

DOI:10.14048/j.issn.1671-2579.2021.03.011

基于 SFO—DPC 算法的三维沥青路面裂缝检测

王敬飞^{1,2}, 邓然然³, 陈志毅^{1,2}, 李伟³

(1. 广东华路交通科技有限公司, 广东 广州 510080; 2. 广东交科检测有限公司; 3. 长安大学)

摘要:复杂的路面纹理和噪声的影响导致现有路面裂缝检测方法有效性较低。为了提高路面裂缝检测精度,该文提出一种基于自调节步长果蝇优化密度峰值聚类(SFO—DPC)算法的三维沥青路面裂缝检测系统。首先,利用 Gocator3100 系列双目智能传感器构建三维图像采集系统来采集沥青路面的三维数据;然后,采用自调节步长果蝇优化密度峰值聚类算法对沥青路面的三维数据进行聚类分析,达到裂缝识别的目的;最后,将聚类分析的结果映射至二维图像中,更直观地验证裂缝检测结果。通过比较发现,该算法能够实现有效的沥青路面裂缝检测,并且相较于其他基于聚类的三维检测方法,检测效果更加高效准确。

关键词:养护与管理;裂缝检测;聚类;自调节步长果蝇优化密度峰值聚类算法;三维检测

1 引言

道路交通在世界上所有国家的经济建设中起着重要作用,例如经济结构和不断发展的城市网络都是由道路交通支撑的。裂缝的识别对于道路的日常维护十分关键。至今为止,裂缝检测技术变得越来越成熟,为路面维护提供了很多技术支持。然而,现有的裂缝检测技术仍不能满足实际应用中的准确性和效率的需求。

传统的人工检测会影响交通,效率低,主观性强且准确性低,并且长期无法满足不断增长的维护需求。随着信息科技的进步,出现了许多利用数字图像原理的路面裂缝识别方法,例如边缘检测算法极大地提高了识别效率和准确性。但是,这种检测算法对噪声较为敏感。此外,还有一些利用形态学的识别方法,利用阈值分割的识别方法以及利用聚类图像分割的识别方法等。这些算法为提高裂缝检测精度提供了重要参考。二维的方法受光影、标志信息和油渍的影响。现有的二维裂缝识别算法难以解决此类缺陷。因此,诸多学者及研究人员加强了对三维路面裂缝检测的研究。近年来,基于结构光学的三维识别方法成为了研究的热点。通过使用摄像机捕获路面轮廓并通过三维重建进行成像,可以更好地解决二维图像受环境影响

的缺点。然后出现了基于二维分解的三维识别方法等三维方法。深度学习算法也被应用于裂缝的识别。但是,这种算法高度依赖特征选择和训练样本的丰富性,因此对于与训练样本有很大差异的裂缝图像的处理效果并不理想,并且计算成本很高。

综上所述,尽管三维图像可以更好地避免环境干扰,但是由于裂缝对比度低,背景不均匀,裂缝形态多样以及路面纹理复杂等因素的影响,裂缝的准确检测仍然面临巨大的挑战。随着三维识别方法的提出与进步,三维识别方法的研究已成为目前的主要方向。Amhaz 等设计了利用聚类方法的三维裂缝检测方法。聚类属于机器学习领域中的主要分支无监督方法。快速搜索和发现密度峰值聚类算法(DPC)是 2014 年发表的新算法,可以实现非球形数据的有效处理。通过此算法选择聚类中心:① 局部密度较高,即中心点的相邻点的密度值均小于该点;② 与密度较高的其他点的“距离”较大。DPC 算法原理简单,聚类效率高,已广泛应用于高速公路收费数据分析,异常事件挖掘等领域。但是,DPC 算法的缺点也非常明显,截止距离应根据经验值设置,需要根据计算出的局部密度和距离值生成决策图以选择聚类中心。通过人工选择具有较大参数值的样本为中心样本。这种选择具有较高的主观性和不稳定性,严重影响了非中心点的后续分布和

收稿日期:2020-09-03

基金项目:广东省交通运输厅科技项目(编号:201502011);国家重点研发计划专项(编号:2018YFB1600200);国家自然科学基金资助项目(编号:51978071);长安大学中央高校基本科研业务费专项资金资助项目(编号:300102249301,300102249306)

