



(12)发明专利申请

(10)申请公布号 CN 108520278 A

(43)申请公布日 2018.09.11

(21)申请号 201810317128.9

(22)申请日 2018.04.10

(71)申请人 陕西师范大学

地址 710119 陕西省西安市长安区西长安街620号陕西师范大学长安校区

(72)发明人 李良福 高小小 孙瑞赟

(74)专利代理机构 西安智萃知识产权代理有限公司 61221

代理人 赵双

(51) Int. Cl.

G06K 9/62(2006.01)

G06T 5/30(2006.01)

G06T 5/40(2006.01)

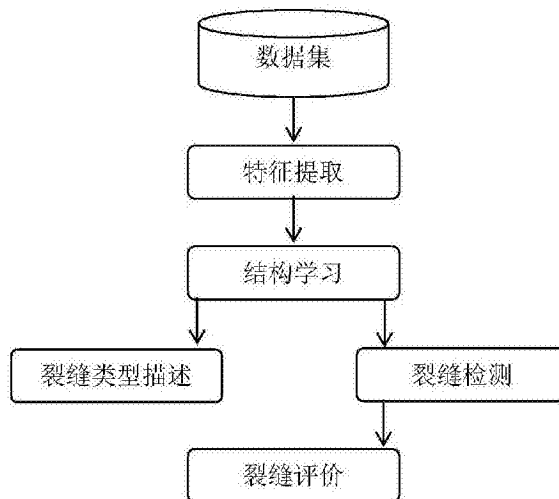
权利要求书3页 说明书12页 附图8页

(54)发明名称

一种基于随机森林的路面裂缝检测方法及其评价方法

(57)摘要

本发明涉及一种基于随机森林的路面裂缝检测方法及其评价方法,包括以下步骤首先,对x提取特征,然后用随机结构森林对x进行训练,所有的模板共同组成模板结构空间,然后对图像块进行二值化处理和膨胀腐蚀操作,其次对模板结构空间里的所有模板,用新的裂缝描述子进行描述,把这些描述特征都输入到分类器中进行学习,最后将原图输入到分类器中进行分类,识别出含有裂缝的图像块,那么,含有裂缝的图像块被置为该图像块对应的二值化的结果,不含裂缝的图像块被置为白色0。本发明能够有效的检测路面结构复杂的裂缝,避免受到噪声的影响,裂缝检测准确度高。本发明的评价方法针对图像块,从连续性判断路面的裂缝情况,进而发现路面存在的安全隐患。



1. 一种基于随机森林的路面裂缝检测方法,其特征在于:包括以下步骤:步骤1,采集路面的灰度图像,将灰度图像分割成多个图像块 x ,并生成图像块 x 对应的二值化分割模板 y ;

步骤2,对图像块 x 提取图像特征 θ_j ,图像特征 θ_j 包括每个图像块 x 的均值特征 μ 、标准差特征 S ,以及积分通道特征;

步骤3,将所述多个含有裂缝的图像块 x 输入决策森林中,每个树的左叶子对应分割模板 y 或生成的新分割模板 y' ;分割模板 y 和新分割模板 y' 构成了结构空间 γ ;

步骤4,将所述图像块 x 进行二值化,并进行腐蚀和膨胀操作消除噪声,得到二值化图像块;

步骤5,将所述结构空间 γ 中的分割模板 y 和新分割模板 y' 用裂缝描述子进行特征提取,然后通过分类器进行学习;

步骤6,将所述路面的灰度图像输入到分类器中,将不含裂缝的图像块 x 均置为0,含有裂缝的图像块 x 均置为所述二值化图像块。

2. 根据权利要求1所述的方法,其特征在于:所述步骤2中的均值特征 μ 和标准差特征 S 分别根据以下公式得到:

$$\mu = \frac{1}{M * N} \sum_{m=1}^M \sum_{n=1}^N x(m, n)$$

$$S(m, n) = \sqrt{\frac{1}{M * N - 1} \sum_{m=1}^M \sum_{n=1}^N |x(m, n) - \mu|^2}$$

其中, $1 \leq m \leq M, 1 \leq n \leq N$, m 和 n 分别表示图像块 x 的长和宽; M 和 N 表示图像块 x 的最大长度值和最大宽度值;

所述的积分通道特征包括8个方向的梯度直方图通道 Q_θ 、3个LUV颜色通道、梯度幅值GRAD和梯度方向 α ;其中,

$$GRAD(m, n) = \sqrt{[x(m+1, n) - x(m-1, n)]^2 + [x(m, n+1) - x(m, n-1)]^2};$$

$$\alpha(m, n) = \arctan\left(\frac{x(m, n+1) - x(m, n-1)}{x(m+1, n) - x(m-1, n)}\right);$$

$$Q_\theta(m, n) = GRAD(m, n) \times L[\Theta(m, n) = \theta];$$

L 表示指示函数, θ 表示梯度方向 $\alpha(m, n)$ 的量化范围, θ 的取值范围分别为:0-45度,45-90度,90-135度,135-180度,180-225度,225-270度,270-315度和315-360度;

所述3个LUV颜色通道通过将图像块 x 从RGB颜色空间转换至CIE LUV空间。

3. 根据权利要求2所述的方法,其特征在于:所述将图像块 x 从RGB颜色空间转换至CIE LUV空间的具体步骤为,根据公式(1)和(2)将图像块 x 从RGB颜色空间转换至CIE XYZ颜色空间,然后再转换到CIE LUV空间;

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \frac{1}{0.17697} \begin{bmatrix} 0.49 & 0.31 & 0.20 \\ 0.17697 & 0.81240 & 0.01063 \\ 0.00 & 0.01 & 0.99 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

$$L^* = \begin{cases} 116 \cdot \left(\frac{Y}{Y_n}\right)^3 - 16, \frac{Y}{Y_n} > \left(\frac{6}{29}\right)^3 \\ \left(\frac{29}{3}\right)^3 \frac{Y}{Y_n}, \frac{Y}{Y_n} \leq \left(\frac{6}{29}\right)^3 \end{cases}$$

$$U^* = 13L^* \cdot (U' - U_n') \quad (2)$$

$$V^* = 13L^* \cdot (V' - V_n')$$

其中,

$$U' = \frac{4X}{X+Y+3Z}, Y_n \text{表示参照白点的刺激值。}$$

$$V' = \frac{9Y}{X+Y+3Z}$$

4. 根据权利要求1所述的方法,其特征在于:所述步骤3的具体步骤为:

步骤3.1,根据决策森林算法,通过预测函数 $\psi(x|f_t):x \rightarrow \gamma$ 和多数投票算法预测含有裂缝的图像块 x 的预类别,预类别预测完成后,每个叶子上的图像块 x 为该叶子的一个分割模板;

