

王森. 基于聚类分割的裂缝检测方法[J]. 智能计算机与应用, 2024, 14(10): 206-213. DOI: 10.20169/j.issn.2095-2163.241030

基于聚类分割的裂缝检测方法

王森

(沈阳工程学院 资产管理处, 沈阳 110136)

摘要: 针对道路表面颗粒噪声干扰严重, 传统聚类算法提取的裂缝轮廓不完整且连续性较差等问题。本文提出一种超像素及快速模糊 C-均值聚类的路面裂缝提取方法, 首先利用直方图均衡化提高正常路面和路面裂缝的对比度; 然后, 采用 Gabor 纹理特征结合简单线性迭代聚类方法生成超像素; 最后, 根据直方图信息计算隶属度矩阵, 将裂缝超像素块聚合成完整的裂缝区域。依靠融合特征作为相似性度量的超像素分割方法, 可提升超像素初始分割效果, 获得更准确的超像素边缘。快速模糊 C-均值聚类算法通过将直方图信息引入到目标函数, 减少聚类分割的计算量, 提升了计算效率。为证明所提算法的准确性, 在公共数据集 Crack Forest Dataset、DeepCrack 上, 与其他 3 种方法进行对比, 实验结果表明本文算法能够有效地检测和提取路面裂缝, 可为道路灾害检测提供有效信息。

关键词: 路面裂缝; 纹理特征; 对比度增强; 超像素分割; 快速模糊 C-均值聚类; 检测

中图分类号: TP391.41

文献标志码: A

文章编号: 2095-2163(2024)10-0206-08

Crack detection method based on clustering segmentation

WANG Sen

(Department of Assets Management, Shenyang Institute of Engineering, Shenyang 110136, China)

Abstract: Aiming at the serious interference of particle noise on road surface, the crack contour extracted by traditional clustering algorithm is incomplete and has poor continuity. This paper proposes a superpixel and fast fuzzy C-means clustering method for pavement crack extraction. Firstly, histogram equalization is used to improve the contrast between normal pavement and pavement cracks. Then, Gabor texture features are combined with simple linear iterative clustering method to generate superpixels. Finally, the fast fuzzy C-means clustering algorithm is used to calculate the membership matrix according to the histogram information, and the crack superpixel blocks are aggregated into a complete crack area. The superpixel segmentation method based on fusion feature as similarity measure can improve the initial segmentation effect and obtain more accurate superpixel edge. By introducing the histogram information into the objective function, the fast fuzzy C-means clustering algorithm reduces the computational complexity of clustering segmentation and improves the computational efficiency. In order to prove the accuracy of the proposed algorithm, it is compared with the other three methods on the public datasets Crack Forest Dataset and DeepCrack. The experimental results show that the proposed algorithm can effectively detect and extract pavement cracks, which can provide effective information for road disaster detection.

Key words: pavement crack; texture feature; contrast enhancement; SLIC; fast fuzzy C-means clustering method; detection

0 引言

裂缝是常见的路面破损类型之一, 会严重影响道路交通安全。路面裂缝的出现不仅增加道路养护成本, 同时也会给道路行车带来较大安全隐患, 道路裂缝检测是一个亟待解决的问题。面对道路环境复杂的情况, 如果采用传统的人工检测方法不仅费时、危险系数大、效率低, 而且已然无法满足道路检测要

求, 因此, 准确且高效地识别道路裂缝对于避免灾害发生、减少经济损失等方面具有重要的现实意义。

近年来, 国内外学者开始借助计算机视觉和数字图像处理技术来实现道路裂缝检测, 并取得了一系列研究进展。其中, 基于视觉的路面裂缝检测方法可以分为 2 类。一类是基于图像处理的检测方法, 主要包括边缘检测^[1-3]、阈值分割^[4]、区域生长和超像素分割等理论方法。通过结合和改进

K -means 聚类算法^[5-6]提取到细致的裂缝区域,但裂缝边缘信息不够准确。徐威等学者^[7]提出将裂缝特征与图像显著性相结合,通过采用图像底层特征,计算裂缝图像的显著度,提取得到路面裂缝。Nguyen 等学者^[8]提出了通过在分割的过程中考虑亮度和连通性计算特征的方法,对任何形式和方向的裂纹进行检测。郝明等学者^[9]提出了一种基于改进主动轮廓模型的无人机影像矿区地裂缝提取方法。Luo 等学者^[10]提出了基于 FSM 的新的双边缘提取算子提取候选裂纹区域的自适应裂缝检测算法。Salman 等学者^[11]使用 Gabor 滤波器检测路面裂缝,但对噪声和灰度不均匀较为敏感。Lei 等学者^[12]提出一种超像素快速模糊 C-均值聚类分割算法,利用一种多尺度形态学梯度重建方法获取超像素,然后对超像素图像进行带直方图参数的 FCM 分割。另一类是基于深度学习的路面裂缝检测算法,目前大多数道路裂缝检测模型采用经典的 CNN 网络作为研究基础,Ronneberger 等学者^[13]提出 U-Net 架构仅需非常少的标注样本,在分割应用上取得了不错的性能。SegNet^[14-15]是用于进行像素级别图像分割的全卷积网络,将编码解码结构普适化并且应用在多个场景数据集中。基于卷积神经网络模型^[16-17]判断图像中是否存在裂缝,曹锦纲等学者^[18]采用深度神经网络,构建了一种基于注意力机制的裂缝检测网络。Nhtn 等学者^[19]提出了一种利用两级卷积神经网络在像素级图像上进行道路裂缝