作者简介:王敬飞,男,硕士,高级工程师。E-mail:15112113911@139.com

优化以及噪声点的发现。为了解决这两个缺点,该文采用自调节步长的果蝇优化算法(SFO)对快速搜索与发现峰值聚类算法(DPC)的参数进行优化,设计了自调节步长果蝇优化密度峰值聚类算法(SFO-DPC)。然后,使用 SFO-DPC 算法对三维沥青路面数据进行聚类,准确识别裂缝并获取裂缝参数,为路面病害评估提供支持。

该文采用三维数据采集设备 Gocator3100 进行数据的采集,可以实现三维智能传感器的三维数据采集和三维数据测量,采用双目相机扫描技术获得高精度的三维测量数据,并且仍能在复杂的照明条件下提供高可靠性和高重复性数据,同时由于外观紧凑,体积小,重量轻,非常易于安装在狭小的空间,因此非常适用于各种固定目标非接触式在线检测应用。

2 沥青路面三维数据采集与预处理

2.1 沥青路面三维裂缝检测系统

该文提出的基于 SFO-DPC 算法的沥青路面裂缝识别方法主要由 3 个部分组成。包括沥青路面三维数据采集、基于 SFO-DPC 算法的路面三维数据聚类以及路面裂缝特征提取。

2.2 沥青路面三维数据采集

目前现存的二维裂缝识别方法的局限性大大增加了对三维方法的需求。Gocator3100 系列双目三维智能扫描仪是一种结合了三维点云数据采集和测量工具的工业检测设备,如图 1 所示。

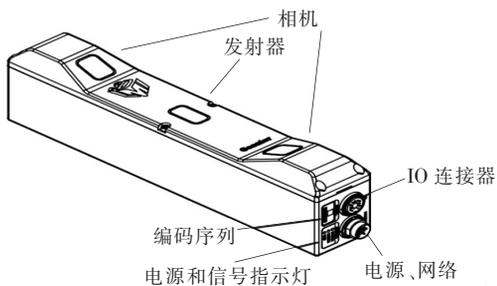


图 1 Gocator3100 双目智能传感器结构图

图 2 为沥青路面数据采集工作现场及数据采集装置俯视图。Gocator3100 相机被安装于特制支架上。采集到的裂缝三维数据,如图 3 所示。同时拍摄了如图 4 所示的三维数据对应的二维图像,便于记录沥青路面的光照及湿度等信息。

2.3 沥青路面三维数据预处理

试验中使用的样本数据主要为三维重建形成的样



图 2 数据采集图

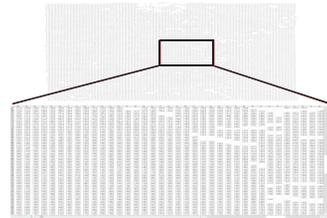


图 3 三维数据截图



图 4 二维图像

本。除了捕捉裂缝的轮廓,三维数据还包括不同高度的沥青路面、纹理、车辙、路标、坑洼或碎石。

表 1 为由双目相机收集的三维路面数据的局部信息。表中的首行及首列信息是路面的水平及垂直坐标。表中为路面高度值,尽管采集设备尽量避免误差,但由于路面磨损反光等因素,其中仍存在一些缺失值。

该研究中使用 Lagrange 插值法对空缺的信息进行填充。为了考虑目标识别的速度和精度,使用中值滤波方法对原始数据加以处理。滤波的目的是平滑数据,消除路面构造深度对裂缝检测的影响。三维数据截面的预处理结果如图 5 所示。

3 基于 SFO-DPC 的三维沥青路面裂缝检测

3.1 沥青路面裂缝检测系统

研究中,采用聚类的方法实现裂缝的检测。对采集的三维裂缝数据中的沥青路面高度值进行参数计算、聚类中心选择、非中心点分配、聚类结果优化和噪声点识别。然后,将数据点识别为普通路面或路面裂

表 1 部分沥青路面三维数据示例

y/mm	不同 x 坐标(mm)下的路面高度值/mm					
	13.5	14	14.5	15	15.5	16
-10	-1.363 78	-0.943 78	-0.379 78		0.208 22	0.448 22
-9.5	-1.483 78	-1.459 78	-1.261 78			
-9	-1.351 78	-1.261 78	-1.249 78	-1.393 78	-2.083 78	-2.773 78
-8.5	-1.225 78	-1.603 78	-1.489 78	-1.597 78	-2.275 78	-2.971 78
-8		-2.263 78	-2.125 78	-2.179 78	-2.539 78	-3.001 78
-7.5		-2.047 78	-2.683 78	-2.689 78	-2.875 78	-3.049 78