其中,预测函数 $\psi(x|f_t):x \rightarrow \gamma$ 为:

$$\psi(x|N(h, f_t^L, f_t^R)) = \begin{cases} \psi(x|f_t^L), h(x, \theta_j) = 0 \\ \psi(x|f_t^R), h(x, \theta_j) = 1 \end{cases}$$

$$\psi(x|L(\pi)) = \pi$$

其中, f_t 表示决策树, $L(\pi)$ 表示叶子节点, $N(h, f_t^L, f_t^R) \in f_t$ 表示所有节点的集合, j 表示任一节点, $h(x, \theta_j) \in \{0, 1\}$ 表示节点的集合 $N(h, f_t^L, f_t^R) \in f_t$ 关联的二元分割函数;若 $h(x, \theta_j) = 0$,则 x 应该属于左子树 f_t^L ,否则属于右子树 f_t^R ; π 是最能代表该叶子类别的模板;

步骤3.2,通过最大化信息增益选择最优的图像特征 θ_j ,以使每个决策树的叶子的模板之间的差别最小,最优图像特征 θ_j 所在叶子的分割模板为图像块 x 的终类别;

步骤3.3,随机选择中转空间 Z 的256维的向量,根据公式(3)将结构空间 γ 映射到中转空间 Z 中,然后采用主元素分析法将中转空间的256维的向量降维至5维作为中转向量,最后,将每一个中转向量 $z \in Z$ 的主方向进行二聚类,同一个聚类器中的中转向量标记为相同的 $c \in C$,以使中转空间 Z 转换至标记空间 C 中;

$$\text{其中, } \Pi_\phi: \gamma \rightarrow Z \quad (3)$$

$$Z = \Pi(\gamma) \text{表示一个 } \binom{16 \cdot 16}{2} = 32640 \text{ 维的向量。}$$

5. 根据权利要求1或4所述的方法,其特征在于:所述步骤4的具体步骤为:

步骤4.1,选取阈值 δ 对结构空间 γ 中的模板组成的图像进行二值化,得到初始检测图像,其中, $0.1 \leq \delta \leq 0.2$;

步骤4.2,采用 4×4 矩形结构元素将初始检测图像进行腐蚀和膨胀操作。

6. 根据权利要求1或4所述的方法,其特征在于:所述步骤5的具体步骤为:

步骤5.1,将所述检测图像中不同类型的分割模板的数量进行统计,并生成统计直方

图；

步骤5.2,将所述检测图像中相邻的两个分割模板的数量进行统计,并生成邻域直方图；

步骤5.3,将所述统计直方图和邻域直方图归一化为[0,1],并拼接成为一个列向量；

步骤5.4,将所述列向量输入分类器进行学习。

7.根据权利要求1或4所述的方法,其特征在于:所述步骤6的具体步骤为:将所述路面的灰度图像输入到分类器中,将裂缝区域被指定为+1类,非裂缝区域指定为-1类,将非裂缝的图像块x均置为0,含有裂缝的图像块x均置为所述二值化图像块。

8.一种基于随机森林的路面裂缝检测方法的评价方法,其特征在于:包括以下步骤:

步骤一,将样本分为+1类和-1类,分别对应正样本和负样本;其中,如预测为正,实际为正,则结果为TP;如预测为正,实际为负,则结果为FP;如预测为负,实际为正,则结果为FN;如预测为负,实际为负,则结果为TN;所述样本为将灰度图像分割成的多个图像块x,根据以下公式计算精确率与召回率的调和平均值F1 Score:

$$\text{Pr}_{region} = \frac{TP}{TP + FP}$$

$$\text{Re}_{region} = \frac{TP}{TP + FN}$$

$$F1 = \frac{2 \times \text{Pr}_{region} \times \text{Re}_{region}}{\text{Pr}_{region} + \text{Re}_{region}}$$

其中,Pr_{region}表示精确率,Re_{region}表示召回率,F1_{region}表示F1 Score;

步骤二,根据以下公式得到裂缝连续性指标CI:

$$CI = \frac{1}{X} \sum_{i=1}^X \left(\frac{1}{Y_i} \sum_{j=1}^Y \frac{1}{n_{ij}} \right)$$

其中,X是测试集中图像的数量,Y_i表示第i张图像上路面实况裂缝的个数,n_{ij}表示第i张图像上第j个路面实况裂缝上的TP个数。

一种基于随机森林的路面裂缝检测方法及其评价方法

技术领域

[0001] 本发明属于数字图像处理和机器学习技术领域,具体涉及一种基于随机森林的路面裂缝检测方法及其评价方法。

背景技术

[0002] 裂缝是一种道路病害,会降低道路性能并威胁道路安全。政府部门已经尽最大能力来构建高质量的道路网络,他们现在已经充分认识到了道路检测和维护系统的重要性。裂缝检测是道路维护系统的一个重要组成部分,近几年已经引起了人们越来越多的注意。

[0003] 裂缝对于道路安全的威胁越来越大,也是智能运输系统亟待解决的问题。然而,路面裂缝自动检测作为智能运输系统的关键部分,面临着很大的挑战,原因在于裂缝的不规则性,裂缝拓扑结构的复杂性,噪声的参与,以及裂缝和路面纹理的相似性等等。

[0004] 众所周知,传统的人力道路裂缝检测方法是不仅耗时耗力和危险,而且主观判断有时存在偏差,1999年,H.Cheng,J._R.Chen,C.Glazier和Y.Hu在《J.Comput.Civil Eng.》杂志第13卷第4期的270-280页发表了《Novel approach to pavement cracking detection based on fuzzy set theory》文章,印证了这一观点。因此,传统的效率低下并且主观的道路检测方法逐渐被自动裂缝检测系统替代。随着图像处理技术的发展,道路裂缝检测和识别在过去的几十年里一直被讨论。早期的一些方法,比如2008年,Q.Li和X.Liu在《CISP》第2卷792-796页上发表的《Novel approach to pavement image segmentation based on neighboring difference histogram method》一文中,他们认为裂缝的像素比周围像素都要更黑,然后通过设置一个阈值来提取出裂缝。这种方法对噪声特别敏感,且对拍摄的图片有较高要求,比方说阳光必须十分充足,否则裂缝区域和其他区域的像素值相差不大。更重要的是,这种方法只考虑了单个像素值,没有考虑整体结构或者局部关系,使得方法的效果不理想。至于近来的一些方法,例如,2009年,T.S.Nguyen,M.Avila和S.Begot在《Eur.Signal Process》会议第617-621页中,发表的《Automatic detection and classification of defect on road pavement using anisotropy measure》;2011年,M.Gavilan等在《Sensor》第11卷第10期9628-9657页中发表的《Adaptive road crack detection system by pavement classification》。大多数的研究者尝试着通过特征联合来抑制噪声,例如将灰度值、均值或者标准差等一些特征联合起来。另外,一些研究人员从全局观的角度进行裂缝检测,提出了最小路径选择方法,例如,2014年,R.Amhaz,S.Chambon,J.Idier和V.Baltazart在《IEEE ICIP》会议第788-792页中,发表了《A new minimal path selection algorithm for automatic crack detection on pavement images》;最小生长树方法,例如,2012年,Q.Zou,Y.Cao,Q.Li,Q.Mao和S.Wang在《Pattern recogio.Lerr.》第33卷第3期第227-238页中,发表了《CrackTree:Automatic crack detection from pavement images》;裂缝基本元素法,例如,2012年,Y.-C.J,C.Jiang和Y.Huang在《Civil Eng.》第28卷第4期第388-396页中,发表了《Implementation of automatic crack evaluation using crack fundamental element》,这些方法可以消除