检测和分割的新方法。深度学习理论为图像分割领域带来了新的思路,在很大程度上实现了算法的优势互补,但是仍然存在裂缝处理效果不佳及过拟合等问题,本文采用一种超像素快速模糊 C-均值聚类算法。首先利用直方图均衡化算法提高正常路面与裂缝的对比度,然后采用 Gabor 算法提取纹理特征,构建以多融合特征为相似性度量的超像素分割方法,提升了超像素初始分割效果。接下来利用基于直方图统计的快速模糊 C-均值聚类分割方法计算隶属度矩阵,在目标函数中增加直方图信息,提升了计算效率。并根据隶属度划分类别,将裂缝超像素块聚合成完整的裂缝区域,有效地提取出路面裂缝。

1 基于超像素的快速模糊 C 均值聚类算法

1.1 裂缝图像预处理

图像灰度信息可为图像分割提供重要参考。图 1 中(a)~(b)为自然影像,(c)为道路裂缝影像,图 1(d)~(f)为自然影像和道路裂缝影像所对应的灰度直方图。图 1(d)~(e)表明自然影像的灰度直方图均存在 2 个明显的峰值,表明图像的前景和背景的灰度分布差异较大,而图 1(f)中的道路裂缝的灰度直方图只存在单一峰值,前景与背景之间灰度分布差异不明显。传统的阈值分割方法可对前景、背景灰度差异明显的图像实现有效分割,但裂缝图像灰度分布差异较小的图像则分割效果不佳,所以需要找到一种适合于路面裂缝的图像处理方法。

