

基于显著性检测和改进投影字典对的盲道分割

王 民, 肖 磊*, 杨 放

西安建筑科技大学信息与控制工程学院, 陕西 西安 710055

摘要 现有盲道分割算法是通过提取颜色或纹理特征,采用聚类等方法来进行分割,易受盲道类型和外部环境的影响。针对此问题,从盲道整体特征进行考虑,引入学习的方式,提出了一种基于显著性检测和改进投影字典对学习的盲道分割方法。该方法首先利用显著性检测,对盲道区域进行粗定位;然后以图像块作为处理单元,通过所提出的稳健字典对学习算法进行字典学习;接着将粗定位后的图像分块在该字典上进行稀疏重构;最后按照重构误差进行分类,以达到分割的目的。实验结果显示,在盲道分割中,该算法相对于现有算法,无论是准确性,还是普适性都表现更好。

关键词 图像处理; 图像分析; 盲道分割; 稳健字典对学习; 图像块

中图分类号 TP391.41

文献标识码 A

doi: 10.3788/LOP54.041001

Blind Road Segmentation Based on Saliency Detection and Improved Projective Dictionary Pair

Wang Min, Xiao Lei, Yang Fang

*School of Information and Control Engineering, Xi'an University of Architecture and Technology,
Xi'an, Shaanxi 710055, China*

Abstract The current blind road segmentation algorithms are used to segment by extracting the color or texture feature, and by using the clustering method, which are vulnerable to blind road types and the external environment. To solve this problem, a learning approach is introduced, and a blind road segmentation method is proposed based on saliency detection and improved projection dictionary from the consideration of the global feature of blind road. Firstly, the saliency detection algorithms are used to roughly locate the blind road region. Then the image piece is used as the processing unit, and the dictionary is learned through the robust projective dictionary pair learning proposed. And the coarse image after location is divided into blocks to sparsely reconstruct on the dictionary. Finally, the rough-positioned images are reconstructed on the dictionary, and classified according to the reconstruction error to achieve the purpose of segmentation. Experimental results show that the proposed algorithm performs better than the existing algorithms in terms of accuracy and universality in blind road segmentation.

Key words image processing; image analysis; blind road segmentation; robust dictionary pair learning; image pieces

OCIS codes 100.2960; 100.3010; 100.2000

1 引言

盲道分割用于从复杂场景图像中对盲道进行精确提取,是导盲设备的关键技术之一,同时也在图像分割领域具有重要应用。当前解决盲道分割问题最常用的传感器是单目视觉,分割方法可分为基于颜色和纹理两类。以阈值分割和区域生长等为代表的基于颜色的分割方法^[1-2]具有效率高的优势,能较好地解决标准盲道的分割,但该方法对颜色和光照敏感,无法适用于盲道与背景区域颜色相近的情况。同样地,通过提取纹

收稿日期: 2016-11-18; **收到修改稿日期:** 2016-12-15

基金项目: 住房和城乡建设部科学技术项目计划(2016-R2-045)、陕西省教育厅专项基金(2013JK1081)、陕西省科学技术研究发展计划项目(CXY1122(2))、陕西省自然科学基金青年基金(2013JQ8003)

