公开的实施例中,S3进一步包括:

[0061] S31:构建目标损失函数;

[0062] S32:使用ResNet50深度残差网络初始化化石图像特征提取模型的网络参数,按照正态分布初始化全连接层的网络参数;

[0063] S33:对于待处理数据集中的原始化石图像,随机选择80%的原始化石图像作为训练集图像,10%的原始化石图像作为验证集图像;

[0064] S34:原始训练集图像和预处理后的训练集图像,输入化石图像分类模型中,采用批梯度下降的训练方法来最小化所述的目标损失函数值,得到训练好的化石图像分类网络的权重;

[0065] S35:通过预处理后的验证集图像的目标损失函数值进行反馈,若目标损失函数值小于训练好的化石图像分类网络的权重,则对化石图像分类网络的权重进行更新,否则保存化石图像分类网络的权重。

[0066] 具体的,目标损失函数L表示为:

[0067] $L = -\theta a (1-b)^y \log(b) - (1-\theta) \log(b)$

[0068] 其中, $\alpha \in [0, 1]$ 是一个权重因子, 用于调节和平衡不同类别样本的重要程度; $\gamma > 0$ 是一个调制因子, 用于调整易分类样本的权重; θ 是用于调整两种损失函数权重的超参数; $b \in [0, 1]$ 表示模型对样本真实标签的估计概率。

[0069] 结合图2, 在本公开的实施例中, 化石图像特征提取模型的构建方法包括:

[0070] S11: 建立可堆叠的复合卷积残差块, 设置所述复合卷积残差块的基础通道数目及空洞卷积膨胀率; 比如在本发明中设置的空洞卷积膨胀率为2。

[0071] S12: 堆叠所述的复合卷积残差块形成不同深度的神经架构, 神经架构的深度由不同任务所在的图像数据集确定; 由于不同图像数据集中输入图像的分辨率不同, 因此需要根据不同数据集重新设定网络的深度; 比如在本发明中形成的化石图像特征提取模型的神经架构为: 输入图像 → 卷积层 → 最大池化层 → 8个复合卷积残差块进行堆叠 → 输出特征图。

[0072] S11中所述的复合卷积残差块设置:

[0073] 第一层: 1×1 大小的卷积核, 减少模型的计算参数;

[0074] 第二层: 3×3 卷积运算, 结合传统卷积和空洞卷积, 传统卷积捕获连续的结构性依赖特征, 空洞卷积捕获间隔距离较远的结构依赖关系;

[0075] 第三层: 1×1 卷积核, 还原特征图的数量。

[0076] 在本公开的实施例中, 基础通道数目随神经架构的深度变深而线性增加。

[0077] 在本公开的实施例中, 化石图像特征提取模型具有表1所示的结构。

[0078] 实施例1:

[0079] 在本实施例中公开了一种基于复合卷积神经网络的化石图像分类模型的构建方法, 包括如下步骤:

[0080] 步骤1, 对原始化石图像进行预处理, 利用Canny算子对原始化石图像的梯度进行计算, 图像的边缘纹理信息计算得到较大的梯度值, 较为平滑的部分计算得到较小的梯度值, 得到最终的梯度图像;

[0081] 具体包括:

[0082] 步骤1.1, 将RGB格式的彩色化石图像转换为灰度图像, 如公式:

[0083] $f(x, y) = 0.299R + 0.587G + 0.114B$

[0084] 其中, $f(x, y)$ 表示由原始图像生成的灰度图像, x, y 分别表示图像的像素点坐标位置, R, G, B 代表红、绿、蓝三个通道的颜色。

[0085] 步骤1.2, 为了尽可能减少噪声对梯度图像的提取结果, 利用高斯滤波对灰度图像 $f(x, y)$ 进行去噪, 该步骤称为平滑图像, 选定的高斯函数为 $G(x, y)$, 平滑后的图像为 $H(x, y)$, 则:

[0086]
$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right)$$

[0087] $H(x, y) = f(x, y) * G(x, y)$

[0088] 其中, σ 表示二维高斯函数的标准差, 影响高斯滤波的质量。“*” 是一种表示卷积的运算符。

[0089] 步骤1.3, 用一阶偏导的有限差分来计算梯度的幅值和方向, 图像的梯度在计算机视觉领域中被定义为像素灰度值变化的程度, 计算变化的程度在微积分学中可以描述为求对应像素沿 x 轴方向和 y 轴方向的偏导数, 则:

$$[0090] \quad \frac{\partial H(x, y)}{\partial x} = \lim_{\varepsilon \rightarrow 0} \frac{f(x + \varepsilon, y) - f(x, y)}{\varepsilon}$$

$$[0091] \quad \frac{\partial H(x, y)}{\partial y} = \lim_{\varepsilon \rightarrow 0} \frac{f(x, y + \varepsilon) - f(x, y)}{\varepsilon}$$