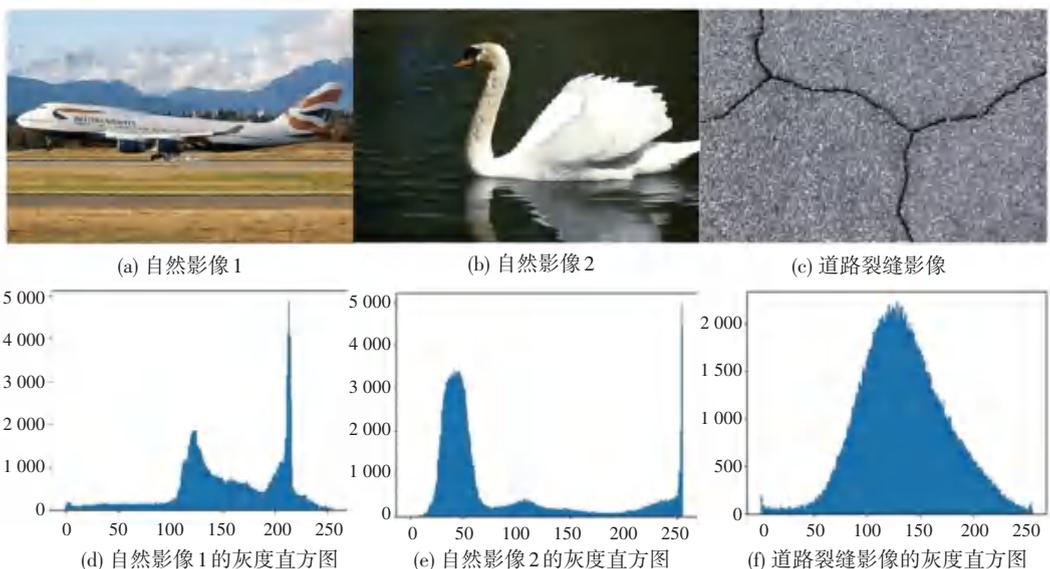


图 1 不同图像灰度直方图

Fig. 1 Different image gray histograms

利用直方图均衡化算法提高前景与背景的对比度,对图像进行非线性拉伸,按照一定灰度范围内像

素值的数量相等原则重新规划像素值,提高像素值的动态范围,达到增强图像整体对比度的效果。对

比度增强灰度直方图差异如图2所示。图2(c)、(d)表明经过对比度增强处理后,裂缝和背景的灰

度差异明显增大,降低了噪声对于图像的影响,使得背景区域的纹理更加均衡。

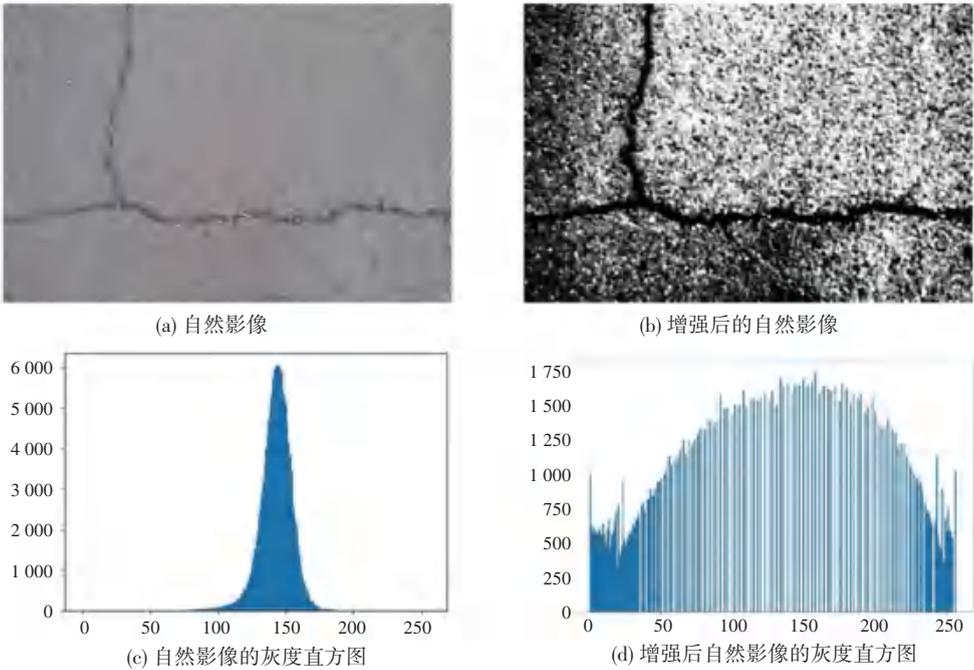


图2 对比度增强灰度直方图差异

Fig. 2 Contrast enhancement gray histogram difference

1.2 结合 Gabor 纹理特征的超像素算法

1.2.1 Gabor 纹理特征

图像纹理作为图像处理和模式识别的重要特征之一。目前比较常用的计算图像纹理特征的方法有 LBP 和 Gabor。其中, LBP 方法是一种用来描述图像局部特征的算子, LBP 的显著优点是具有灰度不变性和旋转不变性, LBP 的局限在于只能获取局部纹理特征。Gabor 方法与 LBP 方法比较, 对道路裂缝图像可通过多尺度、多方向的纹理进行描述, 描述的信息更加丰富, 因此选用 Gabor 算法作为计算纹理特征方法。在空间域中, 二维 Gabor 滤波器是由正弦平面波调制的高斯核函数, 脉冲响应的傅里叶变换是调和函数的傅里叶变换和高斯函数傅里叶变换的卷积。二维 Gabor 函数对波峰、波谷等图像底层特性比较敏感, 应用于道路裂缝检测时, 关键特征会被增强。二维 Gabor 滤波器可表示为:

$$G(x, y) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \exp\left(i\left(2\pi \frac{x'}{\lambda} + \psi\right)\right) \quad (1)$$

$$\begin{cases} x' = x \cos \theta + y \sin \theta \\ y' = -x \sin \theta + y \cos \theta \end{cases} \quad (2)$$

其中, λ 表示波长, 即影像滤波器的滤波尺寸; θ 表示滤波器的方向; ψ 表示相位偏移; σ 表示高斯

滤波器的方差; γ 表示空间纵横比。

根据滤波器与图像卷积结果计算多尺度多方向纹理特征, 得到纹理特征表达式为:

$$t(x, y) = \sqrt{h(x, y)_r^2 + h(x, y)_i^2} \quad (3)$$

其中, $h(x, y)_r$ 、 $h(x, y)_i$ 分别表示实部和虚部与图像卷积结果, 其数值对应滤波图像在该尺度和方向上的能量, 能量值的大小表示滤波图像生成对应频率和方向上的纹理信息的复杂度。

利用二维 Gabor 滤波器对裂缝图像进行多方向与尺度的全局纹理提取, 得到有效的 Gabor 纹理特征, 并通过融合各尺度的纹理特征, 增强纹理结构表征能力, 具有时域和频域上的最佳联合分辨率, 将提取 Lab 空间颜色特征与 Gabor 纹理特征相融合, 利用融合纹理特征改善所研究算法的初始分割, 可得到更精确的超像素边缘。纹理特征提取如图3所示。

1.2.2 超像素分割算法

Achanta 等学者^[20]提出了基于颜色特征和空间距离的简单线性迭代聚类 (Simple Linear Iterative Clustering) 算法, 超像素区域通常被定义为图像中感知上均匀和同质的区域。SLIC 算法有两方面优势。一方面, 超像素能够基于图像的局部空间信息实现预分割。另一方面, 能够用超像素区域的平均