作者简介: 王 民(1959—),男,本科,教授,硕士生导师,主要从事智能信息处理方面的研究。

E-mail: wangmin1329@163.com

* **通信联系人.** E-mail: 1015596715@qq.com

理特征再进行聚类的基于纹理的分割方法^[3]在面对城市中类型众多的盲道时,也显得普适性不足。

近年来,随着稀疏表示理论的逐步完善,它已经被成功地应用到了涉及信号处理的多个领域^[4-7]。应用稀疏表示进行图像处理的主要思想是利用图像的全局特性,来克服现有分割算法将盲道单个特征或其组合作为识别依据的可行性及有效性差的缺陷,其关键在于过完备字典的构建,为此国内外学者提出了多种字典构造方法。如 Wright 等^[8]提出一种基于稀疏表示分类器(SRC)的人脸识别算法,该算法的字典直接由已知类别的训练样本集组成。后来为了充分利用图像的特征信息,使构建的字典更具判别性,又引入了学习的概念。文献[9]提出一种基于 Metaface 框架学习得到的字典,相比 SRC 得到的字典更加紧凑,并获得了更好的识别效果。文献[10]提出兼具判别和重构能力的判别式-K 均值奇异值分解(D-KSVD)字典学习算法。文献[11]将标签常量引入 K 均值奇异值分解(KSVD)算法中,通过增加编码误差约束提高字典的判别分类能力。文献[12]提出一种基于 Fisher 准则的判别字典学习算法,加强对重构系数的约束,使重构系数也具有判别性。以上方法都能使字典性能获得不同程度的提升,但是在算法效率上却区别不大,因为当前稀疏表示优化问题广泛通过求解 l_0/l_1 范数的最小值来解决,计算耗时严重。为此,文献[13]给出了一种新的字典学习算法——投影字典对学习(DPL)算法,该算法引入了分析字典,稀疏重构系数可以通过分析字典与样本相乘快速得到,大大减少了算法的运行时间,但却易受外界噪声影响。

受到上述研究的启示,本文对 DPL 算法进行了改进,将训练样本经过稳健主成分分析(RPCA)后的低秩图像用于字典学习,经过 RPCA 分解得到的低秩图像不受外界噪声影响,严格遵循低秩结构。在此基础上,提出了一种基于显著性检测与稳健投影字典对学习(RDPL)的盲道分割算法,该算法首先对源图像进行显著性分析,得到粗定位的盲道区域,然后以图像小片作为处理单元,通过求解粗定位后图像的每个局部图像小片在改进投影字典上的稀疏编码,根据重构误差最小原则判断该小片是否属于盲道部分。该算法旨在提高盲道分割的普适性和抗噪声能力。

2 相关工作

2.1 显著性检测

显著性检测的任务是找到场景中最重要和信息量最大的部分,在图像分割和目标识别等领域有着重要的应用。显著性检测依据对图像的先验假设不同可以分为多种类别,而近年来的相关研究结果表明基于图论的检测方法表现较好。Yang 等^[14]同时考虑前景和背景线索,提出了一种基于图论流形排序(GBMR)的显著性检测算法。本文将采用 GBMR 算法对测试图像进行盲道粗分割。

GBMR 算法构造显著性图分为以下两个阶段:

- 1) 利用图像的边界节点作为标记节点,按照其他节点与标记节点的相关性进行排序,分别形成 4 个边界的显著性图,然后将这 4 幅图合成第一阶段的显著性图。
- 2) 将第一阶段的显著性图作为新的标记数据并再次进行排序,获得最终的显著性图。

2.2 字典对学习模型

传统判别式字典学习算法的目的是学到能对 K 类训练样本 $\mathbf{X} = [\mathbf{X}_1, \cdots, \mathbf{X}_k, \cdots, \mathbf{X}_K] \in \mathbf{R}^{p \times nK}$ (所有训练样本均为 p 维向量, n 表示每一类样本的数量) 进行稀疏重构的综合字典 $\mathbf{D} = [\mathbf{D}_1, \cdots, \mathbf{D}_k, \cdots, \mathbf{D}_K] \in \mathbf{R}^{p \times mK}$ (m 表示每一类字典中的原子数)。此时为了获得稀疏系数矩阵 \mathbf{A} ,通常需要在稀疏编码过程中进行非常耗时的求解 l_0/l_1 范数运算。假设能够找到一部分析字典 $\mathbf{P} = [\mathbf{P}_1, \cdots, \mathbf{P}_k, \cdots, \mathbf{P}_K] \in \mathbf{R}^{mK \times p}$,使得矩阵 $\mathbf{A} = \mathbf{P}\mathbf{X}$,这样就能快速地对样本 \mathbf{X} 完成稀疏表示。Gu 等^[13]依据这个想法提出了如下所示的字典对学习算法模型,同时学习综合字典 \mathbf{D} 和分析字典 \mathbf{P} 表示为

$$\{\mathbf{P}^*, \mathbf{X}^*\} = \arg \min_{\mathbf{P}, \mathbf{D}} \sum_{k=1}^K \|\mathbf{X}_k - \mathbf{D}_k \mathbf{P}_k \mathbf{X}_k\|_F^2 + \lambda \|\mathbf{P}_k \bar{\mathbf{X}}_k\|_F^2, \text{ s.t. } \|d_i\|_2 \leq 1, \tag{1}$$