部分噪声并且加强裂缝的连续性。但是,这些方法对于复杂裂缝的处理,效果很不理想。一个可能的原因是使用的特征是基于灰度信息的,不能很好的表示一些特殊的裂缝。而且,这些现存的方法都忽略了局部结构信息。实际上,在一个子图像块上,裂缝的各个像素之间是高度依赖的,经常形成一些十分好识别的模式,例如水平裂缝、竖直裂缝和对角裂缝等等。因此,结构化的学习在近几年被用来解决类似问题。例如,2011年,P.Kontschieder, S.R.Bulo,H.Bischof和M.Pelillo在《IEEE ICCV》会议第2190-2197页上,发表的《Structured classlabels in random forests for semantic image labelling》中,研究者应用结构化的学习方法进行语义图像的标注。

发明内容

[0005] 为了解决现有技术中存在的上述问题,本发明提供了一种基于随机森林的路面裂缝检测方法及其评价方法。本发明要解决的技术问题通过以下技术方案实现:一种基于随机森林的路面裂缝检测方法,包括以下步骤:步骤1,采集路面的灰度图像,将灰度图像分割成多个图像块 x ,并生成图像块 x 对应的二值化分割模板 y ;

[0006] 步骤2,对图像块 x 提取图像特征 θ_j ,图像特征 θ_j 包括每个图像块 x 的均值特征 μ 、标准差特征 S ,以及积分通道特征;

[0007] 步骤3,将所述多个含有裂缝的图像块 x 输入决策森林中,每个树的左叶子对应分割模板 y 或生成的新分割模板 y' ;分割模板 y 和新分割模板 y' 构成了结构空间 γ ;

[0008] 步骤4,将所述图像块 x 进行二值化,并进行腐蚀和膨胀操作消除噪声,得到二值化图像块;

[0009] 步骤5,将所述结构空间 γ 中的分割模板 y 和新分割模板 y' 用裂缝描述子进行特征提取,然后通过分类器进行学习;

[0010] 步骤6,将所述路面的灰度图像输入到分类器中,将不含裂缝的图像块 x 均置为0,含有裂缝的图像块 x 均置为所述二值化图像块。

[0011] 进一步的,所述步骤2中的均值特征 μ 和标准差特征 S 分别根据以下公式得到:

$$\mu = \frac{1}{M * N} \sum_{m=1}^M \sum_{n=1}^N x(m, n)$$

$$S(m, n) = \sqrt{\frac{1}{M * N - 1} \sum_{m=1}^M \sum_{n=1}^N |x(m, n) - \mu|^2}$$

[0012] 其中, $1 \leq m \leq M$, $1 \leq n \leq N$, m 和 n 分别表示示图像块 x 的长和宽; M 和 N 表示图像块 x 的最大长度值和最大宽度值;

[0013] 所述的积分通道特征包括8个方向的梯度直方图通道 Q_θ 、3个LUV颜色通道、梯度幅值GRAD和梯度方向 α ;其中,

$$[0014] \quad GRAD(m, n) = \sqrt{[x(m+1, n) - x(m-1, n)]^2 + [x(m, n+1) - x(m, n-1)]^2};$$

$$[0015] \quad \alpha(m, n) = \arctan\left(\frac{x(m, n+1) - x(m, n-1)}{x(m+1, n) - x(m-1, n)}\right);$$

$$[0016] \quad Q_\theta(m, n) = GRAD(m, n) \times L[\Theta(m, n) = \theta];$$

[0017] L 表示指示函数, θ 表示梯度方向 $\alpha(m, n)$ 的量化范围, θ 的取值范围分别为:0-45度,

45-90度,90-135度,135-180度,180-225度,225-270度,270-315度和315-360度;

[0018] 所述3个LUV颜色通道通过将图像块x从RGB颜色空间转换至CIE LUV空间。

[0019] 进一步的,所述将图像块x从RGB颜色空间转换至CIE LUV空间的具体步骤为,根据公式(1)和(2)将图像块x从RGB颜色空间转换至CIE XYZ颜色空间,然后再转换到CIE LUV空间;

$$[0020] \quad \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \frac{1}{0.17697} \begin{bmatrix} 0.49 & 0.31 & 0.20 \\ 0.17697 & 0.81240 & 0.01063 \\ 0.00 & 0.01 & 0.99 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

$$[0021] \quad L^* = \begin{cases} 116 \cdot \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16, & \frac{Y}{Y_n} > \left(\frac{6}{29}\right)^3 \\ \left(\frac{29}{3}\right)^3 \frac{Y}{Y_n}, & \frac{Y}{Y_n} \leq \left(\frac{6}{29}\right)^3 \end{cases}$$

$$U^* = 13L^* \cdot (U' - U'_n) \quad (2)$$

$$V^* = 13L^* \cdot (V' - V'_n)$$

[0022] 其中,

$$[0023] \quad U' = \frac{4X}{X+Y+3Z}, \quad V' = \frac{9Y}{X+Y+3Z},$$

, Y_n 表示参照白点的刺激值。

[0024] 进一步的,所述步骤3的具体步骤为:

[0025] 步骤3.1,根据决策森林算法,通过预测函数 $\psi(x|f_t):x \rightarrow \gamma$ 和多数投票算法预测含有裂缝的图像块x的预类别,预类别预测完成后,每个叶子上的图像块x为该叶子的一个分割模板;

[0026] 其中,预测函数 $\psi(x|f_t):x \rightarrow \gamma$ 为:

$$[0027] \quad \psi(x|N(h, f_t^L, f_t^R)) = \begin{cases} \psi(x|f_t^L), h(x, \theta_j) = 0 \\ \psi(x|f_t^R), h(x, \theta_j) = 1 \end{cases}$$

$$[0028] \quad \psi(x|L(\pi)) = \pi$$

[0029] 其中, f_t 表示决策树, $L(\pi)$ 表示叶子节点, $N(h, f_t^L, f_t^R) \in f_t$ 表示所有节点的集合, j 表示任一节点, $h(x, \theta_j) \in \{0, 1\}$ 表示节点的集合 $N(h, f_t^L, f_t^R) \in f_t$ 关联的二元分割函数;若 $h(x, \theta_j) = 0$,则x应该属于左子树 f_t^L ,否则属于右子树 f_t^R ; π 是最能代表该叶子类别的模板;