[0092] 由于图像可以视为一个离散矩阵,因此将上述微分函数改写为离散微分算子,在此基础上再结合上一维的高斯平滑便可以得到Soble算子,也被称为一阶微分算子,公式如下所示:

$$[0093] \quad S_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} S_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

[0094] 在以上推导的基础上将求解图像梯度的计算过程,在数学方法上抽象为将待处理的图像通过 S_x, S_y 两个方向的Sobel算子进行滤波计算得到两个对应方向的梯度图 G_x, G_y ,由此便可以确定像素点的梯度 G 和方向 θ :

$$[0095] \quad G = \sqrt{G_x^2 + G_y^2}$$

$$[0096] \quad \theta = \arctan \left(\frac{G_y}{G_x} \right)$$

[0097] 其中, G 为梯度强度, θ 表示梯度方向, \arctan 为反正切方向;

[0098] 步骤1.4,基于以上运算步骤可以得到由许多像素组成的梯度边缘,该边缘信息不准确且边缘较粗。故为了获取准确的、单一像素组成的边缘信息,需要进行非极大值抑制。

[0099] 具体包括:

[0100] 步骤1.4.1,将当前像素的梯度强度与沿正负梯度方向上的两个像素进行比较;

[0101] 步骤1.4.2,如果当前像素的梯度强度与另外两个像素相比最大,则该像素点保留为边缘点,否则该像素点将被抑制;

[0102] 步骤1.5,在步骤1.4的基础上进行边缘检测和连接。理想情况下,边缘检测只处理位于边缘上的像素点集合,但在实际处理过程中,噪声是一直存在的,便会引起边缘出现断开的现象,导致边缘上的像素集合无法完全有效的描述边缘特性,因此引入了阈值判断。通过设置合适的阈值范围,对边缘上像素点进行阈值判断。

[0103] 具体包括:

[0104] 步骤1.5.1,如果边缘上像素点的梯度强度值大于阈值的最大值,则把该像素点记录为边缘点;

[0105] 步骤1.5.2,如果边缘上像素点的梯度强度值小于阈值的最小值,则把该像素点记录为非边缘点;

[0106] 步骤1.5.3,如果位于阈值的最大值和最小值之间,则计算该像素点是否和前面标记的边缘点实现八连通,如果实现八连通,则将其作为边缘点标记下来,否则标记为非边缘点;

[0107] 步骤1.5.4,遍历边缘上的所有像素点,从而将没有闭合的边缘点连接起来,构成轮廓,即可得到梯度图像;

[0108] 步骤2,利用基于复合卷积神经网络的化石图像特征提取模型进行特征提取,并在

此基础上构建化石图像分类模型。

[0109] 具体包括：

[0110] 步骤2.1,构建基于复合卷积神经网络的化石图像特征提取模型；

[0111] 具体包括：

[0112] 步骤2.1.1,建立可堆叠的复合卷积残差块,用于堆叠形成不同深度的神经架构,具体深度由不同任务所在的图像数据集而定；由于不同图像数据集中输入图像的分辨率不同,因此需要根据不同数据集重新设定网络的深度；

[0113] 进一步地,如图3所示,复合卷积残差块主路径的第一层是 1×1 大小的卷积核,用于减少模型的计算参数。中间层的 3×3 卷积运算结合了传统卷积和空洞卷积,前者捕获连续的结构性依赖特征,后者捕获间隔距离较远的结构依赖关系,在不增加参数量的情况下增大感受野。第三层使用 1×1 卷积核来还原特征图的数量,以确保可以将输入添加到输出中,在减少计算参数的同时确保了模型准确性。