式中 $\bar{\mathbf{X}}_k$ 是 \mathbf{X}_k 的补集,表示整个训练样本集 \mathbf{X} 中除第 k 类样本 \mathbf{X}_k 外剩余的所有样本, $\|\cdot\|_F^2$ 和 $\|\cdot\|_2^2$ 分别为矩阵的 F 范数和 2 范数, $\arg \min f(x)$ 表示当 $f(x)$ 取最小值时 x 的取值, $\lambda (>0)$ 是一个标量常数, d_i 代表综合字典 \mathbf{D} 中第 i 个元素。

对于 \mathbf{D}_k ,能够根据投影系数矩阵 $\mathbf{P}_k \mathbf{X}_k$ 较好地对第 k 类样本 \mathbf{X}_k 进行重构,即字典对应该使重构误差最

小化。对于 \mathbf{P}_k , 除了对第 k 类训练样本外, 都应满足 $\mathbf{P}_k \mathbf{X}_i \approx 0 (i \neq k)$ 。同其他基于字典学习(DL)的稀疏编码算法相比, DPL 算法不仅具有竞争力, 而且速度优势明显。

2.3 稳健字典对学习模型

DPL 算法有自己独特的优势, 但也存在明显的缺点, 比如对光照、阴影等噪声敏感, 算法性能随着噪声幅值的增加迅速下降, 因此很难适用于处于复杂场景下的盲道分割问题。

一般一幅样本图像既包含结构信息, 也包含噪声信息。Partridge 等^[15]提出了一种具有稳健性的主成分分析(PCA)方法, 利用 RPCA 可以将矩阵 \mathbf{X} 分解为两个矩阵相加, 一个是低秩矩阵 \mathbf{L} , 另一个是稀疏矩阵 \mathbf{E} , $\mathbf{X} = \mathbf{L} + \mathbf{E}$, 并且允许误差项 \mathbf{E} 为任意大小。矩阵 \mathbf{L} 和矩阵 \mathbf{E} 可以通过求解以下的优化问题得到, 即

$$\min_{\mathbf{L}, \mathbf{E}} \text{rank}(\mathbf{L}) + \epsilon \|\mathbf{E}\|_0, \text{ s.t. } \mathbf{L} + \mathbf{E} = \mathbf{X}, \quad (2)$$

式中 $\epsilon > 0$ 是折中因子, 用来表示稀疏矩阵 \mathbf{E} 所占的权重, $\text{rank}(\cdot)$ 是矩阵的秩, $\|\cdot\|_0$ 是矩阵的 l_0 范数。(2) 式是一个非确定性多项式难题(NP 难题), 在满足特定条件时, 可以转化为凸优化问题, 即

$$\min \|\mathbf{L}\|_* + \epsilon \|\mathbf{E}\|_1, \text{ s.t. } \mathbf{L} + \mathbf{E} = \mathbf{X}, \quad (3)$$

式中 $\|\cdot\|_*$ 代表矩阵的核范数, 表示矩阵中全部元素绝对值的和。文献[16]给出了 ϵ 的建议取值 $\epsilon = 1/\sqrt{\max(m, n)}$ 。

基于上述分析, 本文提出用由原始训练样本集 \mathbf{X} 经过 RPCA 分解得到的低秩矩阵集 $\mathbf{L} = [\mathbf{L}_1, \dots, \mathbf{L}_k, \dots, \mathbf{L}_K]$ 参与字典对学习, 其中 $\mathbf{L}_K = [\mathbf{l}_1, \mathbf{l}_2, \dots, \mathbf{l}_n]$ 代表第 k 类训练样本的子低秩矩阵集。于是可得到下面的 RDPL 模型, 即

$$\{\mathbf{P}^*, \mathbf{D}^*\} = \arg \min_{\mathbf{P}, \mathbf{D}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{P}_k \mathbf{L}_k\|_F^2 + \lambda \|\mathbf{P}_k \bar{\mathbf{L}}_k\|_F^2, \text{ s.t. } \|d_i\|_2^2 \leq 1. \quad (4)$$

