



(12) 发明专利

(10) 授权公告号 CN 118196552 B

(45) 授权公告日 2025. 06. 03

(21) 申请号 202410256166.3

(22) 申请日 2023.07.25

(65) 同一申请的已公布的文献号
申请公布号 CN 118196552 A

(43) 申请公布日 2024.06.14

(62) 分案原申请数据
202310918704.6 2023.07.25

(73) 专利权人 长安大学
地址 710064 陕西省西安市雁塔区南二环路中段

专利权人 中国文化遗产研究院

(72) 发明人 包含 李昌波 陈卫昌 李黎
兰恒星 吕洪涛 晏长根 徐玮

(74) 专利代理机构 北京金咨知识产权代理有限公司 11612

专利代理师 方日勇

(51) Int.Cl.
G06V 10/774 (2022.01)
G06V 10/44 (2022.01)
G06V 10/764 (2022.01)
G06V 10/82 (2022.01)
G06N 3/0464 (2023.01)
G06N 3/048 (2023.01)
G06N 3/08 (2023.01)

(56) 对比文件
CN 114964006 A, 2022.08.30
CN 116127239 A, 2023.05.16

审查员 张琪

权利要求书4页 说明书17页 附图3页

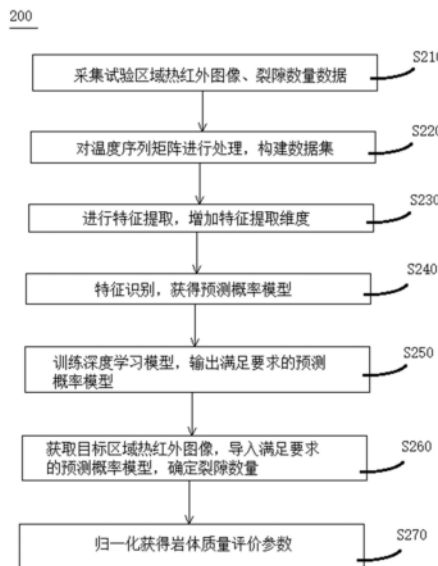
(54) 发明名称

基于机器学习的裂隙岩体质量评价方法、电子设备及存储介质

(57) 摘要

本发明提供一种基于机器学习的裂隙岩体质量评价方法、电子设备及存储介质,包括:通过采集原位裂隙岩体的试验区域的岩体表面热红外图像及其岩体浅表层内的裂隙数量数据;对温度序列矩阵进行处理,结合所采集的裂隙数量数据构建热红外图像数据集;对热红外图像数据集进行裂隙特征提取;将卷积特征向量通过全卷积层进行特征识别,获得裂隙数量预测概率模型;训练深度学习模型;获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,导入满足要求的预测概率模型,确定目标区域的岩体浅表层内的裂隙数量;基于目标区域的面积和确定的裂隙数量,获得岩体质量评价参数。采用本发明提供的评价方法,可快速、高效进行裂隙岩体质量评价。

CN 118196552 B



1. 一种基于机器学习的裂隙岩体质量评价方法,其特征在于,所述评价方法包括以下步骤:

采集原位裂隙岩体的划分的N块矩形试验区域的岩体表面热红外图像,基于热红外图像采用Smartview软件获得对应的温度序列矩阵 $T_{i,n}^0$, $0 \leq i \leq I$, $0 \leq n \leq N$,拍摄第n个试验区域岩体表面中第i张热红外图像的时间为 $t_{i,n}$,拍摄第n个试验区域初始温度为温度矩阵 $T_{0,n}^0$,I为第n个试验区域岩体表面对应拍摄的热红外图像的总张数,采集原位裂隙岩体的试验区域的岩体浅表面10cm以内的裂隙数量数据 j_n ;

对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集,包括:

对温度序列矩阵 $T_{i,n}^0$ 进行上下、左右反转各一次;

基于划分的试验区域四个顶点坐标,得出几何校正矩阵B,再对温度序列矩阵 $T_{i,n}^0$ 进行几何校正,

$$B = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$[x' \ y' \ z'] = [uv1]B$$

$$x = \frac{x'}{z'}$$

$$y = \frac{y'}{z'}$$

其中,u、v为第n个试验区域岩体表面中第i个温度序列矩阵 $T_{i,n}^0$ 的坐标,x、y为温度序列矩阵 $T_{i,n}^0$ 通过几何校正后得到的坐标,x'、y'和z'是把二维坐标系转换为三维坐标系,然后把三维坐标系投影到新的二维坐标系的相关参数; a_{11} 、 a_{12} 、 a_{21} 和 a_{22} 是仿射变换参数; a_{31} 和 a_{32} 是平移变换参数; a_{13} 和 a_{23} 表示变换后边缘交点关系, a_{33} 是一个缩放因子,会归一化为1;温度序列矩阵 $T_{i,n}^0$ 的元素根据坐标变换后重新排列得到温度矩阵 $T_{i,n}^1$,缺失的元素按双线性插值补充;

计算第n个试验区域岩体表面的第i张到第i+1张热红外图像的温差矩阵 $T_{i,n}^2$;

对温差矩阵 $T_{i,n}^2$ 进行标准化,获得矩阵 $T_{i,n}^3$;

构建热红外图像数据集data,

$$data = \begin{bmatrix} data_{(0)} \\ data_{(1)} \\ data_{(2)} \end{bmatrix}$$

$$data_{(0)} = \begin{bmatrix} T_{1,1} & j_1 \\ T_{2,1} & j_1 \\ \vdots & \vdots \\ T_{l,1} & j_1 \\ T_{1,2} & j_2 \\ \vdots & \vdots \\ T_{l,N} & j_N \end{bmatrix}$$

$$T_{i,n} = [T_{0,n}^1, T_{i,n}^1, T_{i,n}^3]$$

其中, $data_{(0)}$ 的一条数据结构是由样本矩阵 $T_{i,n}$ 和以第 n 个试验区域岩体浅表面 10cm 以内的裂隙数量 j_n 作为的标签信息组成, 由于温度序列矩阵 $T_{i,n}^0$ 进行了上下、左右反转各一次, 按照相同步骤可得到 $data_{(1)}$ 和 $data_{(2)}$;

基于深度学习模型对热红外图像数据集进行裂隙特征提取, 并通过增加特征提取的维度以获得卷积特征向量;

将卷积特征向量通过全卷积层进行特征识别, 获得深度学习模型识别到的裂隙数量对应的预测概率模型;

训练深度学习模型直至收敛, 输出此时满足要求的预测概率模型;

获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵, 经格式转换后导入满足要求的预测概率模型, 获得预测概率最高的裂隙数量, 确定目标区域的岩体浅表层内的裂隙数量;

基于目标区域的面积和确定的裂隙数量, 结合采集的目标区域热红外图像的初始时刻和其他某时刻的各自对应的平均温度, 归一化获得岩体质量评价参数 α ,

其中, $0 \leq \alpha \leq 1$, α 值越小表示岩体质量越好。

2. 根据权利要求 1 所述的评价方法, 其特征在于, 所述采集原位裂隙岩体的划分的 N 块矩形试验区域的岩体表面热红外图像, 基于热红外图像采用 Smartview 软件获得对应的温度序列矩阵, 具体内容包括:

开展原位裂隙岩体主动式红外探测试验, 划分好 N 块矩形试验区域, 通过热红外相机对每块试验区域拍摄多组不同岩体表面的热红外图像, 采用 Smartview 软件获取第 n 个试验区域岩体表面的温度序列矩阵 $T_{i,n}^0$;

所述采集原位裂隙岩体的试验区域的岩体浅表面 10cm 以内的裂隙数量数据, 具体内容包括:

使用包括传统皮尺、罗盘、塞尺和钻孔在内的工具进行原位裂隙岩体内外部裂隙调查, 得出第 n 个试验区域岩体浅表面 10cm 以内的裂隙数量 j_n , N 个试验区域中岩体浅表面 10cm 以内的最大裂隙数量为 J , $1 \leq j_n \leq J$ 。

3. 根据权利要求 2 所述的评价方法, 其特征在于,

所述计算第 n 个试验区域岩体表面的第 i 张到第 $i+1$ 张热红外图像的温差矩阵 $T_{i,n}^2$, 具体

包括:

$$T_{i,n}^2 = T_{i+1,n}^1 - T_{i,n}^1$$

其中, $T_{i+1,n}^1$ 为第 n 个试验区域岩体表面的第 $i+1$ 个经过坐标变换后的温度矩阵;