[0030] 步骤3.2,通过最大化信息增益选择最优的图像特征 θ_j ,以使每个决策树的叶子的模板之间的差别最小,最优图像特征 θ_j 所在叶子的分割模板为图像块x的终类别;

[0031] 步骤3.3,:随机选择中转空间Z的256维的向量,根据公式(3)将结构空间 γ 映射到中转空间Z中,然后采用主元素分析法将中转空间的256维的向量降维至5维作为中转向量,最后,将每一个中转向量 $z \in Z$ 的主方向进行二聚类,同一个聚类器中的中转向量标记为相同的 $c \in C$,以使中转空间Z转换至标记空间C中;

$$[0032] \quad \text{其中, } \Pi_\phi: \gamma \rightarrow Z \quad (3)$$

[0033] $Z = \Pi(y)$ 表示一个 $\begin{pmatrix} 16 \cdot 16 \\ 2 \end{pmatrix} = 32640$ 维的向量。

[0034] 进一步的,所述步骤4的具体步骤为:

[0035] 步骤4.1,选取阈值 δ 对结构空间 γ 中的模板组成的图像进行二值化,得到初始检测图像,其中, $0.1 \leq \delta \leq 0.2$;

[0036] 步骤4.2,采用 4×4 矩形结构元素将初始检测图像进行腐蚀和膨胀操作。

[0037] 进一步的,所述步骤5的具体步骤为:

[0038] 步骤5.1,将所述检测图像中不同类型的分割模板的数量进行统计,并生成统计直方图;

[0039] 步骤5.2,将所述检测图像中相邻的两个分割模板的数量进行统计,并生成邻域直方图;

[0040] 步骤5.3,将所述统计直方图和邻域直方图归一化为 $[0, 1]$,并拼接成为一个列向量;

[0041] 步骤5.4,将所述列向量输入分类器进行学习。

[0042] 进一步的,将所述路面的灰度图像输入到分类器中,将裂缝区域被指定为+1类,非裂缝区域指定为-1类,将非裂缝的图像块 x 均置为0,含有裂缝的图像块 x 均置为所述二值化图像块。

[0043] 一种基于随机森林的路面裂缝检测方法的评价方法,其特征在于:包括以下步骤:

[0044] 步骤一,将样本分为+1类和-1类,分别对应正样本和负样本;其中,如预测为正,实际为正,则结果为TP;如预测为正,实际为负,则结果为FP;如预测为负,实际为正,则结果为FN;如预测为负,实际为负,则结果为TN;所述样本为将灰度图像分割成的多个图像块 x ,根据以下公式计算精确率与召回率的调和平均值F1Score:

$$[0045] \quad Pr_{region} = \frac{TP}{TP + FP}$$

$$[0046] \quad Re_{region} = \frac{TP}{TP + FN}$$

$$[0047] \quad F1 = \frac{2 \times Pr_{region} \times Re_{region}}{Pr_{region} + Re_{region}}$$

[0048] 其中, Pr_{region} 表示精确率, Re_{region} 表示召回率, $F1_{region}$ 表示F1Score;

[0049] 步骤二,根据以下公式得到裂缝连续性指标CI:

$$[0050] \quad CI = \frac{1}{X} \sum_{i=1}^X \left(\frac{1}{Y_i} \sum_{j=1}^Y \frac{1}{n_{ij}} \right)$$

[0051] 其中, X 是测试集中图像的数量, Y_i 表示第 i 张图像上路面实况裂缝的个数, n_{ij} 表示第 i 张图像上第 j 个路面实况裂缝上的TP个数。

[0052] 与现有技术相比,本发明的有益效果:(1)本发明通过引进积分通道特征来重新定义裂缝分割模板,裂缝分割模板包含了结构化的信息,从而进一步扩展了传统的裂缝检测特征集。

[0053] (2)本发明通过随机森林构建随机结构森林学习裂缝分割模板的结构信息,从而

得到裂缝检测的初步结果,不仅提高了裂缝检测的灵活性和通用性,易实现并行计算,还提高了计算速度。随机结构森林结合了不同尺度的互补特征来提取裂缝特征,并且充分利用了裂缝的结构化特性。

[0054] (3) 结构化的分割模板通过统计学处理,然后充当裂缝描述子,可以描述任意拓扑结构的裂缝,能够将噪声有效的进行区分。

[0055] (4) 本发明能够有效的检测路面结构复杂的裂缝,避免受到噪声的影响,裂缝检测准确度高。

[0056] (5) 本发明的评价方法针对图像块得到准确率和精确率,并得到连续性指标来评价连续的程度,从连续性判断路面的裂缝情况,进而发现路面存在的安全隐患。

附图说明

[0057] 图1是本发明流程示意图;

[0058] 图2(a)是原始灰度图像;

[0059] 图2(b)是二值化后的结果;

[0060] 图2(c)是经过腐蚀和膨胀处理后的结果;

[0061] 图2(d)是经过本发明方法处理后的最终结果;

[0062] 图3是收到滑出的裂缝轮廓和原始的图像块;

[0063] 图4(a)是叶子对应的最具代表性的分割模板;

[0064] 图4(b)是每个分割模板对应的手动分割模板;

[0065] 图5每个图像块分别对应的裂缝结构;

[0066] 图6(a)表示当阈值 $\delta=0.1$ 二值化的结果;

[0067] 图6(b)表示进行腐蚀和膨胀操作后的结果;

[0068] 图7(a)表示原始灰度图像;

[0069] 图7(b)表示检测结果;

[0070] 图7(c)是统计直方图;

[0071] 图7(d)是出现频率最高的前十个模板;

[0072] 图8(a)所有模板出现次数;

[0073] 图8(b)出现次数最多的708个模板;

[0074] 图9是本发明裂缝检测各个步骤中图像处理结果;

[0075] 图10是不同算法的图像检测结果。

具体实施方式

[0076] 下面结合具体实施例对本发明做进一步详细的描述,但本发明的实施方式不限于此。

[0077] 为了克服以上方法的缺陷,本发明提出一种基于随机结构森林的新的道路裂缝检测方法,被称作CrackForest。CrackForest结合了不同尺度的互补特征来提取裂缝特征,并且充分利用了裂缝的结构化特性。具体说来,本发明首次通过引进积分通道特征来重新定义裂缝分割模板,裂缝分割模板包含了结构化的信息,从而进一步扩展了传统的裂缝检测特征集。然后,利用随机结构森林来学习这种结构信息并预测裂缝分割模板,这些裂缝分

割模板形成了初始的裂缝检测结果。这些结构化的分割模板通过统计学处理,然后充当裂缝描述子,描述子由两个统计直方图组成,可以描述任意拓扑结构的裂缝。用这些裂缝描述子,可以用一种分类方法来把噪声区分出来。另外,我们也提出了一个量化的道路裂缝评价方法。大量的实验结果也表明了CrackForest方法对于裂缝检测有十分高的准确率。