(4) 式通常情况下是一个非凸问题, 此时需要引入一个可变矩阵 \mathbf{A} , 将其松弛为下面的凸问题, 即

$$\{\mathbf{P}^*, \mathbf{A}^*, \mathbf{D}^*\} = \arg \min_{\mathbf{P}, \mathbf{A}, \mathbf{D}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{A}_k\|_F^2 + \tau \|\mathbf{P}_k \mathbf{L}_k - \mathbf{A}_k\|_F^2 + \lambda \|\mathbf{P}_k \bar{\mathbf{X}}_k\|_F^2, \text{ s.t. } \|d_i\|_2^2 \leq 1. \quad (5)$$

式中 τ 为惩罚系数。对于(5)式的求解, 首先将分析字典 \mathbf{P} 和综合字典 \mathbf{D} 初始化为含有 F 范数的随机矩阵, 然后采取交替更新矩阵 \mathbf{A} 和字典对 $\{\mathbf{D}, \mathbf{P}\}$ 的方式。具体实现如下。

1) 固定字典对 $\{\mathbf{D}, \mathbf{P}\}$, 更新矩阵 \mathbf{A} 为

$$\mathbf{A}^* = \arg \min_{\mathbf{A}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{A}_k\|_F^2 + \tau \|\mathbf{P}_k \mathbf{L}_k - \mathbf{A}_k\|_F^2, \quad (6)$$

这是一个标准的最小二乘问题, \mathbf{A} 的封闭解为

$$\mathbf{A}_k^* = (\mathbf{D}_k^T \mathbf{D}_k + \tau \mathbf{I})^{-1} (\tau \mathbf{P}_k \mathbf{L}_k + \mathbf{D}_k \mathbf{L}_k), \quad (7)$$

式中矩阵 \mathbf{I} 表示单位矩阵, $(\cdot)^T$ 表示矩阵的转置, $(\cdot)^{-1}$ 表示矩阵的逆。

2) 固定矩阵 \mathbf{A} , 更新字典对 $\{\mathbf{D}, \mathbf{P}\}$ 为

$$\begin{cases} \mathbf{P}^* = \arg \min_{\mathbf{P}} \sum_{k=1}^K \tau \|\mathbf{P}_k \mathbf{L}_k - \mathbf{A}_k\|_F^2 + \lambda \|\mathbf{P}_k \bar{\mathbf{L}}_k\|_F^2 \\ \mathbf{D}^* = \arg \min_{\mathbf{D}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{A}_k\|_F^2, \text{ s.t. } \|d_i\|_2^2 \leq 1 \end{cases}. \quad (8)$$

分析字典 \mathbf{P} 的封闭解为

$$\mathbf{P}_k^* = \tau \mathbf{A}_k \mathbf{L}_k^T (\tau \mathbf{L}_k \mathbf{L}_k^T + \lambda \bar{\mathbf{L}}_k \bar{\mathbf{L}}_k^T + \gamma \mathbf{I})^{-1}, \quad (9)$$

式中 γ 是一个极小的常数。综合字典 \mathbf{D} 的优化可通过引入一个可变矩阵 \mathbf{S} , 利用交替方向乘子(ADMM)算法求解, 即

$$\min_{\mathbf{D}, \mathbf{S}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{A}_k\|_F^2, \text{ s.t. } \mathbf{D} = \mathbf{S}, \|s_i\|_2^2 \leq 1, \quad (10)$$

$$\begin{cases} \mathbf{D}^{(r+1)} = \arg \min_{\mathbf{D}} \sum_{k=1}^K \|\mathbf{L}_k - \mathbf{D}_k \mathbf{A}_k\|_F^2 + \rho \|\mathbf{D}_k - \mathbf{S}_k^{(r)} + \mathbf{T}_k^{(r)}\|_F^2 \\ \mathbf{S}^{(r+1)} = \arg \min_{\mathbf{S}} \sum_{k=1}^K \rho \|\mathbf{D}_k - \mathbf{S}_k^{(r)} + \mathbf{T}_k^{(r)}\|_F^2, \|s_i\|_2^2 \leq 1 \\ \mathbf{T}^{(r+1)} = \mathbf{T}^{(r)} + \mathbf{D}_k^{(r+1)} - \mathbf{S}_k^{(r+1)} \end{cases}, \quad (11)$$