[0114] 计算过程可以定义为：

$$[0115] \quad F_{1,i} = \text{ReLU}(W_1, p),$$

[0116] 其中 p 代表输入特征图, W 是卷积核的权重, ReLU 为激活函数, $F_{1,i}$ 代表模型第1层的输出特征图,这是复合卷积残差块的第一阶段的输出,包括 i 个特征图。

$$[0117] \quad F_{l+1_{conv},j} = \text{ReLU}(W_{l+1}, F_{l,0:\frac{i}{2}-1}),$$

$$[0118] \quad F_{l+1_{dconv},k} = \text{ReLU}(W_{l+2}, F_{l,\frac{i}{2}:i}),$$

[0119] 在第二阶段,将由 $F_{l,0:\frac{i}{2}-1}$ 表示的 $F_{1,i}$ 的特征图的一半输入到传统卷积中,输出为 $F_{l+1_{conv},j}$,包含 j 个特征图；另一半特征图 $F_{l,\frac{i}{2}:i}$ 则输入到空洞卷积中,输出是 $F_{l+1_{dconv},k}$,包含 k 个特征图。

$$[0120] \quad F_{l+2,j+k} = [F_{l+1_{conv},j}, F_{l+1_{dconv},k}],$$

$$[0121] \quad q = \text{ReLU}(W_{l+3i} F_{l+2,j+k}) + W_{sp},$$

[0122] 在第三阶段,将传统卷积与空洞卷积的输出特征图从通道维度进行叠加,结果为 $F_{l+2,j+k}$,共包含 $j+k$ 个特征图。通过最后一层 1×1 卷积运算和跳跃连接后,得到输出特征图 q 。

[0123] 步骤2.1.2,设置所述复合卷积残差块的基础通道数目以及空洞卷积膨胀率；之后堆叠所述复合卷积残差块,确定最终的特征提取模型,如表1所示；

[0124] 在步骤2.1.2中的每个复合卷积残差块的基础通道数目随着网络不断变深而线性增加；

[0125] 步骤2.2,构建化石图像分类模型；

[0126] 具体包括：

[0127] 步骤2.2.1,将原始化石图像与根据步骤1预处理得到的梯度图像,分别送入步骤2.1构建的基于复合卷积神经网络的化石图像特征提取模型,提取得到包含深度特征的1024个大小为 7×7 像素的特征图与包含初级视觉特征的1024个大小为 7×7 像素的特征图；

[0128] 步骤2.2.2,将深度特征图与初级视觉特征图从通道维度进行融合,得到2048个大

小为 7×7 像素的特征图；

[0129] 步骤2.2.3,将步骤2.2.2融合后的特征图送入全局平均池化层,通过对输入的每个特征图进行全局平均池化操作,即对每个特征图计算所有像素点的均值,输出一个数据值,2048个特征图会输出2048个数据点,这些数据点组成一个2048维的向量,称为特征向量；

[0130] 步骤2.2.4,最后经过全连接层将全局平均池化层学到的分布式特征表示,映射到样本标记空间中,即采用C个大小为 $1 \times 1 \times 2048$,即长为1,宽为1,通道数为2048的卷积核,对全局平均池化得到的输出结果进行卷积操作;最后通过Softmax分类器得到分为各个类别的概率值,得到最终的化石图像所属类别。其中C为化石图像类别的数量。

[0131] 步骤3,训练所构建的化石图像分类模型；

[0132] 步骤3.1,构建目标损失函数；

[0133] 具体包括：

[0134] 步骤3.1.1,在现有的研究工作中,交叉熵(Cross Entropy,CE)损失函数被广泛的应用于化石图像分类模型的训练过程中,如公式：

$$[0135] \quad CE = - \sum_{j=1}^C a_n \log(\hat{a}_n)$$

[0136] 其中,a为样本的真实标签(以one-hot形式编码)。 \hat{a} 表示样本的预测结果,C是化石图像类别的数量,为了便于表示,将公式重写为：

$$[0137] \quad b = \max_{1 \leq j \leq C} a_n \hat{a}_n$$

$$[0138] \quad CE(b) = - \log(b)$$

[0139] 其中, $b \in [0, 1]$ 表示模型对样本真实标签的估计概率。CE损失函数能够反映预测概率分布和真实概率分布之间的差距,在模型的训练过程中,我们期望看到预测概率和真实概率尽可能相近,所以模型的训练目标是将损失函数最小化。然而CE损失函数无法解决样本类别数量不均衡问题和缓解过拟合问题,因此选择对CE损失函数进行改进。