所述对温差矩阵 $T_{i,n}^2$ 进行标准化, 获得矩阵 $T_{i,n}^3$, 具体包括:

$$T_{i,n}^3 = \frac{T_{i,n}^2 - \mu}{\sigma}$$

其中, μ 为第 n 个试验区域岩体表面的第 i 个温差矩阵 $T_{i,n}^2$ 的均值, σ 为温差矩阵 $T_{i,n}^2$ 的标准差。

4. 根据权利要求3所述的评价方法, 其特征在于, 所述基于深度学习模型对热红外图像数据集进行裂隙特征提取, 并通过增加特征提取的维度以获得卷积特征向量, 具体内容包括:

将训练集数据随机打乱, 采用激活函数ReLU, 矩阵 $T_{i,n}$ 通过一个卷积层和四个残差模块提取热红外图像的特征, 每个残差模块由四个残差块组成, 残差块是一个两层的神经网络;

通过平均池化操作将热红外图像的尺度规模减小, 获得大小为 $1 \times 1 \times 4096$ 的卷积特征向量。

5. 根据权利要求4所述的评价方法, 其特征在于, 所述将卷积特征向量通过全卷积层进行特征识别, 获得深度学习模型识别到的裂隙数量对应的预测概率模型, 具体内容包括:

将卷积特征向量通过两个 1×1 全卷积网络, 得到类别特征矩阵 X_j ;

将类别特征矩阵 X_j 通过softmax软件得到包含每个类别的预测概率, 得到大小为 $2 \times J$ 的裂隙数量预测矩阵 C ,

$$d_k = \frac{c_k}{\sum_{k=1}^J c_k}$$

$$C = \begin{bmatrix} c_1 & d_1 \\ c_2 & d_2 \\ c_3 & d_3 \\ \vdots & \vdots \\ c_J & d_J \end{bmatrix}$$

其中, k 表示深度学习模型识别到的裂隙数量, c_k 是识别裂隙数量为 k 条的权重, d_k 是识别裂隙数量为 k 条的预测概率。

6. 根据权利要求5所述的评价方法, 其特征在于, 所述训练深度学习模型直至收敛, 输出此时满足要求的预测概率模型, 具体内容包括:

采用损失函数:

$$L = -\frac{1}{R} \sum_r \sum_{k=1}^J y_{r,k} \log(d_k)$$

其中, R 是训练集数据数量, $y_{r,k}$ 为符号函数, 其取值为0或1, 训练集的第 r 个样本数据的真实类别 j_n 等于 k 取1, 否则取0, $0 \leq r \leq R$;

采用SGD算法更新权重:

$$w' = w - \eta \nabla L(w; T_{i,n}, j_n)$$

其中, w 是深度学习模型中要更新的权重向量, w' 是更新后的权重向量, η 是学习率, 决定了每次权重更新的步长, $\nabla L(w; T_{i,n}, j_n)$ 是损失函数 L 在 $Y_{i,n}$ 和 j_n 关于权重 w 的梯度, 该梯度表示损失函数对于权重的变化方向和速度;

将训练集导入深度学习模型中进行迭代训练, 训练完成后导入验证集得出模型的 accuracy 的值, accuracy 是验证集所有样本被模型检测正确的比例, 使用不同的学习率、权重衰减、批量大小、训练迭代次数超参数组合, 使 accuracy 的值达到预定值, 最后导入测试集计算深度学习模型的 F1 值, 当 F1' 值大于 0.8 时输出此时的预测概率模型,

$$F1_k = \left(\frac{recall^{-1} + precision^{-1}}{2} \right)^{-1}$$

$$F1' = \sum_{k=1}^J F1_k$$

其中, precision 是精准率, 表示深度学习模型在测试集上预测裂隙数量为 k 的所有样本中, 其实际裂隙数量也为 k 的比例, 即每一个类别 k 都有一个精准率, recall 是召回率, 表示在测试集上实际裂隙数量为 k 的所有样本中, 深度学习模型预测裂隙数量也为 k 的比例, 即每一个类别 k 都有一个召回率, $F1_k$ 是预测为 k 的 F1 值, $F1'$ 是深度学习模型总的 F1 值。

7. 根据权利要求 1 所述的评价方法, 其特征在于, 所述岩体质量评价参数 α ,

$$\alpha = E_1 \frac{kA_J}{JA} + E_2 \frac{\Delta T_i^2 - \Delta T^2}{\Delta T^1 - \Delta T^2}$$

$$\Delta T_i = \text{avg}T_i - \text{avg}T_0$$

$$\Delta T_{i,n}^1 = \text{avg}T_{i,n}^1 - \text{avg}T_{0,n}^1$$

$$\Delta T^1 = \max(\Delta T_{i,n}^1)$$

$$\Delta T^2 = \min(\Delta T_{i,n}^1)$$

其中, A 是目标区域的面积, $\text{avg}T_0$ 和 $\text{avg}T_i$ 分别是拍摄的目标区域热红外图像对应的温度序列矩阵在初始时刻 t_0 和其他时刻 t_i 平均温度, ΔT_i 是目标区域热红外图像在初始时刻 t_0 和 t_i 时刻的平均温差; $\Delta T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 在 t_0 和 t_i 时刻的平均温差, $\text{avg}T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 中元素的平均值, $\text{avg}T_{0,n}^1$ 是 $\text{avg}T_{i,n}^1$ 在初始时刻 t_0 对应的值, ΔT^1 是 $\Delta T_{i,n}^1$ 的最大值, ΔT^2 是 $\Delta T_{i,n}^1$ 的最小值, A_J 是试验区域热红外图像对应的温度序列矩阵中标签为最大裂隙数量 J 对应的试验区域面积, E_1 、 E_2 分别是裂隙参数和温度参数的权重。

8. 一种电子设备, 其特征在于, 包括处理器和存储器, 所述存储器上存储有指令, 当所述指令由所述处理器运行时使得所述处理器执行根据权利要求 1-7 中任一项所述的评价方法。

9. 一种计算机可读存储介质, 其上存储有计算机程序, 当所述计算机程序由计算机运行时使得所述计算机执行根据权利要求 1-7 中任一项所述的评价方法。

基于机器学习的裂隙岩体质量评价方法、电子设备及存储介质

技术领域

[0001] 本发明涉及裂隙岩体探测技术领域,尤其涉及一种基于机器学习的裂隙岩体裂隙数量确定方法、裂隙岩体质量评价方法、电子设备及存储介质。

背景技术

[0002] 岩体在自然形成过程中会产生不同成因的裂隙,使得岩体具有非连续性、各向异性等特征,极大地削减了岩体的强度和稳定性,是影响岩体工程安全稳定的重要因素。合理探测出岩体裂隙的表层及内部情况,对其损伤状态进行评价,是制定合适的加固保护措施和施工工艺的基础。

[0003] 岩体具备一定的导热性,在表面均匀加热的情况下,岩体表面会产生与内外裂隙相关的升温异常反应。根据对热异常反应的研究,可以对岩体结构信息进行获取。

[0004] 在实现本发明过程中,发明人发现现有技术中至少存在如下问题:

[0005] 现有的热红外探测技术中,原位岩体的热红外探测理论公式的推导较为困难,热红外温度图像的处理比较繁琐,对裂隙的定量化识别和复杂岩体结构定量描述的研究较少。机器学习是研究怎样使用计算机模拟或实现人类学习活动的科学,可以学习到数据的规律,进而对新输入的数据进行分类或预测,在岩土工程的应用越来越广泛,但融合机器学习和热红外技术的岩体质量评价方法还没有见到相关报道。

[0006] 因此需要一种基于机器学习的裂隙岩体裂隙数量确定方法、裂隙岩体质量评价方法、电子设备及存储介质,以至少部分地解决上述技术问题。

发明内容

[0007] 鉴于此,本发明实施例提供了一种基于机器学习的裂隙岩体裂隙数量确定方法、裂隙岩体质量评价方法、电子设备及存储介质,以至少解决现有技术中的问题之一。

[0008] 本发明的第一个方面提供了一种基于机器学习的裂隙岩体裂隙数量确定方法,该确定方法包括以下步骤:

[0009] 通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵,通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据;

[0010] 对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集;

[0011] 基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量;

[0012] 将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型;

[0013] 训练深度学习模型直至收敛,输出此时满足要求的预测概率模型;

[0014] 获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格

式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,确定目标区域的岩体浅表层内的裂隙数量。

[0015] 在本发明的一些实施例中,所述通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵,具体内容包括:

[0016] 开展原位裂隙岩体主动式红外探测试验,划分好N块矩形试验区域,通过热红外相机对每块试验区域拍摄多组不同岩体表面的热红外图像,采用Smartview软件获取第n个试验区域岩体表面的温度序列矩阵 $T_{i,n}^0$, $0 \leq i \leq I$, $0 \leq n \leq N$,拍摄第n个试验区域岩体表面中第i张热红外图像的时间为 $t_{i,n}$,拍摄第n个试验区域初始温度为温度矩阵 $T_{0,n}^0$;