式中矩阵 T 表示拉格朗日乘子。

3) 比较相邻两次迭代结果,如果字典对 $\{D,P\}$ 已经收敛,则停止迭代并输出。

容易发现,(8)式中的第一个子目标函数是判别分析字典学习,目的是提升字典 P 的判别能力;第二个子目标函数是表示综合字典学习,目的是利用分析字典 P 生成的编码系数对输入样本实现重构误差最小化。当整个过程收敛后,就能得到判别能力和表示能力相对平衡的字典对。RDPL 算法不仅避免了求解 L_0 范数的 NP 难题,而且相对 DPL 算法对噪声拥有更好的稳健性。

3 基于显著性检测和 RDPL 算法的盲道分割

3.1 提取分割决策图

当前城市中盲道虽然标准不一,且污损严重,但一般而言相对其背景仍然具有非常显著的颜色或纹理特征,这些特征让显著性检测算法具有很好的应用。本文将显著性检测算法用于图像的预分割,去掉图像中不显著的部分,找出盲道疑似区域,对于减少后续稀疏表示算法的计算量具有重要的意义。

由于获取的视频图像是 RGB 图像,它的三个基色分量易受光照等影响,为了不影响算法性能,首先将图像转换到与人眼感知接近、受光照影响较小的 HIS 空间。基于显著性检测的盲道区域粗定位方法包含以下步骤,如图 1 所示。

- 1) 利用 GBMR 算法得到源图像 I 的显著性图 G ;
- 2) 对 G 进行阈值分割和形态学变换,得到分割决策图 S 。




图 1 提取分割决策图
Fig. 1 Extract the segmentation decision map

3.2 盲道分割

分割决策图 S 中除了盲道区域以外,还包括其他的疑似区域,因此必须利用 RDPL 算法对 S 作进一步处理。算法以图像块为处理单元,具体可分为字典学习和判别分类两部分。

应用稀疏表示在盲道分割中,出发点是将盲道区域和非盲道区域区分开来,因此只需要构造盲道的投影字典,(4)式中 K 取值为 1。字典对学习在离线阶段完成,所以选取的训练样本应该尽可能地包含多种类型的盲道图像,以便学习到完备的综合字典。然后将训练样本处理成 $n \text{ pixel} \times n \text{ pixel}$ 的图像块(图 2),并把它们下拉成为 n^2 维的列向量,形成 N 张图像小片组成的训练样本集 $X = [x_1, x_2, \dots, x_N]$ 。字典对学习具体实现如下:

算法 1 判别式稳健综合 & 分析字典对学习

输入:训练样本集 $X = [x_1, x_2, \dots, x_N]$ 的低秩成分集 $L = [l_1, l_2, \dots, l_N]$, 参数 λ, τ, m, γ ;

- 1) 初始化 $D^{(t)}$ 和 $P^{(t)}$ 为带有弗罗贝尼乌斯范数的随机矩阵;
- 2) while $\{D,P\}$ 未收敛 do
- 3) $t \leftarrow t + 1$;
- 4) 利用(7)式更新 $A^{(t)}$;
- 5) 利用(9)式更新 $P^{(t)}$;
- 6) 利用(11)式更新 $D^{(t)}$;
- 7) end while

输出:用于盲道分割的分析字典 P ,综合字典 D 。

在 RDPL 模型中,分析字典 P 对测试图像中除盲道以外的图像块生成的系数非常小,只能对盲道块生




图 2 训练小块示例

Fig. 2 Examples of small training pieces

成有效的编码系数。同时,综合字典 \mathbf{D} 被用于重构盲道小块,因此在进行残差 $\|\mathbf{L} - \mathbf{D}^* \mathbf{P}^* \mathbf{L}\|_F^2$ 比较时,盲道块的残差比其他图像块小很多。很显然,重构残差可以用来识别测试图像每一小块的类别,于是能够得到与 RDPL 模型相关联的分类函数,即

$$\mathbf{x} \in \begin{cases} \text{blind road, } \|\mathbf{l} - \mathbf{DPl}\|_2 \leqslant t_h \\ \text{non-blind road, } \|\mathbf{l} - \mathbf{DPl}\|_2 > t_h \end{cases}, \tag{12}$$