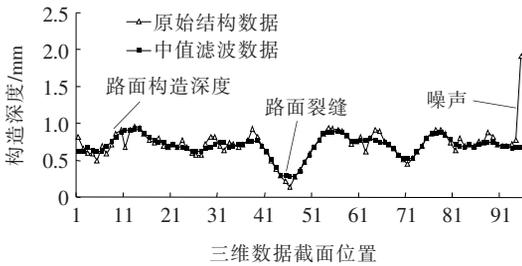


图 5 三维裂缝数据截面预处理实例

缝。三维路面样本聚类结果以二维形式表示。基于聚类的识别系统流程如图 6 所示。

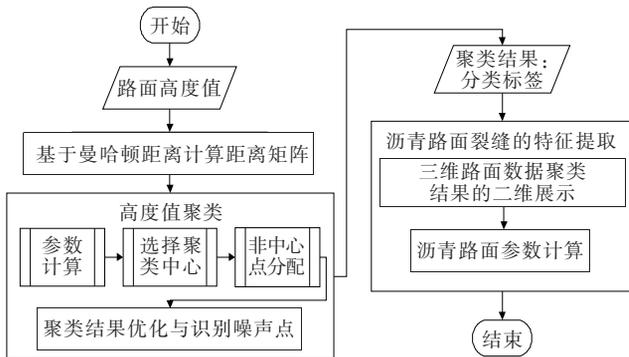


图 6 基于聚类算法的裂缝识别流程图

3.2 基于自调节步长果蝇优化的密度峰值聚类

3.2.1 密度峰值聚类算法(DPC)

DPC 算法主要分 3 个步骤进行:计算距离矩阵、选取中心样本、非中心样本分配及算法结果优化。

密度峰值算法的输入为待处理数据样本的距离矩阵。在进行距离计算之前,将原始数据的不同字段进行标准化处理,使各维度的数据具有相同的量级;计算数据间的相似性;输出矩阵,此矩阵即为快速峰值算法的输入。

聚类中心的特征是密度值较大而且到其他密度更大的样本相距很远。某样本的局部密度 ρ_i 是其截止距离范围内样本的数目:

$$\rho_i = \sum_j \chi(d_{ij} - d_c) \quad (1)$$

式中: i 与 j 为两个互异的数据点,其中当 α 小于 0 时, $\chi(\alpha) = 1$,反之 $\chi(\alpha) = 0$; d_{ij} 为 i 点与 j 点之间的距离; d_c 为截止距离,由用户根据经验值设定。

某一数据的 δ_i 值被定义为:

$$\delta_i = \min_{j: \rho_j > \rho_i} (d_{ij}) \quad (2)$$

对于密度最高的点,由于不存在更高点,故将其 δ_i 值定义为该点与其余所有数据之间距离的最大值。

$$\delta_i = \max_j (d_{ij}) \quad (3)$$

计算出各点的这两个量之后,将所有数据点以 ρ 和 δ 作为两个维度进行可视化输出,所输出的图形称为决策图。从中将 ρ 和 δ 都较大的样本设置为中心样本。找到中心样本后,同时得到了类别的数量,然后合理分配非中心样本。每个剩余点逐个被分到与其距离最近的有较高密度的点所在的类簇,且此操作以单步执行,直到把所有的点全部分配到对应的类为止。

3.2.2 自调节步长果蝇优化算法(SFO)

果蝇优化算法(FOA)仿照果蝇个体觅食的过程,首先根据嗅觉寻找食物气味,然后根据视觉精确觅食,渐渐接近食物。

初始化种群:果蝇数量为 $Sizenum$,执行次数为 $Maxtimes$ 。群体初始坐标($Start_X, Start_Y$)。果蝇个体按照任意方向与距离移动:

$$X_i = Start_X + RandomValue \quad (4)$$

$$Y_i = Start_Y + RandomValue \quad (5)$$

计算每个个体与原点的距离 D_i 以及判定参数 S_i :

$$D_i = (X_i^2 + Y_i^2)^{0.5} \quad (6)$$

$$S_i = 1/D_i \quad (7)$$

将判定参数 S_i 代入函数 $Function(S_i)$ 求出其 $Smell_i$:

$$Smell_i = Function(S_i) \quad (8)$$

找出味道最优的个体(该文以最小值为最优解):

$$[best_Smell_best_index] = \min(Smell) \quad (9)$$

重复上述步骤,判断: $Smell_best_i < Smell_best_{i-1}$, 如果上式取值为真则执行后续步骤,反之重复之前的步骤。记录最优气味 $Smell_best$ 及对应位置信息,再逐步接近最优解:

$$Smell_best_i = best_smell \quad (10)$$

$$Start_X = X(best_Smell) \quad (11)$$

$$Start_Y = Y(best_Smell) \quad (12)$$

FOA 算法每一代果蝇以固定步长随机寻找食物。如果步长不变,则步长的选择就对寻优的效果与效率有较大的影响。难以平衡全局搜索和局部搜索,自调节步长果蝇优化算法根据浓度差值变化率的大小判断迭代处于前期阶段还是后期阶段,对步长进行动态更改(图 7);并且在改变步长过程中引入指数与三角函数机制,使步长变化具有非均匀性和随机性。

求出浓度差值变化率:

$$SRate = \frac{\min(Smell_i) - \max(Smell_i)}{\min(Smell_{i-1}) - \max(Smell_{i-1})} \quad (13)$$

由图 7 可知:寻优前期的浓度差值变化率波动较大,需要适当加大步长提高寻优速度,而寻优后期浓度差值变化率波动变小,逐渐稳定在 1 附近的 0.7~1.3 内,说明群体已经接近目标,此时应当减小步长,以提升精确度。

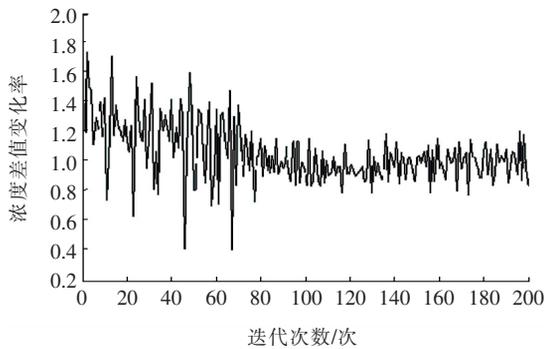


图 7 浓度差值变化率

根据 $SRate$ 的取值范围,对步长进行相应的修改:

如果 $SRate \leq 0.7$ 或者 $SRate \geq 1.3$:

$$L_i = L_{i-1} - \left(1 - \frac{times_i}{Maxtimes}\right) \times Dynamic_factor \times 0.7 \quad (14)$$

如果 $0.7 < SRate < 1.3$:

$$L_i = L_{i-1} - \left(1 - \frac{times_i}{Maxtimes}\right) \times Dynamic_factor$$

$$\times 1.3 \quad (15)$$

步长调节因子:

$$Dynamic_factor = \exp(m \times SRate) \times \sin[rem(times_i, \pi)] \quad (16)$$

式中: L_i 与 L_{i-1} 分别为当前果蝇寻优迭代步长和上一次果蝇寻优迭代步长; m 为在不同所属浓度差值变化率时所采用的步长动态变化参数; $times_i$ 为当前执行算法所处的运行次数;根据每次求的浓度差值变化率 $SRate$, 确定其所属范围,对步长进行相应的修改。

图 8 为步长调节因子在取值连续的情况下所显示的结果。指数机制可以使步长变化具有非均匀性,在果蝇寻优迭代过程中,如果浓度变化较大,那么要适当增加步长,非均匀变化的步长相对于原果蝇算法中的固定步长更容易捕捉到最优值,有利于全局搜索。