[0017] 所述采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据,具体内容包括:

[0018] 使用包括传统皮尺、罗盘、塞尺和钻孔在内的工具进行原位裂隙岩体内外裂隙调查,得出第n个试验区域岩体浅表面10cm以内的裂隙数量 j_n ,N个试验区域中岩体浅表面10cm以内的最大裂隙数量为J, $1 \leq j_n \leq J$ 。

[0019] 在本发明的一些实施例中,所述对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集,具体内容包括:

[0020] 对温度序列矩阵 $T_{i,n}^0$ 进行上下、左右反转各一次;

[0021] 基于划分的试验区域四个顶点坐标,得出几何校正矩阵B,再对温度序列矩阵 $T_{i,n}^0$ 进行几何校正,

$$[0022] \quad B = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$[0023] \quad [x' \ y' \ z'] = [u \ v \ 1]B$$

$$[0024] \quad x = \frac{x'}{z'}$$

$$[0025] \quad y = \frac{y'}{z'}$$

[0026] 其中,u、v为第n个试验区域岩体表面中第i个温度序列矩阵 $T_{i,n}^0$ 的坐标,x、y为温度序列矩阵 $T_{i,n}^0$ 通过几何校正后得到的坐标,z'是把二维坐标系转换为三维坐标系,然后把三维坐标系投影到新的二维坐标系的相关参数; a_{11} 、 a_{12} 、 a_{21} 和 a_{22} 是仿射变换参数; a_{31} 和 a_{32} 是平移变换参数; a_{13} 和 a_{23} 表示变换后边缘交点关系, a_{33} 是一个缩放因子,会归一化为1;温度序列矩阵 $T_{i,n}^0$ 的元素根据坐标变换后重新排列得到温度矩阵 $T_{i,n}^1$,缺失的元素按双线性插值补充;

[0027] 计算第n个试验区域岩体表面的第i张到第i+1张热红外图像的温差矩阵 $T_{i,n}^2$,

$$[0028] \quad T_{i,n}^2 = T_{i+1,n}^1 - T_{i,n}^1$$

[0029] 其中, $T_{i+1,n}^1$ 为第n个试验区域岩体表面的第i+1个经过坐标变换后的温度矩阵;

[0030] 对温差矩阵 $T_{i,n}^2$ 进行标准化,获得矩阵 $T_{i,n}^3$,

$$[0031] \quad T_{i,n}^3 = \frac{T_{i,n}^2 - \mu}{\sigma}$$

[0032] 其中, μ 为第 n 个试验区域岩体表面的第 i 个温差矩阵 $T_{i,n}^2$ 的均值, σ 为温差矩阵 $T_{i,n}^2$ 的标准差;

[0033] 构建热红外图像数据集 $data$,

$$[0034] \quad data = \begin{bmatrix} data_{(0)} \\ data_{(1)} \\ data_{(2)} \end{bmatrix}$$

$$[0035] \quad data_{(0)} = \begin{bmatrix} T_{1,1} & j_1 \\ T_{2,1} & j_1 \\ \vdots & \vdots \\ T_{l,1} & j_1 \\ T_{1,2} & j_2 \\ \vdots & \vdots \\ T_{l,N} & j_N \end{bmatrix}$$

$$[0036] \quad T_{i,n} = [T_{0,n}^1, T_{i,n}^1, T_{i,n}^3]$$

[0037] 其中, $data_{(0)}$ 的一条数据结构是由样本矩阵 $T_{i,n}$ 和以第 n 个试验区域岩体浅表面内的裂隙数量 j_n 作为标签信息组成,由于温度序列矩阵 $T_{i,n}^0$ 进行了上下、左右反转各一次,按照相同步骤可得到 $data_{(1)}$ 和 $data_{(2)}$ 。

[0038] 在本发明的一些实施例中,所述基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量,具体内容包括:

[0039] 将训练集数据随机打乱,采用激活函数ReLU,矩阵 $T_{i,n}$ 通过一个卷积层和四个残差模块提取热红外图像的特征,每个残差模块由四个残差块组成,残差块是一个两层的神经网络;

[0040] 通过平均池化操作将热红外图像的尺度规模减小,获得大小为 $1 \times 1 \times 4096$ 的卷积特征向量。

[0041] 在本发明的一些实施例中,其特征在于,所述将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型,具体内容包括:

[0042] 将卷积特征向量通过两个 1×1 全卷积网络,得到类别特征矩阵 X_j ;

[0043] 将类别特征矩阵 X_j 通过softmax软件得到包含每个类别的预测概率,得到大小为 $2 \times J$ 的裂隙数量预测矩阵 C ,

$$[0044] \quad d_k = \frac{c_k}{\sum_{k=1}^J c_k}$$

$$[0045] \quad C = \begin{bmatrix} c_1 & d_1 \\ c_2 & d_2 \\ c_3 & d_3 \\ \vdots & \vdots \\ c_J & d_J \end{bmatrix}$$

[0046] 其中, k 表示深度学习模型识别到的裂隙数量, c_k 是识别裂隙数量为 k 条的权重, d_k 是识别裂隙数量为 k 条的预测概率。

[0047] 在本发明的一些实施例中, 所述训练深度学习模型直至收敛, 输出此时满足要求的预测概率模型, 具体内容包括:

[0048] 采用损失函数:

$$[0049] \quad L = -\frac{1}{R} \sum_r \sum_{k=1}^J y_{r,k} \log(d_k)$$

[0050] 其中, R 是训练集数据数量, $y_{r,k}$ 为符号函数, 其取值为0或1, 训练集的第 r 个样本数据的真实类别 j_n 等于 k 取1, 否则取0, $0 \leq r \leq R$;

[0051] 采用SGD算法更新权重:

$$[0052] \quad w' = w - \eta \nabla L(w; T_{i,n}, j_n)$$

[0053] 其中, w 是深度学习模型中要更新的权重向量, w' 是更新后的权重向量, η 是学习率, 决定了每次权重更新的步长, $\nabla L(w; T_{i,n}, j_n)$ 是损失函数 L 在 $T_{i,n}$ 和 j_n 关于权重 w 的梯度, 该梯度表示损失函数对于权重的变化方向和速度;

[0054] 将训练集导入深度学习模型中进行迭代训练, 训练完成后导入验证集得出模型的accuracy的值, accuracy是验证集所有样本被模型检测正确的比例, 使用不同的学习率、权重衰减、批量大小、训练迭代次数超参数组合, 使accuracy的值达到预定值, 最后导入测试集计算深度学习模型的F1值, 当F1' 值大于0.8时输出此时的预测概率模型,

$$[0055] \quad F1_k = \left(\frac{recall^{-1} + precision^{-1}}{2} \right)^{-1}$$

$$[0056] \quad F1' = \sum_{k=1}^J F1_k$$

[0057] 其中, precision是精准率, 表示深度学习模型在测试集上预测裂隙数量为 k 的所有样本中, 其实际裂隙数量也为 k 的比例, 即每一个类别 k 都有一个精准率, recall是召回率, 表示在测试集上实际裂隙数量为 k 的所有样本中, 深度学习模型预测裂隙数量也为 k 的比例, 即每一个类别 k 都有一个召回率, $F1_k$ 是预测为 k 的F1值, $F1'$ 是深度学习模型总的F1值。

[0058] 本发明的第二方面提供了一种基于机器学习的裂隙岩体质量评价方法, 该评价方法包括上述技术方案中的确定方法, 还包括如下步骤:

[0059] 基于目标区域的面积和确定的裂隙数量, 结合采集的目标区域热红外图像的初始时刻和其他某时刻的各自对应的平均温度, 归一化获得岩体质量评价参数 α ,

[0060] 其中, $0 \leq \alpha \leq 1$, α 值越小表示岩体质量越好。

[0061] 在本发明的一些实施例中,所述岩体质量评价参数 α ,

$$[0062] \quad \alpha = E_1 \frac{kA_J}{JA} + E_2 \frac{\Delta T_i^2 - \Delta T^2}{\Delta T^1 - \Delta T^2}$$

$$[0063] \quad \Delta T_i = \text{avg}T_i - \text{avg}T_0$$

$$[0064] \quad \Delta T_{i,n}^1 = \text{avg}T_{i,n}^1 - \text{avg}T_{0,n}^1$$

$$[0065] \quad \Delta T^1 = \max(\Delta T_{i,n}^1)$$

$$[0066] \quad \Delta T^2 = \min(\Delta T_{i,n}^1)$$

[0067] 其中, A 是目标区域的面积, $\text{avg}T_0$ 和 $\text{avg}T_i$ 分别是拍摄的目标区域热红外图像对应的温度序列矩阵在初始时刻 t_0 和其他时刻 t_i 平均温度, ΔT_i 是目标区域热红外图像在初始时刻 t_0 和 t_i 时刻的平均温差; $\Delta T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 在 t_0 和 t_i 时刻的平均温差, $\text{avg}T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 中元素的平均值, $\text{avg}T_{0,n}^1$ 是 $\text{avg}T_{i,n}^1$ 在初始时刻 t_0 对应的值, ΔT^1 是 $\Delta T_{i,n}^1$ 的最大值, ΔT^2 是 $\Delta T_{i,n}^1$ 的最小值, A_J 是试验区域热红外图像对应的温度序列矩阵中标签为最大裂隙数量 J 对应的试验区域面积, E_1 、 E_2 分别是裂隙参数和温度参数的权重。