式中 \mathbf{x} 代表测试小块, t_h 是盲道与非盲道的稀疏误差分界阈值。判别分类算法的实现步骤如下。

算法 2 测试图像判别分类

输入:分割决策图 \mathbf{S} ,分析字典 \mathbf{P} ,综合字典 \mathbf{D} ;

1) 将 \mathbf{S} 按照与训练小块同等大小 $n \times n$ 进行分块,共 N 块,将它们下拉成 N 组列向量;

2) for $\mathbf{x} = 1:N$ do

3) 对 \mathbf{x} 进行 RPCA 分解,得到其低秩成分 \mathbf{l} ;

4) 利用(12)式对 \mathbf{x} 进行分类;

5) end for

6) 将分类后的图像二值化;

输出:分割出的盲道图像。

4 实验结果与分析

由于目前尚没有权威的盲道科学研究测试数据库,为了对本文方法的有效性进行验证,实验所用数据为自行录制的 10 段含有盲道的人行道视频。这些视频中包含了多种类型的盲道,并且受到光照、天气等外界因素干扰。所有实验都在配置为 Intel i5 处理器、主频 2.5 GHz、内存 4 GB 的电脑上进行,运行环境为 MATLAB R2014a。

首先对采集的视频进行分帧处理,从 10 段视频中共选出 300 帧图像(图 3),视频帧大小为 640 pixel \times 480 pixel,把其中 150 幅图像作为训练样本,剩下 150 幅图像作为测试样本。从训练样本中均匀截取 256 张大小为 20 pixel \times 20 pixel 的盲道小片用于盲道字典的学习。在选取训练小片时,保证每一种类型的盲道小




图 3 视频图像示例

Fig. 3 Examples of video images

为了定量评价 RDPL 算法的抗噪声性能,将 256 张训练小片复制一份并添加不同大小的随机噪声,各字典学习算法对它们的识别率和训练时间分别如表 1 和 2 所示。参与比较的算法有 SRC、基于 Fisher 准则的判别字典学习算法(FDDL)、标签常量-K 均值奇异值分解(LC-KSVD)算法、DPL 和本文算法。可以看出,其他字典学习算法性能随着噪声的增加急剧下降,而 RDPL 算法依然保持较高的识别率,表明 RDPL 算法对于解决复杂场景下的分割问题依然可靠。此外,由于字典对在优化过程中都具有封闭解,因此大大减少了重构字典的训练时间。

表 1 不同信噪比(SNR)下的各 DL 算法识别率

Table 1 Recognitions rate of different DL algorithms under different signal-to-noise ratios (SNRs)					
SNR	SRC /%	FDDL /%	LC-KSVD /%	DPL /%	RDPL /%
Original	94.7	96.7	97.3	98.2	98.4
5 dB	68.8	65.8	73.1	82.5	85.5
3 dB	31.3	23.9	40.5	42.7	72.3
1 dB	18.4	13.2	24.3	28.4	60.1

表 2 各 DL 算法的训练时间

Table 2 Training time of different DL algorithms					
Algorithm	SRC	FDDL	LC-KSVD	DPL	RDPL
Time /s	—	6071.92	376.47	24.61	27.53

将本文方法与文献[1]~[3]中提出的盲道分割方法进行比较,为了保证对分割效果的客观评价,实验对所有方法采用精度、召回率、F 值(F-measure)和平均分割时间 4 个客观评价指标开展评价^[14]。精度值表示正确分配给提取区域的像素占提取区域中所有像素的比值,召回率定义为正确分配给提取区域的像素相对于真实应该提取区域的像素的百分比,F-measure 是对精度值 ν_{pre} 和召回率 r_{rec} 的综合衡量,表达式为

$$F_{\beta} = \frac{(1 + \beta) \nu_{pre} \times r_{rec}}{\beta^2 \nu_{pre} + r_{rec}},$$