[0140] 步骤3.1.2,构建目标损失函数L,提出使用基于focal loss进行改进的损失函数作为目标函数,对CE损失函数进行改进,可以表示为：

$$[0141] \quad L = -6\alpha(1-b)^\gamma \log(b) - (1-\theta) \log(b)$$

$$[0142] \quad \alpha_m = \frac{\frac{\sum_{m=1}^t \text{Count}_m}{\text{Count}_m}}{\sum_{m=1}^t \frac{\sum_{m=1}^t \text{Count}_m}{\text{Count}_m}}$$

[0143] 其中, $\alpha \in [0, 1]$ 是一个权重因子,用于调节和平衡不同类别样本的重要程度, Count_m 表示第m个类别样本的个数, $\gamma > 0$ 是一个调制因子,用于调整易分类样本的权重, θ 是用于调整两种损失函数权重的超参数。

[0144] 步骤3.2,使用Imagenet大型数据集上预先训练好的ResNet50深度残差网络初始化化石图像特征提取模型中的参数作为初始参数值,按照正态分布初始化全连接层的网络参数；

[0145] 步骤3.3,对于数据集中的图像,随机选择80%的图像作为训练集,10%的图像作

为验证集,10%的图像作为测试集;将训练集与验证集中的图像按照步骤1进行预处理,得到预处理后的训练集图像和预处理后的验证集图像;

[0146] 步骤3.4,运用预处理后的训练集图像,包括原始化石图像与对应的梯度图像,送入构建好的化石图像分类模型中,采用批梯度下降的训练方法来最小化所述的目标损失函数值,进而对网络中所有层的参数进行调整,得到训练好的复合卷积神经网络的权重;

[0147] 本实施例中,将训练的批处理大小设置为64,参数更新动量设置为0.9,学习率设置为0.001,迭代次数(Epoch)设置为500,对训练好的浅层卷积神经网络模型的权重,采用后向传播算法进行再训练,得到权重训练结果,批量随机梯度下降,从而使损失值最小化。

[0148] 步骤3.6,对权重训练结果,每一代训练结束后通过预处理后的验证集图像的损失值进行反馈:将验证集图像输入到当前训练好的化石图像分类模型中,并计算其损失值,若当前的误差值小于权重训练结果,则对模型的权重进行更新,否则继续保存之前的权重训练结果;迭代训练500次后,模型的训练终止,保存最优的模型结果。

[0149] 步骤4,利用基于复合卷积神经网络的化石图像分类模型对化石图像进行分类。

[0150] 步骤4.1,对于一幅待测化石图像,首先对其按照步骤1进行预处理,得到梯度图像;

[0151] 步骤4.2,将待测化石图像与对应的梯度图像输入到步骤3训练得到的化石图像分类模型对其类别进行预测,得到最终的所属类别。

[0152] 实施例2:

[0153] 本实施例中数据集由西北大学地质学院提供,共包含四类2354张化石图像,其中云南头虫1392张,始莱德利基虫852张,关杨三叶虫85张,武定虫25张。采用分类准确率作为模型性能的评价指标,取值为[0,1],取值越高,说明模型的性能越好。

[0154] 表2不同方法之间的对比结果

数据集	模型	准确率
[0155] 化石图像数据集	VGG 16	94.2%
	Inception V3	95.7%
	ResNet 50	96.3%
	Densenet 121	98.2%
	This Method	100%

[0156] 由表2结果可知,本发明在该数据集上的性能高于所对比的化石图像分类模型。为了进一步证明本年发明所提出的创新可以对最终的结果产生有利的影响,本实施例通过对比了四种不同方法之间的效果,具体方法如下:

[0157] N1:仅包含一个子网络,即输入为原始化石图像,采用交叉熵损失函数对整个网络端到端进行训练。

[0158] N2:仅包含一个子网络,即输入为原始化石图像,采用本发明所提出的损失函数L对整个网络端到端进行训练。

[0159] N3:仅包含一个子网络,即输入为原始化石图像对应的梯度图像,采用本发明所提

出的损失函数L对整个网络端到端进行训练。

[0160] N4:包含两个子网络,输入分别为原始化石图像与其对应的梯度图像,将两个子网络所提取的特征进行拼接融合,采用本发明所提出的损失函数L对整个网络端到端进行训练。

[0161] 表3消融实验对比效果

模型	原始化石图像	梯度图像	交叉熵损失函数	本发明所提 L 损失函数	准确率
N1	√		√		97.6%
N2	√			√	98.5%
N3		√		√	97.9%
N4	√	√		√	100%