[0078] 我们提出的CrackForest方法,可以很好的利用图像的结构信息。图1展示了CrackForest方法的执行过程。这个过程可以分为三个部分:1)、引进积分通道特征来扩展原始特征集,这些特征来自于多个层次和方向,这就允许我们来重新定义含有丰富结构信息的分割模板;2)、利用随机结构森林来学习这些特征的结构信息,因此初始的裂缝检测结果也可以得到;3)、我们提出了一个新的裂缝描述子,这个描述子可以表示任意形状的裂缝,因为我们的方法可以自主的产生数据集中没有的裂缝,最后使用分类器将裂缝和噪声有效地区分出来。附图展示了全部过程。图2(a)是原始图像,图2(b)是二值化后的结果,可以看出检测的结果含有很多噪声,图2(c)是经过腐蚀和膨胀处理后的结果,该操作的目的是使裂缝的连续性更强,图2(d)是经过CrackForest检测方法处理后的最终结果。

[0079] CrackForest执行过程为:给定数据集 $\{(x_1, y_1), (x_2, y_2), \dots, (x_1, y_1)\}$,其中 $x \in x$, $y \in \gamma$, x 表示原始采集的灰度图像分割后的图像块集, γ 表示手动画出的二值化分割模板集,首先,对 x 提取特征,然后用随机结构森林对 x 进行训练,训练结果:有一部分 x 越来越接近 γ ,另一部分 x 产生了新的模板 γ ,所有的模板共同组成模板结构空间,然后,对图像块进行二值化处理 and 膨胀腐蚀操作,二值化处理后的原图含有很多噪声且不连续,膨胀腐蚀操作是为了使裂缝尽可能连续,其次,对所有的结构化模板,也就是模板结构空间里的所有模板,用新的裂缝描述子进行描述,把这些描述特征都输入到分类器中进行学习,那么分类器学习到的全部为含有裂缝的模板的特征,最后,将原图输入到分类器中进行分类,识别出含有裂缝的图像块,那么,含有裂缝的图像块被置为该图像块对应的二值化的结果,不含裂缝的图像块被置为白色0。分类方法为最邻近算法、线性支持向量机或一类支持向量机,分类的结果为最终的裂缝检测结果,然后对这个结果进行评价。

[0080] 本发明的具体实施方法如下:

[0081] 如图1所示,本实施例提供一种基于随机森林的路面裂缝检测方法,包括以下步骤:步骤1,采集路面的灰度图像,将灰度图像分割成多个图像块 x ,并生成图像块 x 对应的二值化分割模板 y ;

[0082] 数据集是由路面的灰度图像集和对应的二值化分割模板组成的,路面的灰度图像集是通过拍摄得到的,二值化分割模板是用Photoshop工具手动画出裂缝的轮廓,再通过二值化处理得到的。在图3中,我们可以看到各个原始的图像块和手动画出的裂缝轮廓。首先,将路面的灰度图像集分割成 $16*16$ (像素)的图像块 $x \in x$,这些裂缝模板包含了各种各样的裂缝,不限于直线、曲线或者角等。

[0083] 步骤2,对图像块 x 提取图像特征 θ_j ,图像特征 θ_j 包括每个图像块 x 的均值特征 μ 、标准差特征 S ,以及积分通道特征;

[0084] 均值特征 μ 和标准差特征 S 分别根据以下公式得到:

[0085]
$$\mu = \frac{1}{M * N} \sum_{m=1}^M \sum_{n=1}^N x(m, n)$$

$$[0086] \quad S(m, n) = \sqrt{\frac{1}{M * N - 1} \sum_{m=1}^M \sum_{n=1}^N |x(m, n) - \mu|^2}$$

[0087] 其中, $1 \leq m \leq M, 1 \leq n \leq N$, m 和 n 分别表示图像块 x 的长和宽; M 和 N 表示图像块 x 的最大长度值和最大宽度值; 每个图像块 x 产生一个均值和一个 $16 * 16$ 的标准差矩阵。

[0088] 积分通道特征融合了颜色、梯度和梯度方向等信息。积分通道特征不仅比梯度方向直方图的效果好, 而且速度更快。积分通道特征选用13个通道: 包括8个方向的梯度直方图通道 Q_0 、3个LUV颜色通道、梯度幅值 $GRAD$ 和梯度方向 α ; 其中,

$$[0089] \quad GRAD(m, n) = \sqrt{[x(m+1, n) - x(m-1, n)]^2 + [x(m, n+1) - x(m, n-1)]^2};$$

$$[0090] \quad \alpha(m, n) = \arctan\left(\frac{x(m, n+1) - x(m, n-1)}{x(m+1, n) - x(m-1, n)}\right);$$

$$[0091] \quad Q_0(m, n) = GRAD(m, n) \times L[\Theta(m, n) = \theta];$$

[0092] L 表示指示函数, θ 表示梯度方向 $\alpha(m, n)$ 的量化范围, θ 的取值范围分别为: $0-45$ 度, $45-90$ 度, $90-135$ 度, $135-180$ 度, $180-225$ 度, $225-270$ 度, $270-315$ 度和 $315-360$ 度;

[0093] 梯度直方图是一个加权直方图, 它的bin索引通过梯度的方向来计算, 而它的权值则通过梯度的幅值计算。

[0094] 我们通常得到的图像是RGB颜色空间的图像, 需要先转化到CIE XYZ颜色空间, 最后再转换到CIE LUV空间。

[0095] 将图像块 x 从RGB颜色空间转换至CIE LUV空间的具体步骤为, 根据公式(1)和(2)将图像块 x 从RGB颜色空间转换至CIE XYZ颜色空间, 然后再转换到CIE LUV空间;

$$[0096] \quad \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \frac{1}{0.17697} \begin{bmatrix} 0.49 & 0.31 & 0.20 \\ 0.17697 & 0.81240 & 0.01063 \\ 0.00 & 0.01 & 0.99 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (1)$$

$$[0097] \quad L^* = \begin{cases} 116 \cdot \left(\frac{Y}{Y_n}\right)^{\frac{1}{3}} - 16, & \frac{Y}{Y_n} > \left(\frac{6}{29}\right)^3 \\ \left(\frac{29}{3}\right)^3 \frac{Y}{Y_n}, & \frac{Y}{Y_n} \leq \left(\frac{6}{29}\right)^3 \end{cases}$$

$$U^* = 13L^* \cdot (U' - U'_n) \quad (2)$$

$$V^* = 13L^* \cdot (V' - V'_n)$$

[0098] 其中,

$$U' = \frac{4X}{X+Y+3Z}$$

[0099] $V' = \frac{9Y}{X+Y+3Z}$, Y_n 表示参照白点的刺激值。

[0100] 步骤3, 将所述多个图像块 x 输入决策森林中, 每个树的左叶子对应分割模板 y 或生成的新分割模板 y ; 分割模板 y 和新分割模板 y 构成了结构空间 γ ;