[0068] 本发明的第三方面提供了一种电子设备,包括处理器和存储器,所述存储器上存储有指令,当所述指令由所述处理器运行时使得所述处理器执行上述技术方案中所述的方法或上述技术方案中的所述的评价方法。

[0069] 本发明的第四方面提供了一种存储有计算机指令的非瞬时计算机可读存储介质,其中,所述计算机指令用于使所述计算机执行上述技术方案中所述的方法或上述技术方案中的所述的评价方法。

[0070] 根据本发明实施例的基于机器学习的裂隙岩体裂隙数量确定方法,首先通过采集原位裂隙岩体的试验区域的岩体表面热红外图像获得对应的温度序列矩阵,通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据;然后对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集;接着基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量;将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型;然后训练深度学习模型直至收敛,输出此时满足要求的预测概率模型;再然后获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,最终确定目标区域的岩体浅表层内的裂隙数量。通过本发明的确定方法可实现裂隙岩体裂隙数量的快速、高效确定。

[0071] 本发明的附加优点、目的,以及特征将在下面的描述中将部分地加以阐述,且将对于本领域普通技术人员在研究下文后部分地变得明显,或者可以根据本发明的实践而获知。本发明的目的和其它优点可以通过在说明书以及附图中具体指出的结构实现到并获得。

[0072] 本领域技术人员将会理解的是,能够用本发明实现的目的和优点不限于以上具体所述,并且根据以下详细说明将更清楚地理解本发明能够实现的上述和其他目的。

附图说明

[0073] 此处所说明的附图用来提供对本发明的进一步理解,构成本申请的一部分,并不构成对本发明的限定。附图中的部件不是成比例绘制的,而只是为了示出本发明的原理。为了便于示出和描述本发明的一些部分,附图中对应部分可能被放大,即,相对于依据本发明实际制造的示例性装置中的其它部件可能变得更大。在附图中:

[0074] 图1为本发明一实施例的基于机器学习的裂隙岩体裂隙数量确定方法的流程图;

[0075] 图2为本发明一实施例的基于机器学习的裂隙岩体质量评价方法的流程图;

[0076] 图3为本发明一实施例的基于机器学习的裂隙岩体裂隙数量确定方法中的机器学习模型和全卷积层结构图;

[0077] 图4为本发明一实施例的电子设备的框图。

具体实施方式

[0078] 为使本发明的目的、技术方案和优点更加清楚明白,下面结合实施方式和附图,对本发明做进一步详细说明。在此,本发明的示意性实施方式及其说明用于解释本发明,但并不作为对本发明的限定。

[0079] 在此,还需要说明的是,为了避免因不必要的细节而模糊了本发明,在附图中仅仅示出了与根据本发明的方案密切相关的结构和/或处理步骤,而省略了与本发明关系不大的其他细节。

[0080] 应该强调,术语“包括/包含”在本文使用时指特征、要素、步骤或组件的存在,但并不排除一个或多个其它特征、要素、步骤或组件的存在或附加。

[0081] 在此,还需要说明的是,如果没有特殊说明,术语“连接”在本文不仅可以指直接连接,也可以表示存在中间物的间接连接。

[0082] 在下文中,将参考附图描述本发明的实施例。在附图中,相同的附图标记代表相同或类似的部件,或者相同或类似的步骤。

[0083] 首先,将参考图1描述根据本申请实施例的基于机器学习的裂隙岩体裂隙数量确定方法。如图1所示,确定方法可以包括如下步骤:

[0084] 在步骤S110,通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵。通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据。

[0085] 在步骤S120,对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集。

[0086] 在步骤S130,基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量。

[0087] 在步骤S140,将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型。

[0088] 在步骤S150,训练深度学习模型直至收敛,输出此时满足要求的预测概率模型。

[0089] 在步骤S160,获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,确定目标区域的岩体浅表层内的裂隙数量。

[0090] 在本申请的实施例中,首先通过采集原位裂隙岩体的试验区域的岩体表面热红外

图像获得对应的温度序列矩阵,通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据;然后对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集;接着基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量;将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型;然后训练深度学习模型直至收敛,输出此时满足要求的预测概率模型;再然后获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,最终确定目标区域的岩体浅表层内的裂隙数量。

[0091] 通过上述过程的描述可知,根据本申请实施例的确定方法,基于大量热红外探测试验数据,通过建立适应于热红外裂隙岩体结构探测的机器学习方法,对原位探测的岩体表面热红外数据进行处理,实现野外裂隙岩体裂隙数量的识别,具有无损、快速、高效的特点。

[0092] 其中,岩体是一种不连续性、非均质性和各向异性的地质体,在内外营力长期作用下岩体不断劣化,不稳定性病害时有发生,严重影响人类生产生活。目前,人类生产建设中的岩体工程类型很多,该类工程对岩体的劣化结构敏感性较强和有特殊使用需求,对岩体的劣化较为敏感,快速实现其裂隙相关参数(例如裂隙数量)分析异常重要,可为灾害的诊断、防止提供有效决策。

[0093] 在本申请的实施例中,步骤S110中通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵。通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据。

[0094] 具体地,步骤S110可以包括以下内容:开展原位裂隙岩体主动式红外探测试验,划分好N块矩形试验区域。N的大小依据需要确定。通过热红外相机对每块试验区域拍摄多组不同岩体表面的热红外图像。然后将热红外图像传输给计算机或其他处理终端,通过计算机内安装的Smartview软件获取第n个试验区域岩体表面的温度序列矩阵 $T_{i,n}^0$, $0 \leq i \leq I$, $0 \leq n \leq N$ 。I为第n个试验区域岩体表面对应拍摄的热红外图像的总张数。其中,拍摄第n个试验区域岩体表面中第i张热红外图像的时间为 $t_{i,n}$ 。拍摄第n个试验区域初始温度为温度矩阵 $T_{0,n}^0$ 。为了拍摄的热红外图像更明显,还可以在拍摄前对试验区域的岩体表面进行持续的主动式红外加热激励等。

[0095] 可以通过使用传统皮尺、罗盘、塞尺和钻孔等工具或方式进行原位裂隙岩体内外部裂隙调查,得出第n个试验区域岩体浅表面10cm以内的裂隙数量 j_n 。N个试验区域中岩体浅表面10cm以内的最大裂隙数量为J, $1 \leq j_n \leq J$ 。其中,第n个试验区域岩体浅表面内的裂隙数量 j_n 在下文的相关步骤中可以作为标签信息使用。

[0096] 在本申请的实施例中,步骤S120中对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集。具体可以包括以下步骤:

[0097] 步骤S121:对温度序列矩阵 $T_{i,n}^0$ 进行上下、左右反转各一次。这样一个试验区域热红外图像拍摄可获得I条数据,N个不同试验区域总共可生成IN条数据。经过反转处理后可获得3IN条数据。这样增加了样本数量,以及提高后续模型的鲁棒性。

[0098] 步骤S122:基于划分的试验区域四个顶点坐标,得出几何校正矩阵B,再对温度序

列矩阵 $T_{i,n}^0$ 进行几何校正,

$$[0099] \quad \mathbf{B} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$[0100] \quad [x' \ y' \ z'] = [u \ v \ 1] \mathbf{B}$$

$$[0101] \quad x = \frac{x'}{z'}$$

$$[0102] \quad y = \frac{y'}{z'}$$

[0103] 其中, u 、 v 为第 n 个试验区域岩体表面中第 i 个温度序列矩阵 $T_{i,n}^0$ 的坐标。 x 、 y 为温度序列矩阵 $T_{i,n}^0$ 通过几何校正后得到的坐标。 z' 是把一个二维坐标系转换为三维坐标系,然后把三维坐标系投影到新的二维坐标系的相关参数。 a_{11} 、 a_{22} 、 a_{22} 和 a_{22} 是仿射变换参数,能改变平面位置和形状,但是边都是保持平直状态的。 a_{31} 和 a_{32} 是平移变换参数。 a_{13} 和 a_{23} 表示变换后边缘交点关系。 a_{33} 是一个缩放因子,一般都会归一化为1。温度序列矩阵 $T_{i,n}^0$ 的元素根据坐标变换后重新排列得到温度矩阵 $T_{i,n}^1$,缺失的元素按双线性插值补充。

