

基于条件随机场的梨园场景图像分割方法^{*}

周俊¹ 朱金荣¹ 王明军²

(1. 南京农业大学江苏省智能农业装备重点实验室, 南京 210031; 2. 宁波工程学院机械工程学院, 宁波 315016)

摘要: 提出一种基于条件随机场模型的梨园场景分割方法, 条件随机场模型直接对分割目标的后验概率建模, 融入图像空间上下文信息, 使得条件随机场模型可以获得更精确的分割结果。将已标记的场景图像划分为超像素, 超像素的特征向量和标记的类别作为学习样本整合到类别数据库中; 将未标记场景图像划分为超像素, 利用条件随机场和类别数据库对未标记图像超像素的特征向量和空间关系进行建模; 训练获得模型参数, 利用最大后验边缘准则对未标记超像素进行类别推理。实验结果表明, 与改进的 K-最近邻方法相比该算法可以更加准确地进行梨园场景分割。

关键词: 梨园场景 图像分割 条件随机场 超像素 空间上下文

中图分类号: TP242.6 文献标识码: A 文章编号: 1000-1298(2015)02-0008-06

Pear Orchard Scene Segmentation Based on Conditional Random Fields

Zhou Jun¹ Zhu Jinrong¹ Wang Mingjun²

(1. Key Laboratory of Intelligent Agricultural Equipment in Jiangsu Province, Nanjing Agricultural University, Nanjing 210031, China

2. School of Mechanical Engineering, Ningbo University of Technology, Ningbo 315016, China)

Abstract: A pear orchard scene segmentation based on conditional random fields (CRFs) was proposed. The CRFs modeled posterior probabilities directly, and had an ability to fuse context information of images. Therefore, it was a suitable method to solve images segmentation of the pear orchard scene whose structures are often very complicated. Firstly, labeled images of the pear orchard scene were segmented into superpixels, and feature vectors of the superpixels and their corresponding labels were integrated into a label database as training samples. Secondly, unlabeled images of the pear orchard scene were also segmented into the superpixels, and their features and spatial relationships between these unlabeled superpixels were modeled by using the CRFs. Moreover, parameters of the CRFs model were obtained by taking the label database as the training samples. Finally, labels of the unlabeled superpixels were inferred through the maximum posterior marginal (MPM) algorithm. The experimental results showed that the proposed algorithm could provide more accurate segmentation results of the pear orchard scene compared with the mutual K-nearest neighbor method (MKNN).

Key words: Pear orchard scene Image segmentation Conditional random fields Superpixel Spatial context

引言

图像分割是图像分析和模式识别的首要问题, 它是图像分析和模式识别系统的重要组成部分^[1-3]。农业机器人完成自主导航或精确施肥等任

务时, 经常需要应用机器视觉将农田场景中的绿色植株所在区域分割出来, 而后才能继续展开导航路径提取、作物行识别定位、路径跟踪等过程。所以, 在农业机器人自主导航算法中, 农田自然环境图像中的绿色植株目标高质量分割是完成农业机器人后

收稿日期: 2014-02-23 修回日期: 2014-05-12

^{*} 高等学校博士学科点专项科研基金资助项目(20130097110043)和国家自然科学基金资助项目(61203327, 31071325)

作者简介: 周俊, 教授, 博士生导师, 主要从事农业机器人、机器视觉与模式识别研究, E-mail: zhoujun@njau.edu.cn

续任务的关键前提^[4]。

传统的图像分割方法主要有阈值化、边缘检测、区域生长、分水岭方法等。这些算法具有算法原理简单,对特定场景具有很好分割结果等特点,但是由于一些因素的制约,限制了该类算法应用推广到其他领域。阈值化算法要求物体与背景在灰度上存在较大差异;基于边缘检测的分割算法对于图像的噪声十分敏感,且容易丢失纹理信息;基于区域生长的分割算法对种子点的选择及生长顺序依赖性很强;基于分水岭的分割算法易于产生过分割、对低对比度图像易丢失重要轮廓^[4]。