[0162] 由表3结果可知,本发明所提出的创新可以对最终的结果产生有利的影响,从而进一步提升化石图像分类模型的性能。

[0164] 以上结合附图详细描述了本公开的优选实施方式,但是,本公开并不限于上述实施方式中的具体细节,在本公开的技术构思范围内,可以对本公开的技术方案进行多种简单变型,这些简单变型均属于本公开的保护范围。

[0165] 另外需要说明的是,在上述具体实施方式中所描述的各个具体技术特征,在不矛盾的情况下,可以通过任何合适的方式进行组合,为了避免不必要的重复,本公开对各种可能的组合方式不再另行说明。

[0166] 此外,本公开的各种不同的实施方式之间也可以进行任意组合,只要其不违背本公开的思想,其同样应当视为本公开所公开的内容。

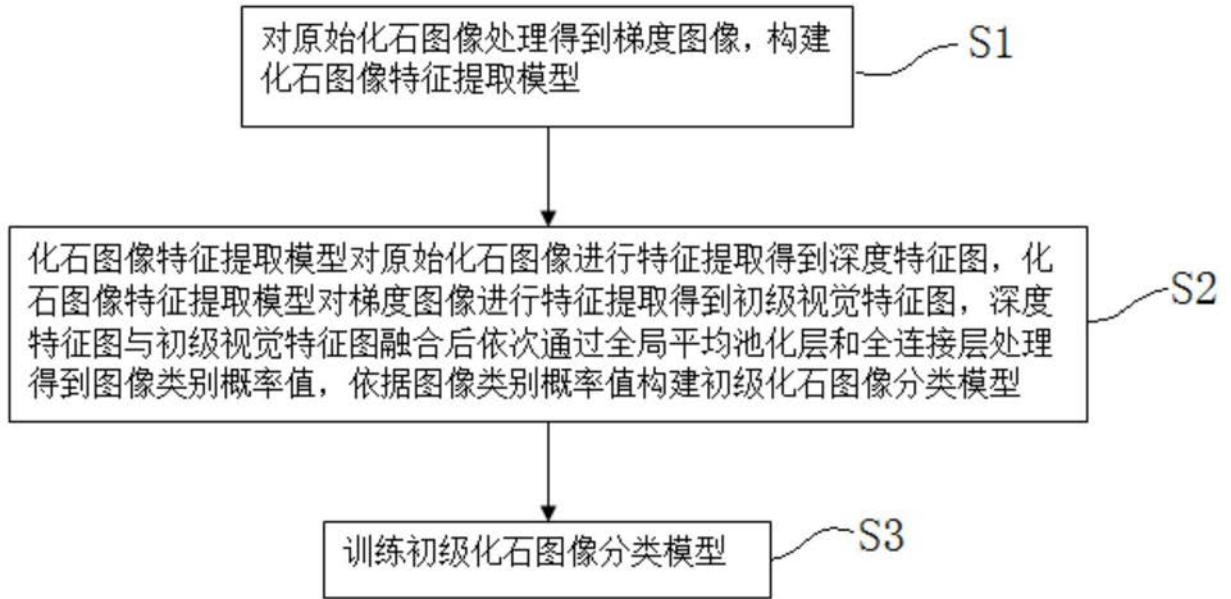


图1

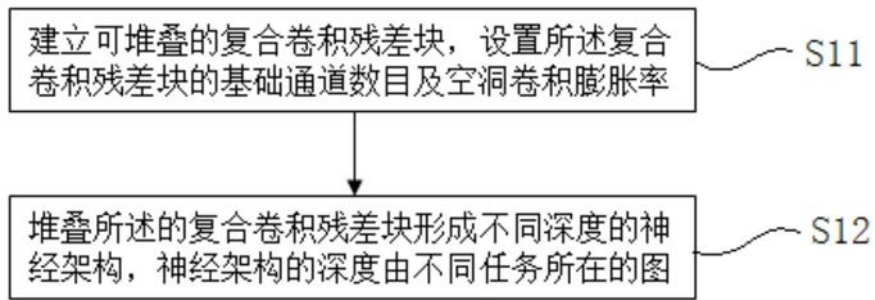


图2




图3





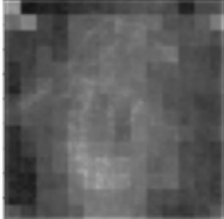
原始图像	HRes-Group1	HRes-Group2	HRes-Group3	HRes-Group4
				

图4