[0104] 步骤S123:计算第 n 个试验区域岩体表面的第 i 张到第 $i+1$ 张热红外图像的温差矩阵 $T_{i,n}^2$,

$$[0105] \quad T_{i,n}^2 = T_{i+1,n}^1 - T_{i,n}^1$$

[0106] 其中, $T_{i+1,n}^1$ 为第 n 个试验区域岩体表面的第 $(i+1)$ 个经过坐标变换后的温度矩阵。

[0107] 步骤S124:对温差矩阵 $T_{i,n}^2$ 进行标准化,获得矩阵 $T_{i,n}^3$,

$$[0108] \quad T_{i,n}^3 = \frac{T_{i,n}^2 - \mu}{\sigma}$$

[0109] 其中, μ 为第 n 个试验区域岩体表面的第 i 个温差矩阵 $T_{i,n}^2$ 的均值。 σ 为温差矩阵 $T_{i,n}^2$ 的标准差。

[0110] 步骤S125:构建热红外图像数据集 $data$,

$$[0111] \quad data = \begin{bmatrix} data_{(0)} \\ data_{(1)} \\ data_{(2)} \end{bmatrix}$$

$$[0112] \quad data_{(0)} = \begin{bmatrix} T_{1,1} & j_1 \\ T_{2,1} & j_1 \\ \vdots & \vdots \\ T_{l,1} & j_1 \\ T_{1,2} & j_2 \\ \vdots & \vdots \\ T_{l,N} & j_N \end{bmatrix}$$

$$[0113] \quad T_{i,n} = [T_{0,n}^1, T_{i,n}^1, T_{i,n}^3]$$

[0114] 其中, $\text{data}_{(0)}$ 的一条数据结构是由样本矩阵 $T_{i,n}$ 和以第 n 个试验区域岩体浅表面内的裂隙数量 j_n 作为的标签信息组成。 $T_{i,n}$ 是由 $T_{0,n}^1$, $T_{i,n}^1$ 和 $T_{i,n}^3$ 三个温度矩阵组成的一个三维矩阵。

[0115] 由于温度序列矩阵 $T_{i,n}^0$ 进行了上下、左右反转各一次, 按照上述相同步骤可得到 $\text{data}_{(1)}$ 和 $\text{data}_{(2)}$ 。可以理解, 由于步骤S121中对温度序列矩阵 $T_{i,n}^0$ 进行上下、左右反转各一次, 此步骤中热红外图像数据集 data 的数据量也为 $3IN$ 条数据。将热红外图像数据集 data 中的 $3IN$ 条数据随机划分为训练集、验证集以及测试集。其各自比例依据需要确定。例如可以将各个试验区域产生的热红外图像数据集 data 按 $7:1:2$ 的比例划分训练集、验证集以及测试集。

[0116] 在本申请的实施例中, 步骤S130中基于深度学习模型对热红外图像数据集进行裂隙特征提取, 并通过增加特征提取的维度以获得卷积特征向量。具体地, 参考图4, 将训练集数据随机打乱, 可以采用激活函数ReLU, 矩阵 $T_{i,n}$ 通过一个卷积层和四个残差模块提取热红外图像的特征, 每个残差模块由四个残差块组成, 残差块是一个两层的神经网络。

[0117] 然后通过平均池化操作将热红外图像的尺度规模减小, 获得大小为 $1 \times 1 \times 4096$ 的卷积特征向量。以使深度学习模型更好识别到细微的差别。

[0118] 其中, 深度学习模型的卷积层以及池化层结构及其参数如下:

	层名	激活函数	卷积核	步长	输出层大小
	conv1	relu	7×7	2	$128 \times 128 \times 64$
	conv2	relu	3×3	[2,1,1,1]	$64 \times 64 \times 64$
[0119]	conv3	relu	3×3	[2,1,1,1]	$32 \times 32 \times 128$
	conv4	relu	3×3	[2,1,1,1]	$16 \times 16 \times 256$
	conv5	relu	3×3	[2,1,1,1]	$8 \times 8 \times 512$
	pool layer	relu	4×4	4	$1 \times 1 \times 4096$

[0120] 在本申请的实施例中, 步骤S140中将卷积特征向量通过全卷积层进行特征识别, 获得深度学习模型识别到的裂隙数量对应的预测概率模型。即将深度学习模型提取的特征进行识别, 将输入节点通过全卷积层, 将输入特征组合和变换为输出特征, 使深度学习模型进行非线性的映射和复杂的特征提取。

[0121] 步骤S140可以具体采用如下方式:

[0122] 首先将卷积特征向量通过两个 1×1 全卷积网络, 得到类别特征矩阵 X_j 。

[0123] 然后将类别特征矩阵 X_j 通过计算机内安装的softmax软件得到包含每个类别 (每种可能的裂隙数量) 的预测分数, 即每个试验区域中各个类别的的预测概率, 得到大小为 $2 \times J$ 的裂隙数量预测矩阵 C ,

$$[0124] \quad d_k = \frac{c_k}{\sum_{k=1}^J c_k}$$

$$[0125] \quad \mathbf{C} = \begin{bmatrix} c_1 & d_1 \\ c_2 & d_2 \\ c_3 & d_3 \\ \vdots & \vdots \\ c_J & d_J \end{bmatrix}$$

[0126] 其中, j 表示深度学习模型识别到的裂隙数量。 c_k 是识别裂隙数量为 k 条的权重。 d_k 是识别裂隙数量为 k 条的预测概率。

[0127] 其中,全卷积层结构及其参数如下:

	层名	卷积核	输出层大小
[0128]	dense layer	第 1 层 第 2 层	1000×1×1×4096 $J \times 1 \times 1 \times 1000$
			1×1×1000 1×1× J

[0129] 在本申请的实施例中,步骤S150中训练深度学习模型直至收敛,输出此时满足要求的预测概率模型。进一步地,通过损失函数和随机梯度下降(SGD)算法对深度学习模型进行训练,更新深度学习模型的权重值,验证集优化网络超参数,测试集对模型的泛化能力进行评估。

[0130] 具体地,步骤S150可以包括:

[0131] 步骤S151:采用损失函数:

$$[0132] \quad L = -\frac{1}{R} \sum_r \sum_{k=1}^J y_{r,k} \log(d_k)$$

[0133] 其中, R 是训练集数据数量。 $y_{r,k}$ 为符号函数,其取值为0或1。训练集中的第 r 个样本数据的真实类别 j_n 等于 k 取1,否则取0, $0 \leq r \leq R$ 。

[0134] 步骤S152:采用SGD算法更新权重:

$$[0135] \quad \mathbf{w}' = \mathbf{w} - \eta \nabla L(\mathbf{w}; T_{i,n}, j_n)$$

[0136] 其中, \mathbf{w} 是深度学习模型中要更新的权重向量。 \mathbf{w}' 是更新后的权重向量。 η 是学习率,决定了每次权重更新的步长。 $\nabla L(\mathbf{w}; T_{i,n}, j_n)$ 是损失函数 L 在样本 $T_{i,n}$ 和标签 j_n 关于权重 \mathbf{w} 的梯度,该梯度表示损失函数对于权重的变化方向和速度。

[0137] 步骤S153:将训练集导入深度学习模型中,训练完成后导入验证集得出模型的accuracy的值,accuracy是验证集所有样本被模型检测正确的比例,使用不同的学习率、权重衰减、批量大小、训练迭代次数超参数组合,使accuracy的值达到预定值,即深度学习模型的预测的效果达到较好,最后导入测试集计算深度学习模型的F1值对模型的泛化能力进行评估。当F1'值大于0.8时输出此时的预测概率模型,

$$[0138] \quad F1_k = \left(\frac{\text{recall}^{-1} + \text{precision}^{-1}}{2} \right)^{-1}$$

$$[0139] \quad F1' = \sum_{k=1}^J F1_k$$

[0140] 其中,precision是精准率,表示深度学习模型在测试集上预测裂隙数量为 k 的所

有样本中,其实际裂隙数量也为k的比例,即每一个类别k都有一个精准率。recall是召回率,表示在测试集上实际裂隙数量为k的所有样本中,深度学习模型预测裂隙数量也为k的比例,即每一个类别k都有一个召回率。 $F1_k$ 是预测为k的F1值, $F1'$ 是深度学习模型总的F1值。

[0141] 在步骤S160中,在划分的所有试验区域之外,可以再划分一区域,名称定为目标区域。也可以通过拍摄的方式获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵。同理,经格式转换后导入满足要求的预测概率模型,输出预测分数最高的类别 d_k 。即获得预测概率最高的裂隙数量,则目标区域的岩体浅表层内的裂隙数量为k。