随着机器视觉与人工智能的发展,出现了如马尔可夫随机场模型、聚类法、遗传算法、神经网络、支持向量机^[5-9]等方法。这些算法一定程度上引入了人工智能技术,改善了分割结果,但是依旧存在一些不足。基于马尔可夫随机场模型的分割算法需要进行条件独立性假设,而此假设在实际场景中很难满足^[5];基于聚类法的分割算法对于初始聚类中心的依赖性很强^[6];基于遗传算法的分割算法中的参数选择多是依据经验,没有定量方法^[7];基于神经网络的分割算法分割结果对于训练样本依赖性很强,容易陷入局部最优解^[8];基于支持向量机的分割算法训练速度慢、参数调整不便,对训练样本依赖性很强^[9]。

农田自然环境图像所表现出来的不确定性和模糊性,使得农田自然环境图像分割成为一个具有很大挑战的任务。为此,需要尽可能多地利用图像中包含的信息,主要包括:①像元或者像元邻域特征信息。②图像成分之间的相关信息,通常也称为上下文信息^[10]。本文提出以一种基于条件随机场模型的梨园场景分割的算法,对这两种信息进行融合。将已标记的场景图像分割为超像素,超像素的特征向量和标记的类别作为学习样本整合到类别数据库中,利用条件随机场模型对未标记图像超像素的特征向量和空间关系进行建模,经过训练获取模型参数,利用最大后验边缘准则对未标记图像超像素进行类别推理。

1 超像素分割与邻域描述

1.1 超像素分割

超像素(Superpixels)是指具有相似纹理、颜色、亮度等特征的相邻像素构成的图像块^[11],在图像分割^[12]、图像分类^[13]等方面都有应用。超像素生成算法大致可以分为两类:基于图论的方法和基于梯度下降的方法^[11]。本文通过基于 Graph-based 分割算法^[14]获取超像素,分割结果如图1所示。

1.2 超像素的邻域描述

以像素为图像处理单元时,可以直接通过像素

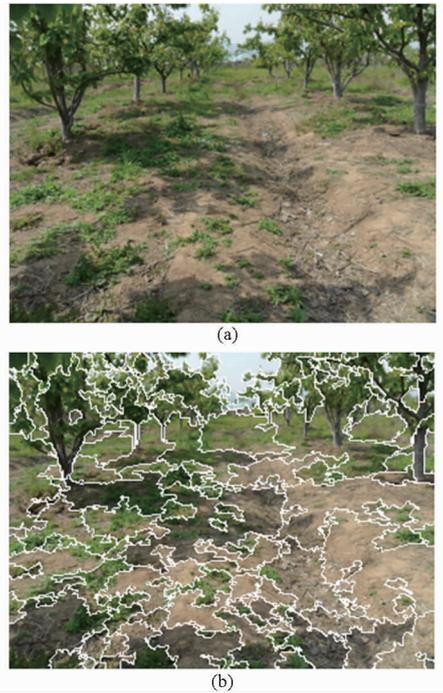


图1 超像素分割

Fig. 1 Superpixel segmentation

(a) 原场景图像 (b) 超像素分割

的坐标值确定其邻域像素。以超像素作为图像处理的基础单元,为使用图像中包含的空间上下文信息,必须确定超像素之间的邻域关系。

超像素分割后产生一个与原图像像素位置一一对应的二维数组,二维数组中的每个元素值为原图像对应位置像素所属超像素的索引标号。通过逐行逐列搜索,确定每个超像素的边界。边界两侧的超像素即为相邻超像素,也称为邻域超像素。

表1所示为图1中原场景图像超像素分割后第13~22行、第30~34列部分像素所属超像素索引标号,针对此部分区域超像素的邻域进行描述。通过逐行逐列搜索,表中前3行(即第13、14、15行)像素都