值替换区域中的所有像素,从而减少图像中不同像素的数量。本文利用 Gabor 算法将纹理特征融合到

SLIC 超像素算法中,在聚类过程中通过纹理、颜色和空间位置的归一化距离作为聚类的相似度量。

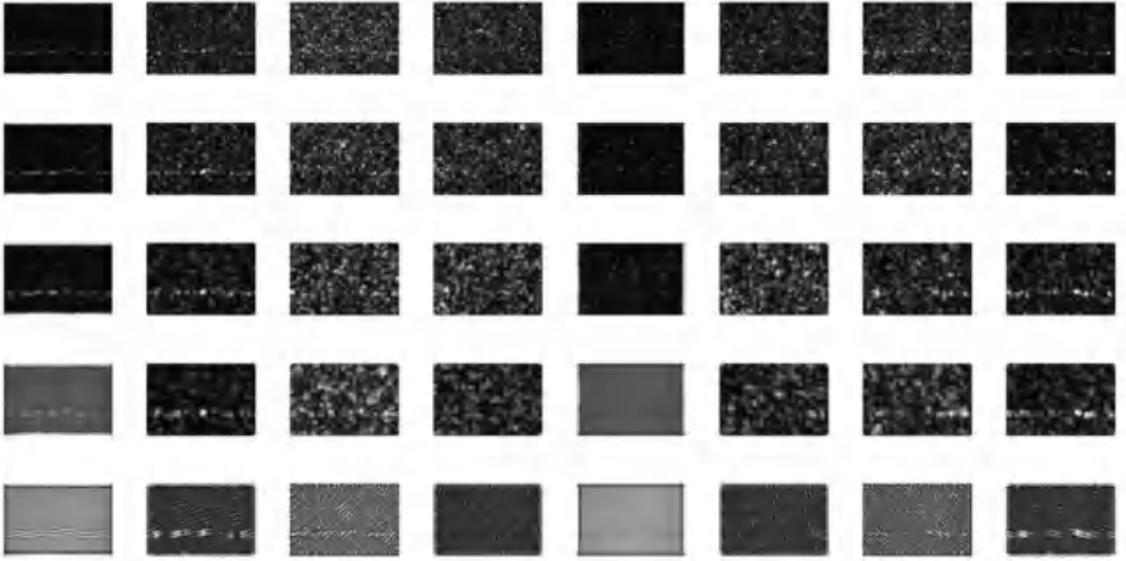


图 3 纹理特征提取

Fig. 3 Texture feature extraction

通过将原始图像的 RGB 色彩空间转换到 Lab 色彩空间,提取 Lab 颜色空间的 3 个分量、像素点的 x, y 坐标和纹理特征 t , 而后通过构造 6 维特征向量 $[l, a, b, x, y, t]$ 定义新的距离度量来实现图像初始分割。各流程如下。

(1) 首先在图像上均匀初始化 n 个初始聚类中心,预设分割成 n 个超像素块。首先在间隔 S 个像素的网格上均匀采样作为超像素中心点 C_j 初始化位置。然后计算像素点与超像素中心的距离,赋予与其距离最近的超像素标签。

(2) 利用 Sobel 计算像素梯度值,计算像素中心点及其 8 邻域内像素点的梯度值,通过比较得到梯度最小值的像素点,更新成为最新超像素中心点。

(3) 对每个超像素中心点的 C_j 的 $2S \times 2S$ 邻域,计算像素点到聚类中心 C_j 的距离 D' , 通过标签记录此时的位置,并将所有像素关联到与距离 D' 最近的超像素块之中。由于像素点会被多个聚类中心搜索,因此通过对比距离 D' 最小值来赋予超像素标签。

(4) 迭代结束后,更新每一个超像素块中心点。

(5) 重复步骤(3)、步骤(4),不断迭代直至误差收敛。

研究得到的裂缝图像超像素分块结果如图 4 所示。在前述步骤(3)中计算像素点和超像素中心点的特征距离 D' 的计算公式如下:

$$D' = \sqrt{\left(\frac{d_c}{M}\right)^2 + \left(\frac{d_s}{S}\right)^2 + \left(\frac{d_t}{T}\right)^2} \quad (4)$$