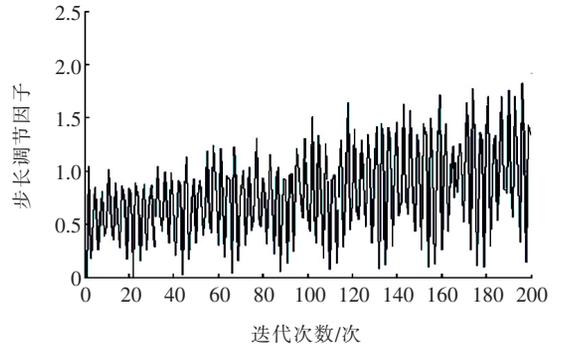


图 8 步长调节因子变化曲线

果蝇个体位置计算:

$$X_i = Start_X + L_i \times X_{i-1} \times RandomValue \quad (17)$$

$$Y_i = Start_Y + L_i \times Y_{i-1} \times RandomValue \quad (18)$$

3.2.3 SFO-DPC 算法

存在数据集 $D = \{x_1, x_2, \dots, x_n\}$ 包括 n 条数据,每条数据的密度函数值为:

$$\varphi_i = \sum_{j=1}^n e^{-\left(\frac{\|x_i - x_j\|}{\sigma}\right)^2} \quad (19)$$

$Z = \sum_{i=1}^n \varphi_i$ 为标准化因子。则密度估计可以定义为:

$$H = - \sum_{i=1}^n \frac{\varphi_i}{Z} \log\left(\frac{\varphi_i}{Z}\right) \quad (20)$$

聚类含小样本数据集时,DPC 算法可以使用指数方式来估计密度:

$$\rho_i = \sum_{j \neq i} \exp\left[-\left(\frac{d_{ij}}{d_c}\right)^2\right] \quad (21)$$

观察式(19)、(21)可知:当使用高斯核函数方法来表示局部密度时,截断距离 d_c 与密度函数值中的 σ 物理意义相同,求解最优 σ 即可得到 d_c 的最优值。若将

数据集当作一个系统,合理准确的聚类结果是系统最稳定的,是每个样本之间稳定关系的最佳状态,所以,将信息熵最小作为判定函数,利用 SFO 算法对 σ 进行最优值求解得出的 σ 值等同于截止距离 d_c 。

将式(20)所示的信息熵函数作为自调节步长果蝇优化算法的浓度判定函数 $Function(S_i)$ 进行优化,求出最优 σ 值,即截断距离 d_c 。按式(1)、(2)、(3)计算得到 ρ_i 和 δ_i 后,自适应地选择聚类中心。该文引入 $\gamma_i = \rho_i \times \delta_i$, γ_i 较大的点,就很有可能是聚类中心,进而根据 γ 分布的特性从中选择真正的聚类中心完成后续聚类过程。

3.3 基于 SFO-DPC 的三维沥青路面裂缝检测

对拍摄到的部分路面数据加以重构,不同的高度值以不同的颜色显示。在数据收集过程中,每组收集 330×170 个数据点。在该研究中,使用 SFO-DPC 算法来聚类沥青路面三维数据的高度值。图 9 为裂缝图像聚类结果。

4 裂缝检测结果评价与分析

该文根据 4 种情况对数据结果进行评估:真正例 TP 、假正例 FP 、真负例 TN 和假负例 FN 。将处理结果与真实标签进行对比,计算准确率 P 、召回率 R 和 F -measure。

$$P = \frac{TP}{TP + FP} \quad (22)$$

$$R = \frac{TP}{TP + FN} \quad (23)$$

F -measure 是平衡了精确度和召回率的调和平均值:

$$F = \frac{2 \times P \times R}{P + R} = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (24)$$