[0142] 基于上面的描述,根据本申请实施例的确定方法,其应用于裂隙岩体,为野外裂隙岩体裂隙数量的识别,提供了一种快速、高效、无损、非接触的方法。

[0143] 参考图2,本发明还提供一种基于机器学习的裂隙岩体质量评价方法200。如图2所示,根据本申请实施例的评价方法200可以包括如下步骤:

[0144] 在步骤S210,通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵。通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据。

[0145] 在步骤S220,对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集。

[0146] 在步骤S230,基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量。

[0147] 在步骤S240,将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型。

[0148] 在步骤S250,训练深度学习模型直至收敛,输出此时满足要求的预测概率模型。

[0149] 在步骤S260,获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,确定目标区域的岩体浅表层内的裂隙数量。

[0150] 在步骤S270,基于目标区域的面积和确定的裂隙数量,结合采集的目标区域热红外图像的初始时刻和其他某时刻的各自对应的平均温度,归一化获得岩体质量评价参数 α 。其中, $0 \leq \alpha \leq 1$, α 值越小表示岩体质量越好。

[0151] 其中,步骤S210至步骤S260,可以分别参照确定方法100中的步骤S110至步骤S160,在此不进行详述。本实施例就其中的步骤S270进行重点阐述。

[0152] 岩体质量评价参数 α 的一种具体计算方法如下:

$$[0153] \quad \alpha = E_1 \frac{kA_j}{JA} + E_2 \frac{\Delta T_i^2 - \Delta T^2}{\Delta T^1 - \Delta T^2}$$

$$[0154] \quad \Delta T_i = \text{avg}T_i - \text{avg}T_0$$

$$[0155] \quad \Delta T_{i,n}^1 = \text{avg}T_{i,n}^1 - \text{avg}T_{0,n}^1$$

$$[0156] \quad \Delta T^1 = \max(\Delta T_{i,n}^1)$$

$$[0157] \quad \Delta T^2 = \min(\Delta T_{i,n}^1)$$

[0158] 其中,A是目标区域的面积。 $\text{avg}T_0$ 和 $\text{avg}T_i$ 分别是拍摄的目标区域热红外图像对应的温度序列矩阵在初始时刻 t_0 和其他时刻 t_i 平均温度。 ΔT_i 是目标区域热红外图像在初始时刻 t_0 和 t_i 时刻的平均温差。 $\Delta T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标

变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 在 t_0 和 t_i 时刻的平均温差。 $\text{avg}T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 中元素的平均值。 $\text{avg}T_{0,n}^1$ 是 $\text{avg}T_{i,n}^1$ 在初始时刻 t_0 对应的值。 ΔT^1 是 $\Delta T_{i,n}^1$ 的最大值。 ΔT^2 是 $\Delta T_{i,n}^1$ 的最小值。 A_j 是试验区域热红外图像对应的温度序列矩阵中标签为最大裂隙数量 J 对应的试验区域面积。 E_1 、 E_2 分别是裂隙参数(裂隙数量)和温度参数(温度序列矩阵)的权重。

[0159] 其中,为了方便计算,可以将所有划分的试验区域,以及目标区域的面积都设置成相同的,即试验区域和目标区域的面积都是 A 。本实施例中,裂隙参数 E_1 和温度参数 E_2 两个因素的权重可以各取0.5,当然也可以根据需要将该权重设置成其它。

[0160] 需要说明的是,岩体质量评价参数 α 可以基于上述公式计算确定,也可以通过其他可以得到岩体质量评价参数 α 的公式计算确定,在此不做限定。

[0161] 另外,为了对岩体质量评价参数进行更明显的区分、体现效果的差异,对岩体质量评价参数分为1到5级岩体。1级为质量最好($0 \leq \alpha \leq 0.2$),2级为质量较好($0.2 \leq \alpha \leq 0.4$),3级为质量一般($0.4 \leq \alpha \leq 0.6$),4级为质量较差($0.6 \leq \alpha \leq 0.8$),5级为质量最差($0.8 \leq \alpha \leq 1$)。

[0162] 基于上面的描述,根据本申请实施例的评价方法,分析机器学习模型探测的结果,建立与岩体质量指标的关系,评价岩体的稳定性,并对岩体质量进行等级划分,为工程的实施提供依据,提高设计、施工、安全、预警的可靠性。

[0163] 参考图3,用于实现根据本申请实施例的确定方法或评价方法的电子设备300包括处理器310和存储器320。电子设备300可以包括一个或多个处理器310、一个或多个存储器320。存储器320存储有由处理器310运行的可执行程序,所述可执行程序在被处理器310运行时,使得处理器310执行前文所述的根据本申请实施例的确定方法或评价方法。

[0164] 所述处理器310可以是中央处理单元(CPU)或者具有数据处理能力和/或指令执行能力的其它形式的处理单元,并且可以控制所述电子设备300中的其它组件以执行期望的功能。

[0165] 所述存储器320可以包括一个或多个计算机程序产品,所述计算机程序产品可以包括各种形式的计算机可读存储介质,例如易失性存储器和/或非易失性存储器。所述易失性存储器例如可以包括随机存取存储器(RAM)和/或高速缓冲存储器(cache)等。所述非易失性存储器例如可以包括只读存储器(ROM)、硬盘、闪存等。在所述计算机可读存储介质上可以存储一个或多个计算机程序指令,处理器310可以运行所述程序指令,以实现本文所述的本发明实施例中(由处理器实现)的客户端功能以及/或者其它期望的功能。在所述计算机可读存储介质中还可以存储各种应用程序和各种数据,例如所述应用程序使用和/或产生的各种数据等。

[0166] 电子设备300还可以包括输入装置(未示出)以及输出装置(未示出),这些组件通过总线系统(未示出)和/或其它形式的连接机构互连。应当注意,图3所示的电子设备300的组件和结构只是示例性的,而非限制性的,根据需要,所述电子设备300也可以具有其他组件和结构。

[0167] 所述输入装置可以是用户用来输入指令的装置,并且可以包括键盘、鼠标、麦克风和触摸屏等中的一个或多个。此外,所述输入装置也可以是任何接收信息的接口。

[0168] 所述输出装置可以向外部(例如用户)输出各种信息(例如图像或声音),并且可以包括显示器、扬声器等中的一个或多个。此外,所述输出装置也可以是任何其他具备输出功能的设备。

[0169] 示例性地,用于实现根据本发明实施例的确定方法或评价方法的示例电子设备300可以应用于终端设备(比如手机)、平板电脑、笔记本电脑、超级移动个人计算机(ultra-mobile personal computer,UMPC)、手持计算机、上网本、个人数字助理(personal digital assistant,PDA)、可穿戴设备(如智能手表、智能眼镜或者智能头盔等)、增强现实(augmented reality,AR)、虚拟现实(virtualreality,VR)设备、智能家居设备、车载电脑等电子设备中,本申请实施例对此不做任何限制。

[0170] 本领域技术人员可以结合前文所述的内容理解根据本申请实施例的确定方法或评价方法的电子设备300的具体操作,为了简洁,此处不再赘述具体的细节,仅描述处理器310的一些主要操作。

[0171] 在本申请的一个实施例中,所述可执行程序在被处理器310运行时,使得处理器310执行如下步骤:通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵,通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据;对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集;基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量;将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型;训练深度学习模型直至收敛,输出此时满足要求的预测概率模型;获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,确定目标区域的岩体浅表层内的裂隙数量。

[0172] 在本申请的一个实施例中,所述可执行程序在被处理器310运行时,使得处理器310还执行如下步骤:对温度序列矩阵 $T_{i,n}^0$ 进行上下、左右反转各一次;

[0173] 基于划分的试验区域四个顶点坐标,得出几何校正矩阵B,再对温度序列矩阵 $T_{i,n}^0$ 进行几何校正,

$$[0174] \quad \mathbf{B} = \begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

$$[0175] \quad [x' \ y' \ z'] = [u \ v \ 1] \mathbf{B}$$

$$[0176] \quad x = \frac{x'}{z'}$$

$$[0177] \quad y = \frac{y'}{z'}$$

[0178] 其中,u、v为第n个试验区域岩体表面中第i个温度序列矩阵 $T_{i,n}^0$ 的坐标,x、y为温度序列矩阵 $T_{i,n}^0$ 通过几何校正后得到的坐标,z'是把二维坐标系转换为三维坐标系,然后把三维坐标系投影到新的二维坐标系的相关参数; a_{11} 、 a_{12} 、 a_{21} 和 a_{22} 是仿射变换参数; a_{31} 和 a_{32} 是平移变换参数; a_{13} 和 a_{23} 表示变换后边缘交点关系, a_{33} 是一个缩放因子,会归一化为1;温度