[0101] 通过以上步骤, 包含结构信息的分割模板和描述模板的特征, 都已经得到了。然后, 将所有的含裂缝的图像块 x 输入到决策树中。

[0102] 在随机结构森林中,每一个决策树 $f_t(x)$ 通过不断的递归,最终到叶子结点,对每一个图像块 $x \in X$ 进行预测。叶子存储了每一个输入 x 的预测值,也就是目标标号 $y \in \gamma$,或者是新的 y 。通过训练,具有相同结构的模板就会聚集到同一个叶子上。我们使用每个叶子中最具代表性的模板来表示这类模板,模板的类别号等于叶子的标号。

[0103] 一个森林 T 是决策树 f_t 的集合。每个决策树 $f_t(x)$ 包含了每一个样本 $x \in X$ 的预测值。多个树的最终类预测是通过多数投票算法决定的。一个叶子节点 $L(\pi) \in f_t$ 可以预测样本的类别,其中 π 是最能代表该叶子类别的模板。每一个节点 $N(h, f_t^L, f_t^R) \in f_t$ 关联了一个二元分割函数 $h, h(x, \theta_j) \in \{0, 1\}$,其中 θ_j 是每个节点 j 的特征。如果 $h(x, \theta_j) = 0$,则 x 应该属于左子树 f_t^L ,否则属于右子树 f_t^R 。

[0104] 1) 类预测:给定一个决策树 $f_t \in T$ 和一个图像块 $x \in X$,通过不断的迭代递归,直到碰到叶子节点结束,我们可以预测到 $x \in X$ 的类别。对于节点 j ,有预测函数 $\psi(x | f_t) : X \rightarrow \gamma$,见下式(7),但是 x 的最终类别号是通过多数投票算法决定的。

$$[0105] \quad \psi(x | N(h, f_t^L, f_t^R)) = \begin{cases} \psi(x | f_t^L), h(x, \theta_j) = 0 \\ \psi(x | f_t^R), h(x, \theta_j) = 1 \end{cases} \quad (7)$$

$$\psi(x | L(\pi)) = \pi$$

[0106] 2) 随机训练:每一棵树是单独训练的。对于一个给定节点 N_j 和一个训练集 $S_j \subset X \times \gamma$,我们的目标是发现一个最优的特征 θ_j ,这个特征可以把数据集很好的区分出来。换句话说,属于同一个叶子节点的模板之间的差值应该越小越好。我们利用信息增益来衡量这个误差,并且通过最大化信息增益来选择 θ_j 。节点 j 的信息增益定义为下式:

$$[0107] \quad I_j = I(S_j, S_j^L, S_j^R) \quad (8)$$

[0108] 其中, $S_j = S_j^L \cup S_j^R$, $S_j^L = \{(x, y) \in S_j | h(x, \theta_j) = 0\}$ 代表到达了当前节点左子树的样本, $S_j^R = \{(x, y) \in S_j | h(x, \theta_j) = 1\}$ 代表到达了当前节点右子树的其他样本。

[0109] 当前节点应不应该继续分割下去,取决于最大深度值、最小节点数或者类分布的熵值。如果一个节点不再分离或者这棵树不再生长时,叶子节点就生成了。否则,节点 $N(h, f_t^L, f_t^R)$ 继续根据 θ_j 确定的分离函数 h 进行生长, θ_j 使信息增益最大化。

[0110] 对于多分类问题 $\gamma \subset Z$,信息增益的定义如下(见式(9)),

[0111] $H(S_j) = -\sum_y p_y \log(p_y)$ 定义了香农熵, p_y 代表标记为 y 的样本占数据集 S 的比重。换句话说,基尼不纯度 $H(S_j) = \sum_y p_y (1-p_y)$ 也可以应用在此式(9)中。

$$[0112] \quad I_j = H(S_j) - \sum_{k \in \{L, R\}} \frac{|S_j^k|}{|S_j|} H(S_j^k) \quad (9)$$

$$H(S_j^k) = -\sum_y p_y \log(p_y)$$

[0113] 单个决策树更容易倾向过拟合,这会严重影响分类准确率。为了克服这个缺陷,随机结构森林联合多个决策树共同指定最终的类别号。随机结构森林具有很强的灵活性和通用性,最重要的是,这个方法很容易实现并行计算,且计算速度很快。

[0114] 随机性是指随机地从数据集中抽取样本来训练每个树 f 和节点 N ,并且随机地选取 θ_j 的部分特征来分离各个节点。为了保持决策树的多样性,当选择分割函数 h 时,我们采集

的特征只有一少部分被用来选择最优 θ_j 。

[0115] 3) 结构映射: 随机结构森林将传统决策森林的离散空间转换为了一个结构空间 γ 。将这个结构空间 γ 直接离散化时, 也就是说给这个空间的每个结构 $y \in \gamma$ 做标记 $c \in C, c = \{1, 2, \dots, k\}$, 计算代价是很大的。给定离散标记空间 C , 信息增益可以由式(9)计算得到。我们首先将结构空间 γ 映射到中转空间 Z 。

$$[0116] \quad \Pi: \gamma \rightarrow Z \quad (10)$$

[0117] 定义 $z = \Pi(y)$ 是一个 $\binom{16 \cdot 16}{2} = 32640$ 维的向量, 这个向量重新编码了分割模板 y 的每一对像素。这样一来, z 的计算代价是十分昂贵的, 因为 z 的维数太高了。为解决次问题, 我们随机选择 z 的256维来训练分割函数 h , 这样空间转换公式就变换为式(11):

$$[0118] \quad \Pi_\phi: \gamma \rightarrow Z \quad (11)$$

[0119] 然后, 我们使用主成分分析法进行降维, 使 z 从原来的256维降到5维, 其中, z 的第一维是最重要的因素, 称为主方向。为了使结构空间 $y \in \gamma$ 能够转换到标记空间 $c \in C$, 我们利用中转空间 Z 的每个中转向量 $z \in Z$ 的主方向进行二聚类。同一个聚类器中的中转向量, 被指定为同样的标记 $c \in C$, 这样就完成了从中转空间到标记空间的转换。

[0120] 表示所有节点的集合, j 表示任一节点, $h(x, \theta_j) \in \{0, 1\}$ 表示节点的集合 $N(h, f_t^L, f_t^R) \in f_t$ 关联的二元分割函数; 若 $h(x, \theta_j) = 0$, 则 x 应该属于左子树 f_t^L , 否则属于右子树 f_t^R ; π 是最能代表该叶子类别的模板。

[0121] 当随机结构森林训练过后, 所有的叶子都对应了一个结构 $y \in \gamma$, 训练学习到的分割模板详见附件, 图4(a)是叶子对应的最具代表性的分割模板, 图4(b)是每个分割模板对应的手动分割模板。每棵树都是

[0122] 步骤4, 将所述图像块 x 进行二值化, 并进行腐蚀和膨胀操作消除噪声, 得到二值化图像块;