该文试验所用数据中可以分为 4 种典型的路面裂缝图像类型,其图像灰度直方图如图 10 所示。

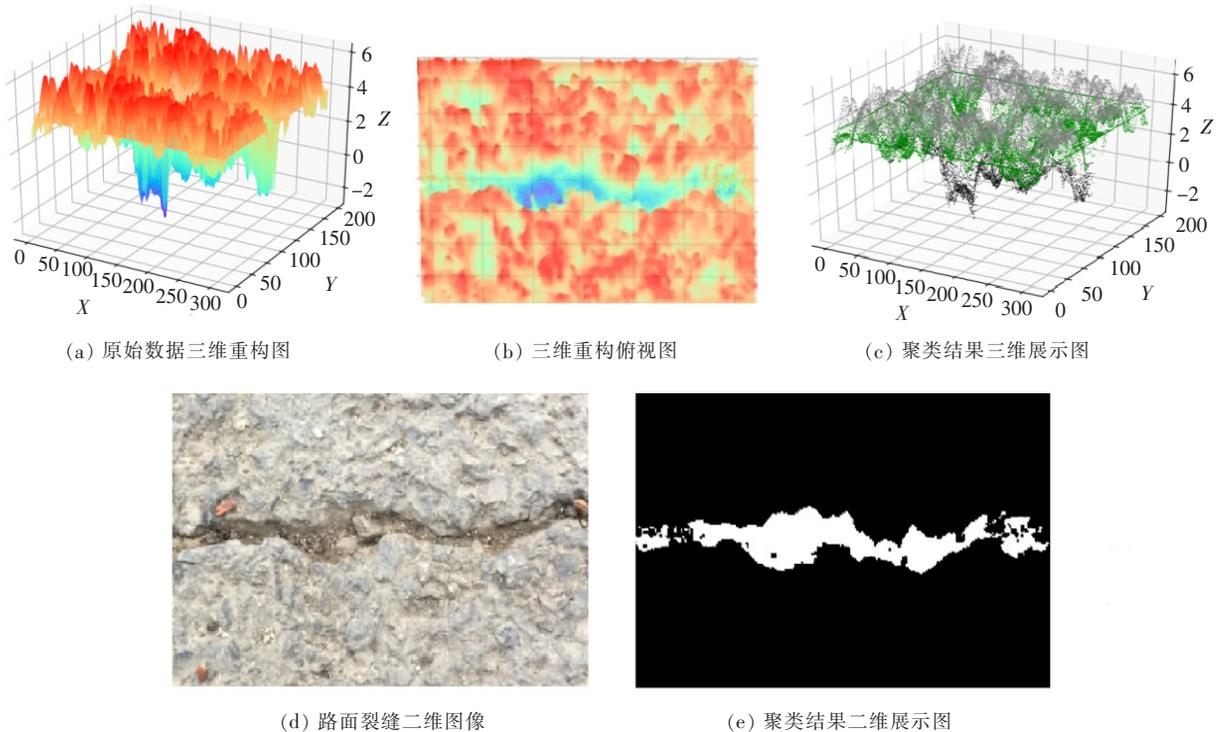


图 9 裂缝图像聚类结果

图 10(b)中,类型 1 路面和裂缝的灰度差异很小;类型 2 图像中由于水渍的影响,路面的灰度分布直方图呈双峰分布,水渍的存在将影响其二维检测;类型 3 的图像中,路面和裂缝的灰度有明显差异,但其差值小于路面与集料的灰度差值;类型 4 图像中,裂缝与路面的差异较大。综上所述,光照、水渍及路面碎石等因素

将会直接影响二维检测效果,而该文提出的基于聚类的沥青路面三维裂缝检测系统不会受到这些因素的干扰。

图 11 为沥青路面三维数据的检测结果,其中图 11(a)为 K-means 算法的检测结果,图 11(b)为 SFO-DPC 算法的处理结果,图 11(c)为处理结果经形态学

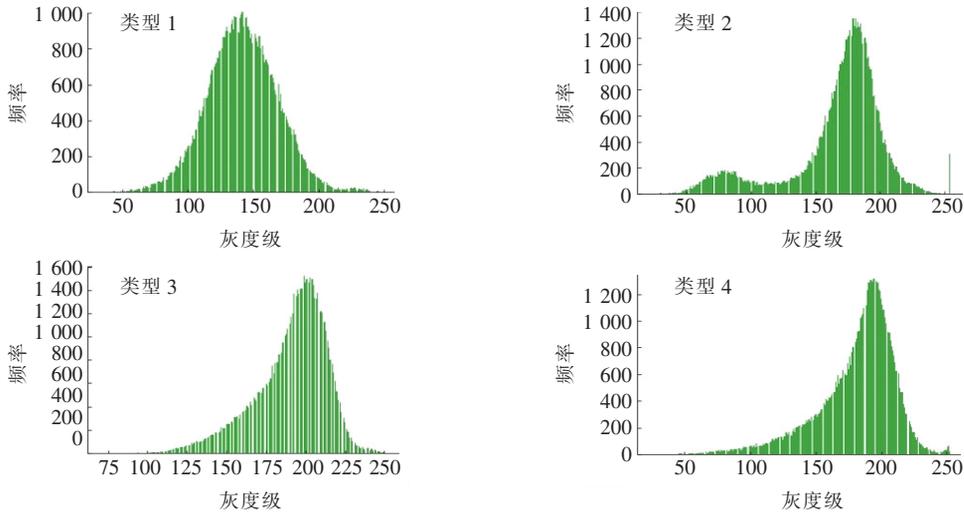
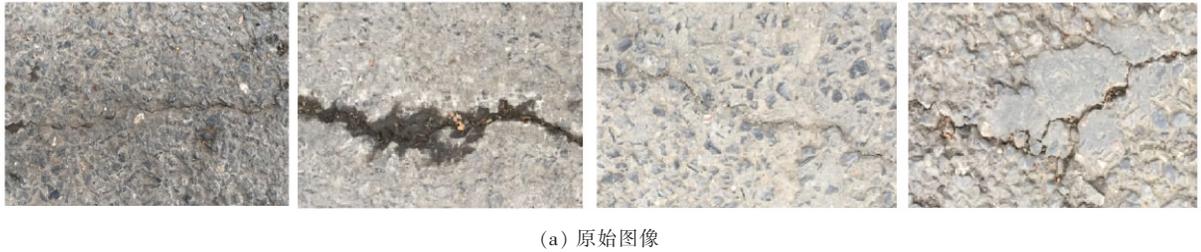