序列矩阵 $T_{i,n}^0$ 的元素根据坐标变换后重新排列得到温度矩阵 $T_{i,n}^1$,缺失的元素按双线性插值补充;

[0179] 计算第n个试验区域岩体表面的第i张到第i+1张热红外图像的温差矩阵 $T_{i,n}^2$,

$$[0180] \quad T_{i,n}^2 = T_{i+1,n}^1 - T_{i,n}^1$$

[0181] 其中, $T_{i+1,n}^1$ 为第n个试验区域岩体表面的第i+1个经过坐标变换后的温度矩阵;

[0182] 对温差矩阵 $T_{i,n}^2$ 进行标准化,获得矩阵 $T_{i,n}^3$,

$$[0183] \quad T_{i,n}^3 = \frac{T_{i,n}^2 - \mu}{\sigma}$$

[0184] 其中, μ 为第n个试验区域岩体表面的第i个温差矩阵 $T_{i,n}^2$ 的均值, σ 为温差矩阵 $T_{i,n}^2$ 的标准差;

[0185] 构建热红外图像数据集data,

$$[0186] \quad data = \begin{bmatrix} data_{(0)} \\ data_{(1)} \\ data_{(2)} \end{bmatrix}$$

$$data_{(0)} = \begin{bmatrix} T_{1,1} & j_1 \\ T_{2,1} & j_1 \\ \vdots & \vdots \\ T_{I,1} & j_1 \\ T_{1,2} & j_2 \\ \vdots & \vdots \\ T_{I,N} & j_N \end{bmatrix}$$

$$T_{i,n} = [T_{0,n}^1, T_{i,n}^1, T_{i,n}^3]$$

[0187] 其中, $data_{(0)}$ 的一条数据结构是由样本矩阵 $T_{i,n}$ 和以第n个试验区域岩体浅表面内的裂隙数量 j_n 作为的标签信息组成,由于温度序列矩阵 $T_{i,n}^0$ 进行了上下、左右反转各一次,按照相同步骤可得到 $data_{(1)}$ 和 $data_{(2)}$ 。

[0188] 在本申请的一个实施例中,所述可执行程序在被处理器310运行时,使得处理器310还执行如下步骤:将卷积特征向量通过两个 1×1 全卷积网络,得到类别特征矩阵 X_j ;

[0189] 将类别特征矩阵 X_j 通过softmax软件得到包含每个类别的预测概率,得到大小为 $2 \times J$ 的裂隙数量预测矩阵C,

$$[0190] \quad d_k = \frac{c_k}{\sum_{k=1}^J c_k}$$

$$[0191] \quad C = \begin{bmatrix} c_1 & d_1 \\ c_2 & d_2 \\ c_3 & d_3 \\ \vdots & \vdots \\ c_J & d_J \end{bmatrix}$$

[0192] 其中,k表示深度学习模型识别到的裂隙数量, c_k 是识别裂隙数量为k条的权重, d_k

是识别裂隙数量为k条的预测概率。

[0193] 在本申请的一个实施例中,所述可执行程序在被处理器310运行时,使得处理器310执行如下步骤:通过采集原位裂隙岩体的试验区域的岩体表面热红外图像,获得对应的温度序列矩阵,通过采集原位裂隙岩体的试验区域的岩体浅表层内的裂隙数量数据;对温度序列矩阵进行增加样本数量和格式转换处理,结合所采集的裂隙数量数据构建热红外图像数据集;基于深度学习模型对热红外图像数据集进行裂隙特征提取,并通过增加特征提取的维度以获得卷积特征向量;将卷积特征向量通过全卷积层进行特征识别,获得深度学习模型识别到的裂隙数量对应的预测概率模型;训练深度学习模型直至收敛,输出此时满足要求的预测概率模型;获取原位裂隙岩体的目标区域的岩体表面热红外图像对应的温度序列矩阵,经格式转换后导入满足要求的预测概率模型,获得预测概率最高的裂隙数量,确定目标区域的岩体浅表层内的裂隙数量。基于目标区域的面积和确定的裂隙数量,结合采集的目标区域热红外图像的初始时刻和其他某时刻的各自对应的平均温度,归一化获得岩体质量评价参数 α 。其中, $0 \leq \alpha \leq 1$, α 值越小表示岩体质量越好。

[0194] 在本申请的一个实施例中,所述可执行程序在被处理器310运行时,使得处理器310执行如下步骤:岩体质量评价参数 α ,

$$[0195] \quad \alpha = E_1 \frac{kA_J}{JA} + E_2 \frac{\Delta T_i^2 - \Delta T^2}{\Delta T^1 - \Delta T^2}$$

$$[0196] \quad \Delta T_i = \text{avg}T_i - \text{avg}T_0$$

$$[0197] \quad \Delta T_{i,n}^1 = \text{avg}T_{i,n}^1 - \text{avg}T_{0,n}^1$$

$$[0198] \quad \Delta T^1 = \max(\Delta T_{i,n}^1)$$

$$[0199] \quad \Delta T^2 = \min(\Delta T_{i,n}^1)$$

[0200] 其中,A是目标区域的面积。 $\text{avg}T_0$ 和 $\text{avg}T_i$ 分别是拍摄的目标区域热红外图像对应的温度序列矩阵在初始时刻 t_0 和其他时刻 t_i 平均温度。 ΔT_i 是目标区域热红外图像在初始时刻 t_0 和 t_i 时刻的平均温差。 $\Delta T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 在 t_0 和 t_i 时刻的平均温差。 $\text{avg}T_{i,n}^1$ 是试验区域热红外图像对应的温度序列矩阵根据坐标变换后重新排列得到的温度矩阵 $T_{i,n}^1$ 中元素的平均值。 $\text{avg}T_{0,n}^1$ 是 $\text{avg}T_{i,n}^1$ 在初始时刻 t_0 对应的值。 ΔT^1 是 $\Delta T_{i,n}^1$ 的最大值。 ΔT^2 是 $\Delta T_{i,n}^1$ 的最小值。 A_J 是试验区域热红外图像对应的温度序列矩阵中标签为最大裂隙数量J对应的试验区域面积。 E_1 、 E_2 分别是裂隙参数(裂隙数量)和温度参数(温度序列矩阵)的权重。

[0201] 此外,根据本申请实施例,本发明还提供了一种存储介质,在所述存储介质上存储了计算机程序,在所述计算机程序被处理器运行时用于执行本申请实施例的确定方法或评价方法的相应步骤。所述存储介质例如可以包括智能电话的存储卡、平板电脑的存储部件、个人计算机的硬盘、只读存储器(ROM)、可擦除可编程只读存储器(EPROM)、便携式紧致盘只读存储器(CD-ROM)、USB存储器、或者上述存储介质的任意组合。所述计算机可读存储介质可以是一个或多个计算机可读存储介质的任意组合。

[0202] 尽管这里已经参考附图描述了示例实施例,应理解上述示例实施例仅仅是示例性的,并且不意图将本申请的范围限制于此。本领域普通技术人员可以在其中进行各种改变和修改,而不偏离本申请的范围和精神。所有这些改变和修改意在被包括在所附权利要求

所要求的本申请的范围之内。

[0203] 本领域普通技术人员可以意识到,结合本文中所公开的实施例描述的各示例的单元及算法步骤,能够以电子硬件、或者计算机软件和电子硬件的结合来实现。这些功能究竟以硬件还是软件方式来执行,取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能,但是这种实现不应认为超出本申请的范围。

[0204] 在本申请所提供的几个实施例中,应该理解到,所揭露的设备和方法,可以通过其它的方式实现。例如,以上所描述的设备实施例仅仅是示意性的,例如,所述单元的划分,仅仅为一种逻辑功能划分,实际实现时可以有另外的划分方式,例如多个单元或组件可以结合或者可以集成到另一个设备,或一些特征可以忽略,或不执行。

[0205] 在此处所提供的说明书中,说明了大量具体细节。然而,能够理解,本申请的实施例可以在没有这些具体细节的情况下实践。在一些实例中,并未详细示出公知的方法、结构和技术,以便不模糊对本说明书的理解。

[0206] 类似地,应当理解,为了精简本申请并帮助理解各个发明方面中的一个或多个,在对本申请的示例性实施例的描述中,本申请的各个特征有时被一起分组到单个实施例、图、或者对其的描述中。然而,并不应将该本申请的方法解释成反映如下意图:即所要求保护的本申请要求比在每个权利要求中所明确记载的特征更多的特征。更确切地说,如相应的权利要求书所反映的那样,其发明点在于可以用少于某个公开的单个实施例的所有特征的特征来解决相应的技术问题。因此,遵循具体实施方式的权利要求书由此明确地并入该具体实施方式,其中每个权利要求本身都作为本申请的单独实施例。