表1 部分位置像素的超像素索引标号

Tab. 1 Index labels of superpixels for pixels at some locations

行号	列号				
	30	31	32	33	34
13	1	1	1	1	1
14	1	1	1	1	1
15	1	1	1	1	1
16	1	1	1	20	1
17	1	1	20	20	23
18	20	20	20	20	23
19	20	20	20	23	23
20	20	20	23	23	23
21	20	20	23	23	23
22	23	23	23	23	23

属于索引标号为“1”的超像素(记为SP 1);表中第4行(即第16行)前3列(即第30、31、32列)也属于SP 1,而表中第4行第4列(即第33列)像素属于索引标号为“20”的超像素(记为SP 20),表中第4行第5列(即第34列)像素属于SP 1;从而确定SP 1与SP 20互为邻域超像素。相应地,表1中SP 1与SP 23、SP 20与SP 23也互为邻域超像素。通过上述算法,可以确定每个超像素的所有邻域超像素。

2 类别数据库构建

2.1 样本获取与特征向量

将手工标记过的场景图像进行超像素处理。若超像素所包含的某一类别像素超过一定比例,则认为该超像素为对应类别的训练样本。一个超像素训练样本产生一个特征向量,超像素的特征向量获取方法:对于每一个色彩通道(RGB中的R、G、B),将其依次划分为5个bin(区域),将每一个超像素中所有像素点对应的色彩值在这5个bin中的归一化柱状图作为该超像素所对应的颜色特征,共15维。

2.2 增量式整合策略

样本数据库包含2个模型:非梨树类模型 M_N 和梨树类模型 M_P 。在果园自然环境中,非梨树类通常包含天空、地面、杂草等,梨树类包含梨树树叶和梨树树干等;同时,环境中光照分布不均,容易在地面形成阴影区域(图1)。使得这种自然场景中同类超像素特征向量呈多模态分布,不同类超像素特征向量存在部分重叠。因而,2个模型均包含若干聚类中心 c_j (样本原型),且每个聚类中心 c_j 对应一个计数器 $n_j(j=1,2,\dots,j_{\max})$ 。以一个新的训练样本 (x_i, l_i) (x_i 为第 i 个样本特征向量, l_i 为第 i 个样本所属类别)为例,根据其标记被放到一个模型库中,整合、更新方式为:

(1)若当前模型中所有聚类中心 c_j 与当前样本特征距离大于预定义阈值 θ_d ,即 $\forall c_j, \|x_i - c_j\| > \theta_d$,则当前模型增加一个新的聚类中心,该中心的颜色特征与当前样本相同,且该中心的计数器值为1。

(2)若模型中的某一聚类中心 c_i 与当前样本的特征距离不超过预定义阈值 θ_d ,则该聚类中心对应的样本计数器直接加1。

3 基于条件随机场模型的梨园场景分割模型构建

条件随机场^[15](Conditional random fields, CRF)直接对后验概率建模,能够融入图像空间上下文信息,可以增强对图像内容的理解,因此被应用于图像分析领域^[10,13,16-17]。为了提高对梨园目标的分割

准确性,这里使用条件随机场进行场景图像模型构建。将场景图像中得到的全体超像素颜色特征记作 $X = \{x_i\}$, x_i 为从第 i 个超像素中获得的颜色特征。对应的场景图像超像素类别 $L = \{l_i\}$ 。 $l_i \in \{-1, 1\}$, -1 表示非梨树类, 1 表示梨树类。给定场景图像的超像素颜色特征 X ,基于条件随机场的场景类别的联合后验概率定义为

$$P(L|X) = \frac{1}{Z} \exp \left(\sum_{i \in S} \phi_i(l_i, X) + \sum_{i \in S} \sum_{j \in N_i} \phi_{ij}(l_i, l_j, X) \right) \quad (1)$$