图 10 二维裂缝图像及其灰度分布直方图

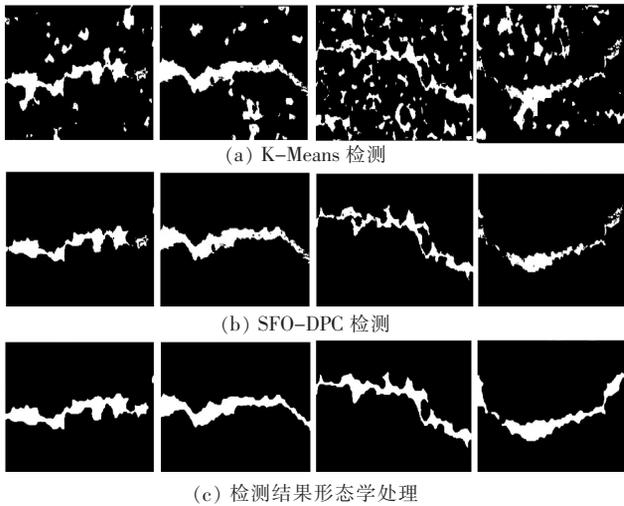


图 11 三维裂缝检测结果对比

处理后的效果。对于 4 种典型的图像,基于聚类的三维检测效果较好,这是因为三维方法不受光照、路面水渍及集料灰度等因素的干扰,仅考虑路面高度变化情况。与此同时,SFO-DPC 算法的检测结果大大优于 K-Means 算法,因为 K-Means 算法受到数据形状及样本量是否均衡等因素的影响,无法自动去除噪声,并且仅能由用户设置类的个数。在设置聚类类别为 2

类或 3 类时,均无法精准地区分沥青路面与路面裂缝。而 SFO-DPC 算法能够自动识别类别数目并能够自动识别噪声,同时其聚类处理不被样本分布特征干扰。

表 2 为 K-Means、SFO-DPC 以及经过形态学处理的最终检测的精确度(P)、召回率(R)和 F -measure。表中数据表明:K-Means 的识别结果不理想。而 SFO-DPC 的精确度、召回率和 F -measure 值最高。

表 2 裂缝检测结果

检测算法	准确率 P	召回率 R	F -measure
K-Means 算法	35.28	70.44	47.01
SFO-DPC 算法	85.45	86.12	85.78
SFO-DPC 算法 (形态学处理后)	88.09	91.35	89.69

5 结论

设计了采用 SFO-DPC 方法的路面裂缝识别方法。采用双目摄像机采集沥青路面数据,保证了采集数据的准确性和低噪声性。提出的 FOA-DPC 算法

有效地解决了基于经验值确定截止距离所带来的不稳定性因素,并利用果蝇优化算法获得最优参数。通过自适应选择中心样本,有效地避免了人工选择中心样本的不稳定性。最后,基于该算法的沥青路面三维检测可以根据三维数据的高程值和空间分布特征有效地识别路面裂缝。该算法在精确度、召回率和 F 值均优于 K -Means算法。利用路面三维数据的高精度来识别裂缝,避免了二维识别方法受道路标记、光影、污渍等噪声干扰的问题。在后续的研究中,将对SFO-DPC算法的二维检测效果进行试验,并将对比同一聚类方法对2D和3D数据的有效性。