[0207] 本领域的技术人员可以理解,除了特征之间相互排斥之外,可以采用任何组合对本说明书(包括伴随的权利要求、摘要和附图)中公开的所有特征以及如此公开的任何方法或者设备的所有过程或单元进行组合。除非另外明确陈述,本说明书(包括伴随的权利要求、摘要和附图)中公开的每个特征可以由提供相同、等同或相似目的的替代特征来代替。

[0208] 此外,本领域的技术人员能够理解,尽管在此所述的一些实施例包括其它实施例中所述的某些特征而不是其它特征,但是不同实施例的特征的组合意味着处于本申请的范围之内并且形成不同的实施例。例如,在权利要求书中,所要求保护的实施例的任意之一都可以以任意的组合方式来使用。

[0209] 本申请的各个部件实施例可以以硬件实现,或者以在一个或者多个处理器上运行的软件模块实现,或者以它们的组合实现。本领域的技术人员应当理解,可以在实践中使用微处理器或者数字信号处理器(DSP)来实现根据本申请实施例的一些模块的一些或者全部功能。本申请还可以实现为用于执行这里所描述的方法的一部分或者全部的装置程序(例如,计算机程序和计算机程序产品)。这样的实现本申请的程序可以存储在计算机可读介质上,或者可以具有一个或者多个信号的形式。这样的信号可以从因特网网站上下载得到,或者在载体信号上提供,或者以任何其他形式提供。

[0210] 应该注意的是上述实施例对本申请进行说明而不是对本申请进行限制,并且本领域技术人员在不脱离所附权利要求的范围的情况下可设计出替换实施例。在权利要求中,不应将位于括号之间的任何参考符号构造成对权利要求的限制。单词“包含”不排除存在未列在权利要求中的元件或步骤。位于元件之前的单词“一”或“一个”不排除存在多个这样的

元件。本申请可以借助于包括有若干不同元件的硬件以及借助于适当编程的计算机来实现。在列举了若干装置的单元权利要求中,这些装置中的若干个可以是通过同一个硬件项来具体体现。单词第一、第二、以及第三等的使用不表示任何顺序。可将这些单词解释为名称。

[0211] 以上所述,仅为本申请的具体实施方式或对具体实施方式的说明,本申请的保护范围并不局限于此,任何熟悉本技术领域的技术人员在本申请揭露的技术范围内,可轻易想到变化或替换,都应涵盖在本申请的保护范围之内。本申请的保护范围应以权利要求的保护范围为准。

100

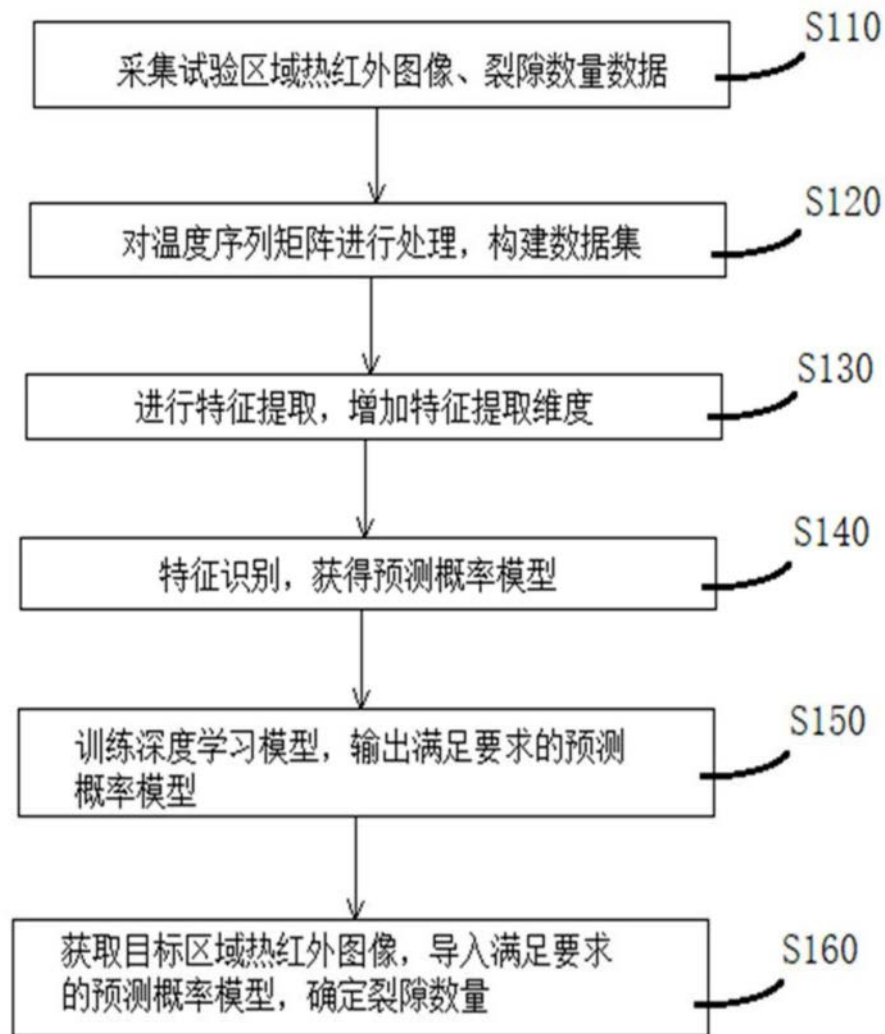


图1

200

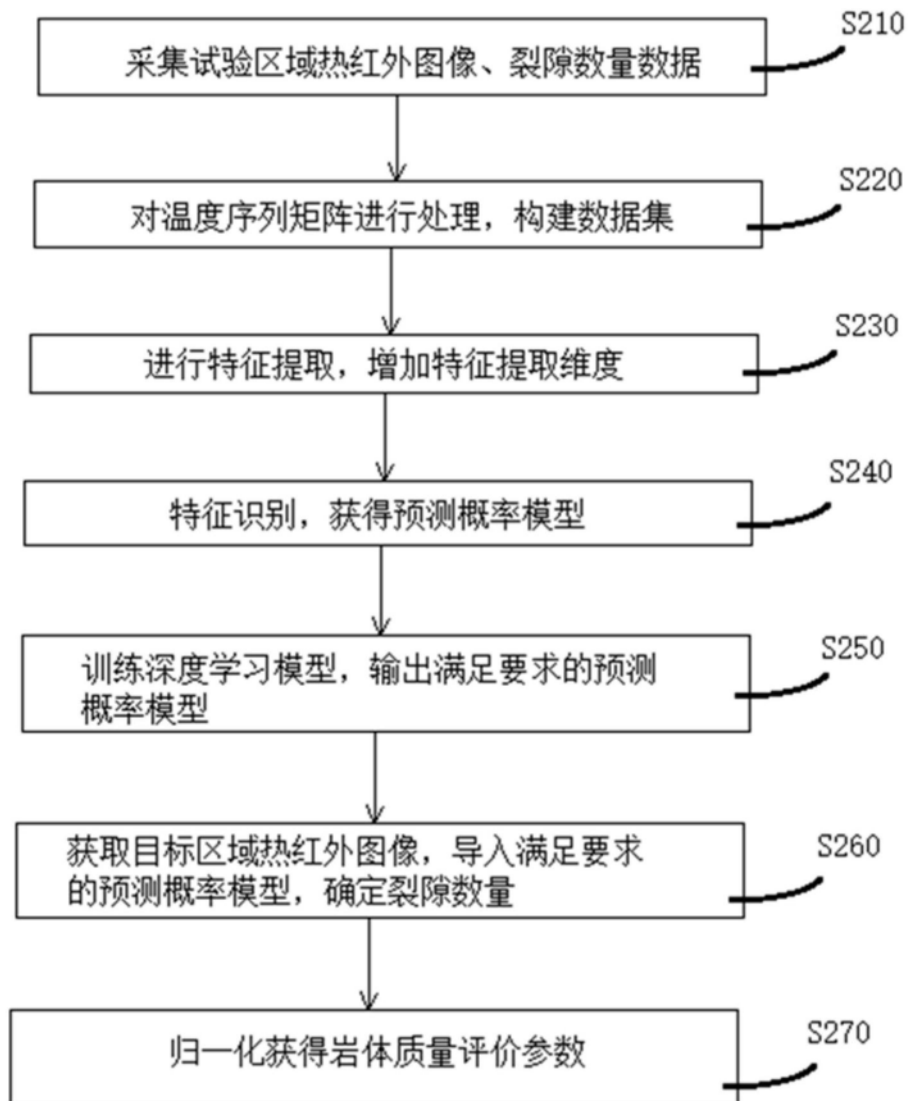


图2




图3




图4