式中 Z ——归一化系数

S ——超像素的索引集合

N_i ——第 i 个超像素的全部邻域超像素

ϕ_i ——条件随机场图模型的一元势能函数,刻画了超像素自身颜色特征与所属类别的相互关系

ϕ_{ij} ——二元势能函数,反映了邻接超像素的局部空间关系对其类别判定的影响

CRF模型具体的实现流程通常包含3个重要步骤:模型选择、模型训练和模型推理^[10]。

3.1 模型选择

由式(1)可知,CRF模型主要由一元势能函数和二元势能函数组成。因而,CRF模型选择主要是一元势能函数和二元势能函数的构建。

3.1.1 一元势能函数

CRF模型中的势能函数常定义为一些判别的分类器。本研究基于改进的K-最近邻(Modified K nearest neighbours, MKNN)^[18]和半径扩大策略定义一元势能函数。若一个超像素的特征向量记为 x ,分别求取 x 与模型 M_N 及模型 M_P 中所有聚类中心的距离,分别记作 d_{N_i} 和 d_{P_j} ,并分别保存特征距离为 d_{N_i} 和 d_{P_j} 对应的计数值 n_{N_i} 和 n_{P_j} ,其与两类聚类中心的最小特征距离记作: $d_{N_{\min}} = \min\{d_{N_1}, d_{N_2}, \dots, d_{N_i}\}$ 和 $d_{P_{\min}} = \min\{d_{P_1}, d_{P_2}, \dots, d_{P_j}\}$ 。若预定义的距离阈值为 θ_{dist} ,且 $P_N(x)$ 表示超像素特征 x 属于 M_N 的概率, $P_P(x)$ 表示 x 属于 M_P 的概率,建立启发式规则如下:

(1)若 $d_{N_{\min}} > \theta_{dist}$ 且 $d_{P_{\min}} > \theta_{dist}$,表明当前类别数据库中的所有特征原型都不能确定当前待分类超像素的所属类别,更新距离阈值 $\theta_{dist} = 1.5\theta_{dist}$ 。否则,进入下一步。

(2)分别计算待估计超像素特征 x 属于 M_N 、 M_P 的概率 $P_N(x)$ 和 $P_P(x)$

$$P_N(x) = \frac{\sum_{N_i \in (d_{N_i} \leq \theta_{dist})} n_{N_i}}{\sum_{N_i} n_{N_i}}$$

$$P_p(\mathbf{x}) = \frac{\sum_{p_j \in (d_{p_j} \leq \theta_{dist})} n_{p_j}}{\sum_{p_j} n_{p_j}} \quad (2)$$

式中 $\sum_{N_i} n_{N_i}$ 、 $\sum_{p_j} n_{p_j}$ ——两类类别模型中分别包含的样本总数

式(2)反映了与超像素特征 \mathbf{x} 相似的样本数与已知类别样本总数的比值,当前超像素特征 \mathbf{x} 分别为梨树类与非梨树类的概率,即为

$$P_{pear}(\mathbf{x}) = \frac{P_p(\mathbf{x})}{P_N(\mathbf{x}) + P_p(\mathbf{x})}$$

$$P_{nonpear}(\mathbf{x}) = 1 - P_{pear}(\mathbf{x})$$

(3) 若 $P_{pear}(\mathbf{x}) > 0.7$, 则将 $P_{nonpear}(\mathbf{x})$ 和 $P_{pear}(\mathbf{x})$ 分别设置为 0.7 和 0.3。

(4) 若 $P_{nonpear}(\mathbf{x}) > 0.7$, 则将 $P_{nonpear}(\mathbf{x})$ 和 $P_{pear}(\mathbf{x})$ 分别设置为 0.3 和 0.7。

将超像素特征 \mathbf{x} 属于相应类别的概率值作为一元势能函数的取值。

3.1.2 二元势能函数

CRF 的二元势函数^[17]定义为

$$\phi_{ij}(l_i, l_j, \mathbf{X}) = w_{ij} \left[k_1 l_i l_j + k_2 \left(1 - \frac{d_{ij}}{d_{max}} \right) \cdot \delta(l_i = l_j) + k_3 \frac{d_{ij}}{d_{max}} \delta(l_i \neq l_j) \right] \quad (3)$$