[0123] 步骤4.1, 选取阈值 δ 对结构空间 γ 中的模板组成的图像进行二值化, 得到初始检测图像, 其中, $0.1 \leq \delta \leq 0.2$;

[0124] 步骤4.2, 采用 4×4 矩形结构元素将初始检测图像进行腐蚀和膨胀操作。

[0125] 具体的, 经过结构映射后, 每个图像块 $x \in x$ 都被指定了一个结构标记 $y \in \gamma$ 。由于重叠的原因, 裂缝检测的结果是一个地图, 在这个地图中, 每个元素对应了裂缝区域的一个可能的位置。接下来, 我们设定一个阈值 δ 来获得所有可能的区域, 如果阈值过高, 可能导致裂缝不连续, 并且忽略一些细小的裂缝。因此, 我们限定 $0.1 \leq \delta \leq 0.2$ 。图6(a)表示当阈值 $\delta = 0.1$ 二值化的结果。这样, 我们就得到了初始结果。

[0126] 我们应用腐蚀和膨胀操作使初始结果的连续性更好, 裂缝内部的一些空隙被填充了, 裂缝的碎片也被连接起来了。更重要的是, 一些噪声被消除了。在图6(b)中, 我们使用 4×4 矩形结构元素进行腐蚀和膨胀操作, 由结果可以看出, 检测区域的小片段被融合在一起了, 并且裂缝的连续性得到了改善。

[0127] 步骤5, 将所述结构空间 γ 中的分割模板 y 和新分割模板 y' 用裂缝描述子进行特征提取, 然后通过分类器进行学习;

[0128] 经过结构学习之后, 每个图像块都对应了一个裂缝结构 $y \in \gamma$ 。尽管我们获得了初始裂缝检测结果, 但是大量的噪声仍然存在, 原因在于非裂缝区域的结构性也是十分强的,

且非裂缝区域和裂缝区域的纹理相差不大。传统的阈值处理方法去除噪声的时候,很可能将不太明显的裂缝错误地去除。

[0129] 设想一下,裂缝存在一系列区别于噪声的独特的结构特征。基于此设想,我们创造了一个基于统计特性的裂缝描述子。裂缝描述子由两个统计直方图组成,可以描述任意形态的裂缝。然后应用支持向量机分类器,可以将裂缝和噪声有效地区分出来。

[0130] 1) 裂缝描述子:现存的裂缝描述方法将裂缝分成了几种类型,例如水平的,竖直的,对角的,碎片的和网状的。然而,这些裂缝描述方法通常需要很高的维数,这就给计算带来很大负担。更重要的是,这几种类型无法全部描述裂缝,很多裂缝不属于这些类型,所以,我们将裂缝类型扩展到上千种。在结构学习过程中,我们使用了26443个裂缝分割模板来描述裂缝,这些裂缝模板的统计直方图和邻域直方图可以被精确地计算出来,充当裂缝描述子。

[0131] 统计直方图:结构学习之后,我们得到了结构映射。也就是说,一副图像的每个图像块都对应了一个裂缝模板,或者说结构类型。把所有的这些裂缝模板,按照图像块在图像中的位置,组成模板地图。然后,将不同类型的模板的个数统计出来,详细结果见附图。图7(a)表示原始图像,图7(b)表示检测结果,图7(c)是统计直方图,图7(d)是出现频率最高的前十个模板。

[0132] 模板的数量是很多的,所有模板出现的次数被统计见图8(a),由图8(a)可以看出,模板分布具有长尾效应,我们发现90%的模板出现的次数可以忽略不计,只有708个模板出现的次数比较多。我们就可以只使用这708个模板来构建统计直方图,所有图像只需要统计这708个模板的个数即可。图8(b)展示了这些模板出现的次数。

[0133] 邻域直方图:邻域直方图获取两个模板的邻域信息。我们已经得到了模板地图,如果两个模板是相邻的,那么我们就统计这两个模板中708个模板出现的次数。这样,如果没有降维的话,将会有

$\binom{708}{2} = 250278$ 对模板。更进一步研究后,我们发现这些模板对也有长

尾效应,超过90%的模板对提供了很少的信息,可以忽略不计,只有956个模板对可以提供重要信息。因此,只有这些模板对会在接下来的步骤中使用。

[0134] 2) 裂缝检测:在这一部分,我们会介绍怎样用裂缝描述子将裂缝和噪声区分出来。

[0135] 向量化:将所有的直方图归一化为 $[0, 1]$,统计直方图的有效维数为708维,邻域直方图的有效维数为956维,将这两个直方图简单拼接成一个列向量,这个列向量有 $708+956=1664$ 维。将列向量输入分类器进行学习。

[0136] 步骤6,将所述路面的灰度图像输入到分类器中,将不含裂缝的图像块 x 均置为0,含有裂缝的图像块 x 均置为所述二值化图像块。

[0137] 具体步骤为:将所述路面的灰度图像输入到分类器中,将裂缝区域被指定为+1类,非裂缝区域指定为-1类,将非裂缝的图像块 x 均置为0,含有裂缝的图像块 x 均置为所述二值化图像块。

[0138] 本实施例还提供一种基于随机森林的路面裂缝检测方法的评价方法,包括以下步骤:

[0139] 步骤一,将样本分为+1类和-1类,分别对应正样本和负样本;其中,如预测为正,实际为正,则结果为TP;如预测为正,实际为负,则结果为FP;如预测为负,实际为正,则结果为

FN;如预测为负,实际为负,则结果为TN;所述样本为将灰度图像分割成的多个图像块 x ,根据以下公式计算精确率与召回率的调和平均值F1Score:

$$[0140] \quad Pr_{region} = \frac{TP}{TP + FP}$$

$$[0141] \quad Re_{region} = \frac{TP}{TP + FN}$$

$$[0142] \quad F1 = \frac{2 \times Pr_{region} \times Re_{region}}{Pr_{region} + Re_{region}}$$

[0143] 其中, Pr_{region} 表示精确率, Re_{region} 表示召回率, $F1_{region}$ 表示F1Score;

[0144] 步骤二,根据以下公式得到裂缝连续性指标CI:

$$[0145] \quad CI = \frac{1}{X} \sum_{i=1}^X \left(\frac{1}{Y_i} \sum_{j=1}^Y \frac{1}{n_{ij}} \right)$$

[0146] 其中, X 是测试集中图像的数量, Y_i 表示第 i 张图像上路面实况裂缝的个数, n_{ij} 表示第 i 张图像上第 j 个路面实况裂缝上的TP个数。

[0147] 具体的,首先,我们需要下载Piotr的计算机视觉和结构边缘检测的Matlab工具包,实验所用电脑的CPU是Intel (R) Core (TM) i7-6700k@4.00GHz 4.00GHz,系统的内存(RAM)是16GB。其次,为了评价我们的方法,我们将本发明的方法和传统的Canny边缘检测算法,还有先进的路面检测方法(CrackTree, CrackIT, FFA和MPS)进行了比较。最后,不同于其他的边缘检测任务,裂缝检测效果的评价是十分困难的,鉴于此,我们应用了两个裂缝检测评价方法。