(13)

实验设置 $\beta^2=0.3$ 以强调精度。各方法对所有测试图像分割结果的评价指标平均值对比如图 4 所示,分割时间对比如表 3 所示。

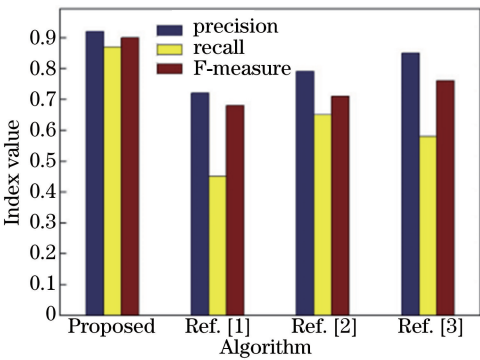


图 4 客观评价指标

Fig. 4 Objective evaluation indices

表 3 各算法平均分割时间

Table 3 Average segmentation time of different algorithms				
Algorithm	Ref. [1]	Ref. [2]	Ref. [3]	Proposed
Time /s	1.073	1.247	2.731	1.064

从图 4 可以看出,本文方法在平均分割精度和召回率等指标上都优于其他方法。经过分析得知,这是文献算法自身局限性造成的,例如文献[1]、[2]使用的是基于颜色的分割方法,虽然在盲道与人行道颜色区别明显的情况下能取得非常不错的结果,但是在二者颜色无明显差异或盲道受阴影和光照等噪声干扰的场景下,文献[1]、[2]方法几乎不能将盲道与人行道分割开来,误分割严重,间接拉低了平均评价指标值。此外,本文方法的耗时工作即投影字典对学习主要在离线阶段完成,所以从表 3 可以看出,本文方法与效率很高的

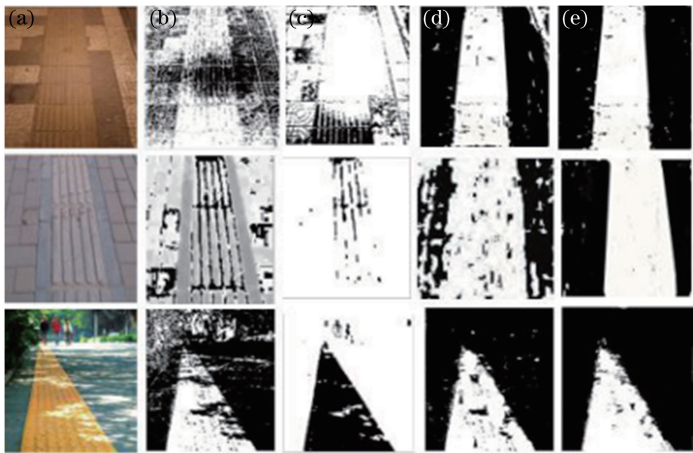


图 5 各方法分割结果。(a)原图;(b)文献[1]算法;(c)文献[2]算法;(d)文献[3]算法;(e)本文算法

Fig. 5 Segmentation results of different methods. (a) Original images; (b) Ref. [1] method; (c) Ref. [2] method; (d) Ref. [3] method; (e) proposed method

阈值分割相比,同样具有竞争力。图 5 列出了部分测试图像在不同方法下的分割结果。

至于本文方法分割失败的情况,有以下原因:1)盲道受损严重,有大面积缺失;2)与训练样本选择有关,因为稀疏表示分类的准确性在很大程度上取决于字典中原子的完备性。因此,在字典足够完备的情况下,本文方法相对于现有方法分割效果更好,并且自适应性更强。

5 结 论

对稀疏表示理论在盲道分割中的应用进行了研究,提出了一种基于显著性检测与 RDPL 算法的盲道分割方法。首先通过显著性检测算法提取出盲道的疑似区域,再利用稀疏表示的方法完成精确分割。实验结果表明,该方法克服了现有分割算法依赖于某一特征的缺陷,使算法具有了普适性,在分割精度和抗噪性能上都表现更好,并且运行时间上也有一定的优势,能够满足盲道分割实时性的要求。

参 考 文 献

[1] Yan Zhijie, Wang Jianming, Dou Ruzhen, *et al.* Sidewalk for the blind adaptive segmentation based on color clustering and line detection[J]. Journal of Tianjin Polytechnic University, 2010, 29(1): 80-84.
闫志杰, 汪剑鸣, 窦汝振, 等. 基于颜色聚类 and 直线检测的自适应盲道区域分割算法[J]. 天津工业大学学报, 2010, 29(1): 80-84.