其中, d_c, d_s, d_t 分别表示色彩相似度量、欧式距离相似度量、纹理相似度量。 M, T 分别表示衡量颜色信息的权重和纹理信息的权重。进一步研究给出计算公式如下:

$$d_c = \sqrt{(l_j - l_i)^2 + (a_j - a_i)^2 + (b_j - b_i)^2} \quad (5)$$

$$d_s = \sqrt{(x_j - x_i)^2 + (y_j - y_i)^2} \quad (6)$$

$$d_t = \sqrt{t(x_i, y_i)^2 - t(x_j, y_j)^2} \quad (7)$$

其中, l_i, a_i, b_i 分别表示像素点 i 在颜色空间下的色彩值; x_i, y_i 分别表示点 i 的图像空间坐标值。

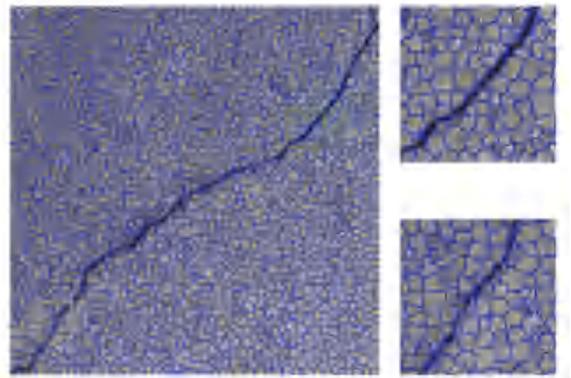


图 4 裂缝图像超像素分块结果

Fig. 4 Crack image superpixel segmentation results

1.3 快速模糊 C-均值聚类

模糊 C-均值聚类算法有着广泛的应用,尤其是在图像分割领域。但模糊 C-均值聚类算法计算复杂度较高,计算时只考虑像素点的灰度信息,遗漏像素点的空间信息,对彩色图像的分割效果不佳。基于超像素的快速模糊 C-均值聚类算法(Superpixel-based Fast Fuzzy C-Means clustering)与模糊 C-均值聚类算法相比,在计算目标函数时增加了直方图信息。计算量从整幅图像的像元数 N 减少为超像素的块数 n ,简化了计算复杂度。通过超像素预分割结果,得到快速模糊 C-均值聚类的目标函数为:

$$J_l = \sum_{i=1}^n \sum_{j=1}^m S_i u_{ji}^l \left\| \left(\frac{1}{S_i} \sum_{p \in R_i} x_p \right) - c_j \right\|^2 \quad (8)$$

其中, n 表示超像素块的数量; i 表示颜色级别,满足 $l \leq i \leq n$; m 表示分类簇的个数; u_{ji} 表示第 i 个超像素和第 j 个簇质心之间的隶属度; l 表示加权指数; S_i 表示第 i 个超像素 R_i 中的像素数,是第 i 个超像素内的颜色像素; c_j 表示第 j 个簇质心。

通过使用 SLIC 方法生成超像素,并统计超像素块的直方图信息,根据超像素分割结果随机初始化隶属度划分矩阵 u_{ji} ,重复操作,通过下式迭代更新聚类中心:

$$\tilde{J}_l = \sum_{i=1}^n \sum_{j=1}^m S_i u_{ji}^l \left\| \frac{1}{S_i} \sum_{p \in R_i} x_p - c_j \right\|^2 - \lambda \left(\sum_{j=1}^m u_{ji} - 1 \right) \quad (9)$$

通过最小化目标函数得到对应的隶属度。对 \tilde{J}_l 求取 d_{ji} 、 c_j 的偏导数,令偏导为 0:

$$\frac{\partial \tilde{J}_l}{\partial u_{ji}} = \sum_{i=1}^k \sum_{j=1}^m \frac{\partial S_i u_{ji}^l \left\| \frac{1}{S_i} \sum_{p \in R_i} x_p - c_j \right\|^2}{\partial u_{ji}} - \lambda = 0 \quad (10)$$

$$\frac{\partial \tilde{J}_l}{\partial c_j} = \sum_{i=1}^k \sum_{j=1}^m \frac{\partial S_i u_{ji}^l \left\| \frac{1}{S_i} \sum_{p \in R_i} x_p - c_j \right\|^2}{\partial c_j} = 0 \quad (11)$$

其中,式(10)、式(11)计算得到 u_{ji} 、 c_j 结果为:

$$u_{ji} = \frac{\left\| \frac{1}{S_i} \sum_{p \in R_i} x_p - c_j \right\|^{-2/(l-1)}}{\sum_{q=1}^m \left\| \frac{1}{S_i} \sum_{p \in R_i} x_p - c_q \right\|^{-2/(l-1)}} \quad (12)$$

$$c_j = \frac{\sum_{i=1}^n u_{ji}^l \sum_{p \in R_i} x_p}{\sum_{i=1}^n S_i u_{ji}^l} \quad (13)$$

2 实验结果与分析

为了验证算法的性能,选用公开路面裂缝数据集 Crack Forest Dataset、DeepCrack Dataset 作为实验数据,本文参数设置如下:快速模糊 C-均值聚类中加权系数 $l = 2$,最大迭代次数为 100, J_l 的收敛误差为 0.001。并将结果与 Canny、K-means、DeepCrack 进行比较,评价指标采用准确率(Precision)、召回率(Recall)和 F -measure。

2.1 裂缝评价指标

采用 Precision、Recall 和 F -measure 三个指标来评价不同裂缝检测算法的性能,判断裂缝检测算法效果的完整性。将人工标记样本作为真值与本文算法做比较,根据 TP 、 FN 和 FP 计算准确率和召回率。由于准确率与召回率存在相互约束的关系,因此采用 F -measure 作为评价检测效果的总体指标。研究给出的数学公式具体如下:

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F\text{-measure} = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (16)$$

其中, TP 表示将裂缝像元正确检测为裂缝像元的数目; FP 表示将非裂缝像元误检测成裂缝像元的数目; FN 表示将裂缝像元检测为非裂缝像元的数目。

2.2 实验结果分析

为验证本文提出算法的有效性,本文选取公开路面裂缝数据集 Crack Forest Dataset 和 DeepCrack Dataset。设计与 Canny 算法、K-means 分割算法、DeepCrack 算法的对比实验,并进行对比分析。

实验结果如图 5 所示。结果表明,Canny 算法能够提取出裂缝的边缘信息,但抗噪声能力较弱,出现大量误检。图 5 中第 4 行第 2 列中发现在细微裂缝图像中,裂缝与背景路面较为相似,K-means 算法出现误检。从图 5 第 4 行第 3 列可发现 K-means 算法在裂缝不显著区域出现断裂。实验结果表明,DeepCrack 算法检测的裂缝较为完整,但 DeepCrack 作为有监督深度学习算法,裂缝的检测精度会受到人工标注样本的影响。本文提出方法的裂缝检测效果优于其他算法,有很好的抗噪声能力,提取的裂缝边缘信息更加丰富。可以看出其他算法无法消除路面砂砾、污垢等产生的噪声,本文算法利用对比度增强以及融合纹理特征的超像素算法能够有效地消除噪声干扰。