参考文献:

- [1] Borsdorf A. Transit Traffic in the Alps and the Andes. A Comparison of very Disparate Systems[J]. Taylor & Francis Group, 2011, 280(1): 22-25.
- [2] 孙波成. 基于数字图像处理的沥青路面裂缝识别技术研究[D]. 西南交通大学博士学位论文, 2015.
- [3] 王玮华. 基于图像处理技术的桥梁裂缝检测[D]. 长安大学硕士学位论文, 2013.
- [4] 张仙艳. 数字图像处理在裂缝识别与检测中的应用[D]. 长安大学硕士学位论文, 2013.
- [5] 瞿中, 林丽丹, 郭阳. 形态学与区域延伸相结合的图像裂缝检测算法研究[J]. 计算机科学, 2014(11).
- [6] 李伟, 呼延菊, 沙爱民, 等. 基于3D数据和双尺度聚类算法的路面裂缝检测[J]. 华南理工大学学报(自然科学版), 2015(8).
- [7] 张栋冰. 基于聚类-最小生成树的沥青路面裂缝检测方法研究[J]. 中山大学学报(自然科学版), 2017(4).
- [8] 闫帅. 基于自然光照条件的路面裂缝检测算法研究[D]. 长安大学硕士学位论文, 2018.
- [9] Mei Q, Gao J, Lin H, et al. Structure Light Telecentric Stereoscopic Vision 3D Measurement System Based on Scheimpflug Condition[J]. Optics and Lasers in Engineering, 2016, 86: 83-91.
- [10] 孙朝云, 呼延菊, 李伟, 等. 基于线结构光的沥青路面三维数据采集系统[J]. 长安大学学报(自然科学版), 2016(4).
- [11] Li W, Huyan J, Tighe S L, et al. An Innovative Primary Surface Profile-Based Three-Dimensional Pavement Distress Data Filtering Approach for Optical Instruments and Tilted Pavement Model-Related Noise Reduction[J]. Road Materials & Pavement Design, 2019, 20(1).
- [12] Li W, Huyan J, Tighe S L, et al. Three-Dimensional Pavement Crack Detection Algorithm Based on Two-Dimensional Empirical Mode Decomposition[J]. Journal of Transportation Engineering, Part B: Pavements, 2017, 143(2).
- [13] Li W, Huyan J, Tighe S L. Pavement Cracking Detection Based on Three-Dimensional Data Using Improved Active Contour Model[J]. Journal of Transportation Engineering, Part B: Pavements, 2018, 144(2).
- [14] Shu Y F, Huang Y, Li B. Design of Deep Learning Accelerated Algorithm for Online Recognition of Industrial Products Defects[J]. Neural Computing and Applications, 2019, 31(9).
- [15] Zeng C, Tian W, Liao W H. The Effect of Residual Stress Due to Interference Fit on The Fatigue Behavior of a Fastener Hole with Edge Cracks[J]. Engineering Failure Analysis, 2016, 66: 72-87.
- [16] Amhaz R, Chambon S, Idier J, et al. Automatic Crack Detection on Two-Dimensional Pavement Images: An Algorithm Based on Minimal Path Selection[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, 17(10): 2 718-2 729.
- [17] Rodriguez A, Laio A. Machine Learning. Clustering by Fast Search and Find of Density Peaks[J]. Science (New York, N. Y.), 2014, 344(6 191).
- [18] 赵怀鑫, 邓然然, 张英杰, 等. 一种用于高速公路通行情况分析的收费数据挖掘方法[J]. 中国公路学报, 2018(8).
- [19] 赵怀鑫, 张英杰, 邓然然, 等. 基于快速峰值聚类的高速公路异常事件识别方法[J]. 长安大学学报(自然科学版), 2018(5).
- [20] Du M J, Ding S F, Xue Y. A Robust Density Peaks Clustering Algorithm Using Fuzzy Neighborhood[J]. International Journal of Machine Learning and Cybernetics, 2017(12): 1-10.
- [21] Liu R, Wang H, Yu X M. Shared-Nearest-Neighbor-Based Clustering by Fast Search and Find of Density Peaks[J]. Information Sciences, 2018, 450.
- [22] 盛超, 邹海, 朱富占. 一种新型自调节步长果蝇优化算法[J]. 微电子学与计算机, 2019(2).