[2] Zhou Yi, Zhao Qunfei. Blind road region detection and tracing algorithm based on color information[J]. Microcomputer Applications, 2010, 26(8): 47-50.
周 毅, 赵群飞. 基于颜色信息的盲道区域检测与跟随算法[J]. 微型电脑应用, 2010, 26(8): 47-50.

[3] Peng Yuqing, Xue Jie, Guo Yongfang. Blind road recognition algorithm based on color and texture information[J]. Journal of Computer Applications, 2014, 34(12): 3585-3588.
彭玉青, 薛 杰, 郭永芳. 基于颜色纹理信息的盲道识别算法[J]. 计算机应用, 2014, 34(12): 3585-3588.

[4] Wang Jianing. Hyperspectral image classification based on joint sparse representation and morphological feature extraction[J]. Laser & Optoelectronics Progress, 2016, 53(8): 082801.
王佳宁. 基于联合稀疏表示与形态特征提取的高光谱图像分类[J]. 激光与光电子学进展, 2016, 53(8): 082801.

[5] Yu Linqian, Qin Yali, Zhang Xiaoshuai. Denoising of strong noisy image via gradient reweighted non-local averaging over learned dictionaries[J]. Laser & Optoelectronics Progress, 2016, 53(11): 111002.
余临倩, 覃亚丽, 张晓帅. 基于字典学习的梯度重权非局部平均的强噪声图像去噪[J]. 激光与光电子学进展, 2016, 53(11): 111002.

[6] Xiao L, Dai B, Wu T, *et al.* Unstructured road segmentation method based on dictionary learning and sparse representation[J]. Journal of Jilin University (Engineering and Technology), 2013, 43(S1): 384-388.

- [7] Yin Wen, Li Yuanxiang, Zhou Zeming, *et al.* Remote sensing image fusion based on sparse representation[J]. Acta Optica Sinica, 2013, 33(4): 0428003.
尹 雯, 李元祥, 周则明, 等. 基于稀疏表示的遥感图像融合方法[J]. 光学学报, 2013, 33(4): 0428003.
- [8] Wright J, Yang A Y, Ganesh A, *et al.* Robust face recognition via sparse representation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2009, 31(2): 210-227.
- [9] Yang M, Zhang L, Yang J, *et al.* Metaface learning for sparse representation based face recognition[C]. IEEE International Conference on Image Processing (ICIP), 2010, 119(5): 1601-1604.
- [10] Zhang Q, Li B. Discriminative K-SVD for dictionary learning in face recognition[C]. Computer Vision and Pattern Recognition (CVPR), 2010, 119(5): 2691-2698.
- [11] Jiang Z, Lin Z, Davis L S. Label consistent K-SVD: learning a discriminative dictionary for recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2013, 35(11): 2651-2664.
- [12] Yang M, Zhang D, Feng X, *et al.* Fisher discrimination dictionary learning for sparse representation[C]. IEEE International Conference on Computer Vision, 2011, 24(4): 543-550.
- [13] Gu S, Zhang L, Zuo W, *et al.* Projective dictionary pair learning for pattern classification[J]. Advances in Neural Information Processing Systems, 2014, 1: 793-801.
- [14] Yang C, Zhang L, Lu H, *et al.* Saliency detection via graph-based manifold ranking[C]. Computer Vision and Pattern Recognition (CVPR), 2013: 3166-3173.
- [15] Partridge M, Jabri M. Robust principal component analysis[C]. Neural Networks for Signal Processing X, 2000: 289-298.
- [16] Candès E J, Li X, Ma Y, *et al.* Robust principal component analysis?[J]. Journal of the ACM, 2011, 58(3): 11.