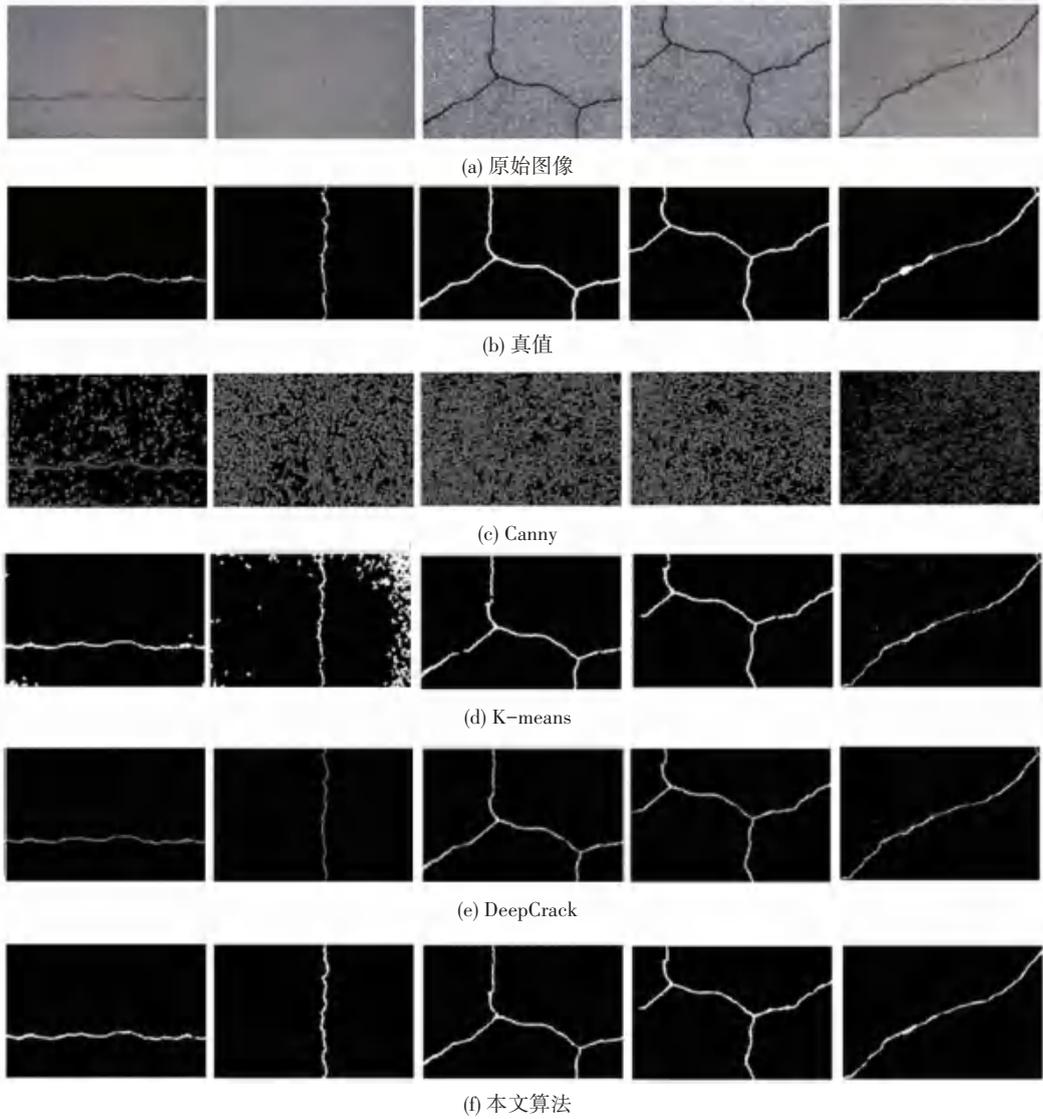


图 5 对比实验结果

Fig. 5 Experimental results comparison

在数据集 Crack Forest Dataset 中,精度评价结果如图 6 所示,精度定量评价结果见表 1。由表 1 可知,本文算法的裂缝提取效果最佳, $F - measure$ 值为 0.712,本文算法相较于 DeepCrack 算法和 K-means 算法, $F - measure$ 值则分别提高 11.9%、15.8%,本文算法从定量评价指标来看,裂缝提取的准确性更加优异,抗噪声干扰能力更强。

表 1 数据集 Crack Forest Datasets 精度定量评价

Table 1 Quantitative evaluation of precision on Crack Forest Datasets

方法	P	R	F
Canny	0.136	0.175	0.171
K-means	0.663	0.634	0.636
DeepCrack	0.675	0.587	0.615
本文算法	0.704	0.683	0.712

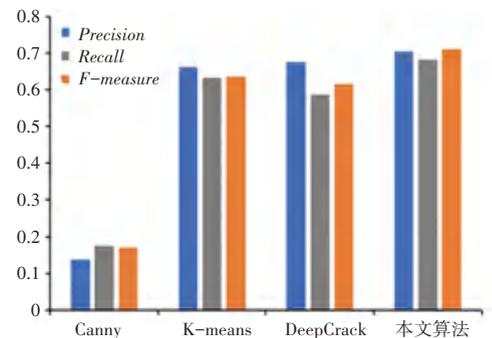


图 6 Crack Forest Dataset 数据集精度评价结果

Fig. 6 Accuracy evaluation results on Crack Forest Dataset

DeepCrack 数据集中,精度评价结果如图 7 所示,精度定量评价结果见表 2。由表 2 可知,本文算法的 $F - measure$ 值为 0.783,本文算法与 DeepCrack 相比, $F - measure$ 值提高 11.1%, $Precision$ 值、

Recall 值分别提高 13.7%、11.8%。对比结果表明,本文算法有效地提升裂缝提取精度,性能更加优异。

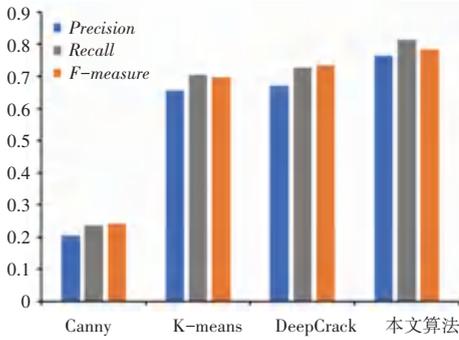


图7 DeepCrack数据集精度评价结果

Fig. 7 Accuracy evaluation result on DeepCrack dataset

表2 数据集 DeepCrack Dataset 精度定量评价

Table 2 Quantitative evaluation of precision on DeepCrack Dataset

方法	<i>P</i>	<i>R</i>	<i>F</i>
Canny	0.204	0.237	0.241
K-means	0.656	0.705	0.698
DeepCrack	0.671	0.728	0.734
本文算法	0.763	0.814	0.783

裂缝提取最终结果如图8(c)、(d)所示。分析图8可知,本文算法提取的裂缝轮廓完整,边缘细节较为准确,对分辨率较低的图像检测效果明显。综上所述,通过与K-means、DeepCrack算法对比结果表明,本文算法以纹理特征为基础,构建以多融合特征为相似性度量的超像素算法,利用图像的纹理特征信息,有效降低了路面颗粒噪声的干扰,更好地保护了裂缝边缘结构,使得提取的裂缝边缘更加准确。其次,本文将超像素快速模糊C-均值聚类应用到路面裂缝检测领域,相较于传统的聚类分割算法得到了更好的检测效果,也提高了计算效率。