[0148] 我们使用精确率(Precision)、召回率或者查全率(Recall)和F1Score来评价裂缝检测的准确率,区别于原机器学习评价方法,这里的评价方法针对的是一个图像块,不是单个像素。由于裂缝检测实际上为一个分类问题,我们将样本分为两类:+1类和-1类,分别对应正样本和负样本。如果预测为正,实际也为正,我们称为TP(true positive);如果预测为正,实际为负,我们称为FP(false positive);如果预测为负,实际为正,我们称为FN(false negative);如果预测为负,实际也为负,我们称为TN(true negative)。每一个样本只可能属于这四种情况中的某一种,不会有其他的可能。精确率和召回率的定义如下,其中 Pr_{region} 表示精确率, Re_{region} 表示召回率, $F1_{region}$ 表示F1 Score:

$$[0149] \quad Pr_{region} = \frac{TP}{TP + FP}$$

$$[0150] \quad Re_{region} = \frac{TP}{TP + FN}$$

$$[0151] \quad F1 = \frac{2 \times Pr_{region} \times Re_{region}}{Pr_{region} + Re_{region}}$$

[0152] 裂缝连续性也是裂缝评价很重要的一部分,我们定义连续性指标来评价连续的程度。它估算在同一个裂缝上有多少个被检测区域是连接在一起的。假设 M 是测试集中图像的数量, N_i 表示第 i 张图像上路面实况裂缝的个数, n_{ij} 表示第 i 张图像上第 j 个路面实况裂缝上的TP个数。连续性指标越接近1,表示连续性越好。连续性指标CI的定义如下:

$$[0153] \quad CI = \frac{1}{X} \sum_{i=1}^X \left(\frac{1}{Y_i} \sum_{j=1}^Y \frac{1}{n_{ij}} \right)$$

[0154] 其中,X是测试集中图像的数量, Y_i 表示第*i*张图像上路面实况裂缝的个数, n_{ij} 表示第*i*张图像上第*j*个路面实况裂缝上的TP个数。

[0155] 数据集中包含118张图片,采集了陕西师范大学长安校区校园内的路面图片,每个图像有对应的手动裂缝模板。图片的宽度在1毫米到3毫米之间。从图9中可以看出,图像的噪声包括阴影、油渍和水渍。

[0156] 我们将60%的图像作为训练集,剩下的作为测试集,并且图像的分辨率全部是480*320像素,样本的检测结果见图9,第一列是原始图像;第二列是手动画出的路面实况裂缝模板;第三列是随机结构森林处理过后的初始裂缝检测结果,比较黑的颜色代表着裂缝可能存在的区域;第四列是经过二值化处理后得到的结果,二值化将那些可能性比较小的像素去除了;第五列是最终的检测结果,利用裂缝描述子将检测区域转换为一个向量,然后使用支持向量机分类器进行分类,得到结果,结果表明,我们的方法对噪声是鲁棒的。

[0157] 为了突出我们提出的方法的优越性,另外四种裂缝检测方法也对该数据集进行了实验并进行了评价:Canny, CrackIT, CrackTree和FFA,实验结果详见图10,裂缝评价的结果见表1。图10的第一行是原始图像,第二行是手动画出的分割模板,第三行是Canny处理结果,第四行是CrackIT处理结果,第五行是CrackTree处理结果,第六行是FFA处理结果,最后一行是CrackForest处理结果。显然,我们提出的方法要比其他方法的检测效果好。

[0158] 由图10可以看出,传统的Canny边缘检测方法不适用于路面裂缝的检测,因为它对边缘太敏感了。Crack IT对于低分辨率和低对比度的图像,处理效果不理想,由结果可以看出,大多数裂缝它都没有检测到。CrackTree的处理效果还可以接受,但是裂缝的宽度不能被检测到。至于FFA算法,处理结果很糟糕,裂缝区域和非裂缝区域不能很好地区分出来。

[0159] 由表1也可以看出,CrackForest方法比其他方法的效果要好,评价的系数越接近1越好,CrackForest的精确率、召回率和连续性指数都比较大,实验效果很理想。

方法	Pr_{pixel}	Re_{pixel}	$F1_{\text{pixel}}$	CI
Canny	12.23%	22.15%	15.76%	0.004
CrackTree	73.23%	76.45%	70.80%	0.22
[0160] CrackIT	67.23%	76.69%	71.64%	0.32
FFA	78.56%	68.43%	73.15%	0.58
CrackForest(KNN)	80.77%	78.15%	79.44%	0.62
CrackForest(SVM)	82.28%	89.44%	85.71%	0.67
CrackForest(一类 SVM)	81.25%	86.45%	83.77%	0.65

[0161] 表1不同方法的评价结果

[0162] 以上内容是结合具体的优选实施方式对本发明所作的进一步详细说明,不能认定本发明的具体实施只局限于这些说明。对于本发明所属技术领域的普通技术人员来说,在不脱离本发明构思的前提下,还可以做出若干简单推演或替换,都应当视为属于本发明的保护范围。

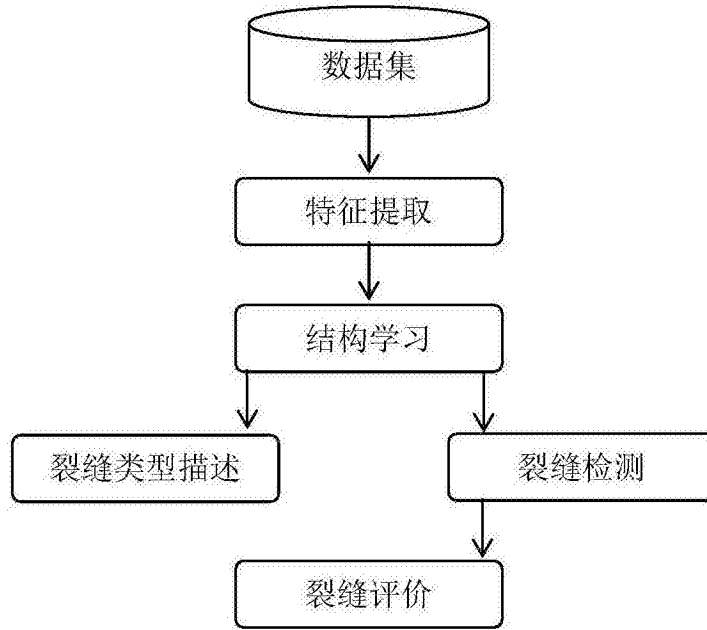


图1




图2 (a)




图2 (b)



图2(c)




图2(d)




图3




图4 (a)




图4 (b)




图5




图6 (a)




图6 (b)




图7 (a)



图7 (b)




图7 (c)




图7 (d)




图8 (a)




图8 (b)




图9




图10