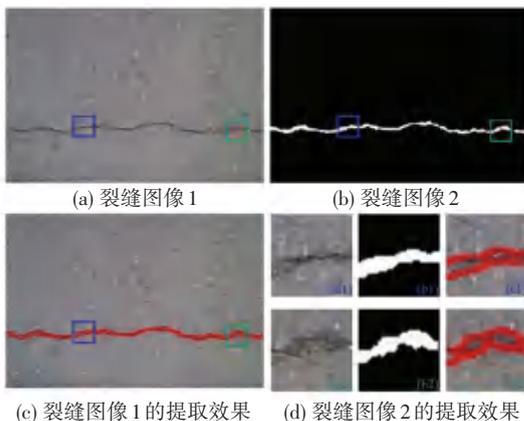


图8 裂缝图像提取效果

Fig. 8 Crack image extraction effect

3 结束语

针对现在道路图像颗粒噪声、传统的裂缝提取算法裂缝轮廓提取不完整且连续性较差等问题,本文提出了一种结合超像素的快速模糊C-均值聚类分割的有效道路裂缝检测算法。通过对比度增强消除路面噪声的干扰,结合超像素和快速模糊C-均值聚类算法,提取得到准确的路面裂缝。实验结果表明,该方法可以有效地检测路面上的裂缝,并且具有较高的准确率和可靠性。下一步,将继续提高路面裂缝的提取精度,由于模糊C-均值聚类算法聚类数量等参数需要手动输入,未来将研究自动模糊C-均值聚类算法。

参考文献

- [1] 张晨阳,曹艳华,杨晓忠.一种基于改进Canny算法的图像边缘检测新方法[J].计算机仿真,2023,40(7):382-386.
- [2] 吴琼,马雷.一种基于LoG算子的量子图像边缘检测算法[J].量子电子学报,2022,39(5):720-727.
- [3] 王世芳,车艳丽,李楠,等.一种基于多尺度脊边缘的沥青路面裂缝检测算法[J].中国公路学报,2017,30(4):32-41.
- [4] WANG Yun, ZHANG Juyong, LIU Jingxin, et al. Research on crack detection algorithm of the concrete bridge based on image processing[J]. Procedia Computer Science, 2019, 154:610-616.
- [5] 徐港,赵悦悦,蒋赏,等.基于多种连通域特征的结构表面裂缝提取方法[J].华中科技大学学报(自然科学版),2019,47(10):52-55,68.
- [6] 王德方,曾卫明,王倪传.基于改进K-means算法的不均匀光照下道路裂缝检测[J].计算机应用与软件,2015,32(7):244-247,300.
- [7] 徐威,唐振民,吕建勇.基于图像显著性的路面裂缝检测[J].中国图象图形学报,2013,18(1):69-77.
- [8] NGUYEN T S, SBÉGOT, DUCULTY F, et al. Free-form anisotropy: A new method for crack detection on pavement surface images[C]// IEEE International Conference on Image Processing. Brussels, Belgium:IEEE, 2011: 1069-1072.
- [9] 郝明,林惠晶,高彦彦.基于改进主动轮廓模型的无人机影像矿区地裂缝提取[J].地球信息科学学报,2022,24(12):2448-2457.
- [10] LUO Qijun, GE Baozhen, TIAN Qingguo. A fast adaptive crack detection algorithm based on a double-edge extraction operator of FSM[J]. Construction and Building Materials, 2019, 204:244-254.
- [11] SALMAN M, MATHAVAN S, KAMAL K, et al. Pavement crack detection using the Gabor filter[C]// 16th International IEEE Annual Conference on Intelligent Transportation Systems (ITSC 2013). The Hague, Netherlands: IEEE, 2014: 2039-2044.
- [12] LEI Tao, JIA Xiaohong, ZHANG Yanning, et al. Superpixel-based fast fuzzy C-Means clustering for color image segmentation[J]. IEEE Transactions on Fuzzy Systems, 2018, 27(9):1753-1766.
- [13] RONNEBERGER O, FISCHER P, BROX T. U-Net;

- Convolutional networks for biomedical image segmentation [C]// Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015: 234–241.
- [14] BADRINARAYANAN V, KENDALL A, CIPOLLA R, et al. Segnet: A deep convolutional Encoder–Decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481–2495.
- [15] SCHMUGGE S J, RICE L, LINDBERG J, et al. Crack segmentation by leveraging multiple frames of varying illumination [C]// Proceedings of 2017 IEEE Winter Conference on Applications of Computer Vision (WACV). Santa Rosa, USA: IEEE, 2017: 1045–1053.
- [16] LIU Yahui, YAO Jian, LU Xiaohu, et al. DeepCrack: A deep hierarchical feature learning architecture for crack segmentation [J]. Neurocomputing, 2019, 338: 139–153.
- [17] ZHANG Lei, YANG Fan, ZHANG D, et al. Road crack detection using deep convolutional neural network [C]// IEEE International Conference on Image Processing. Phoenix, USA: IEEE, 2016: 3708–3712.
- [18] 曹锦纲, 杨国田, 杨锡运. 基于注意力机制的深度学习路面裂缝检测 [J]. 计算机辅助设计与图形学学报, 2020, 32(8): 1324–1333.
- [19] NHUNG H T N, PERRY S, BONE D, et al. Two-stage convolutional neural network for road crack detection and segmentation [J]. Expert Systems with Applications, 2021, 186: 115718.
- [20] ACHANTA R, SHAJI A, SMITH K, et al. SLIC superpixels compared to State-of-the-Art superpixel methods [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2012, 34(11): 2274–2282.