其中 $w_{ij} = |p_{ij}| / |p_i|$ (4)

式中 δ ——Kronecker δ 函数

w_{ij} ——超像素 i 与超像素 j 的连接权值

$|p_{ij}|$ ——超像素 i 与超像素 j 邻接的像素数

$|p_i|$ ——超像素 i 包含的像素数

d_{ij} ——超像素 i 与超像素 j 特征空间欧氏距离

d_{max} ——超像素 i 与其邻域超像素之间最大的距离值

k_1 、 k_2 、 k_3 ——对应的各项势函数的权重

由式(4)可知:若 $|p_{ij}|$ 与 $|p_i|$ 的值越相近,则表明 i 和 j 邻接的像素越多,两者之间的连接权值就越大,超像素 j 对超像素 i 影响就越大。

同时,式(3)中 $k_1 l_i l_j$ 的引入是考虑了农业机器人工作在非结构化场景中可能存在一些不确定性因素。在获得 2 个邻域超像素颜色特征后,不管这 2 个超像素的特征差异有多大, $k_1 l_i l_j$ 项倾向于将邻接超像素划分成同一个类别,以对场景不确定性因素进行补偿。其次,式(3)中 $k_2 (1 - d_{ij}/d_{max}) \delta(l_i = l_j)$ 及 $k_3 (d_{ij}/d_{max}) \delta(l_i \neq l_j)$ 则融入邻域超像素特征向量,从而引入空间上下文信息。

3.2 模型训练

CRF 模型中,需要学习推理的参数为式(3)各

项对应的权值 k_1 、 k_2 、 k_3 。设训练样本特征为 $\mathbf{X}^f (f = 1, 2, 3, \dots, N)$, 其中 f 表示训练样本为第 f 帧, L^f 表示训练样本的类别标记。利用最大似然标准对参数进行估计

$$\hat{\Theta} = \arg \max_{\Theta} \sum_{f=1}^N \ln(P(L^f | \mathbf{X}^f)) \quad (5)$$

式中 Θ ——待估计参数,即 k_1 、 k_2 、 k_3 的值

$\hat{\Theta}$ ——最优估计值

模型参数估计采用梯度上升法^[16],得

$$\Delta k_1 \propto \sum_{f=1}^N \sum_{i \in S} \sum_{j \in N_i} l_{ij} [l_i^f l_j^f - \langle l_i l_j \rangle_{P(l_i, l_j | \mathbf{X}^f, \Theta^c)}] \quad (6)$$

$$\Delta k_2 \propto \sum_{f=1}^N \sum_{i \in S} \sum_{j \in N_i} l_{ij} (1 - d_{ij}/d_{max}) \cdot [\delta(l_i^f = l_j^f) - \langle \delta(l_i = l_j) \rangle_{P(l_i, l_j | \mathbf{X}^f, \Theta^c)}] \quad (7)$$

$$\Delta k_3 \propto \sum_{f=1}^N \sum_{i \in S} \sum_{j \in N_i} l_{ij} d_{ij}/d_{max} \cdot [\delta(l_i^f \neq l_j^f) - \langle \delta(l_i \neq l_j) \rangle_{P(l_i, l_j | \mathbf{X}^f, \Theta^c)}] \quad (8)$$

式中 Θ^c ——参数当前估计值

$P(l_i, l_j | \mathbf{X}^f, \Theta^c)$ ——基于当前参数值估计的超像素 i 和 j 的联合边缘概率

$\langle \delta(l_i = l_j) \rangle_{P(l_i, l_j | \mathbf{X}^f, \Theta^c)}$ —— $P(l_i, l_j | \mathbf{X}^f, \Theta^c)$ 分布下的 $\delta(l_i = l_j)$ 平均值

模型训练的流程图如图 2 所示。

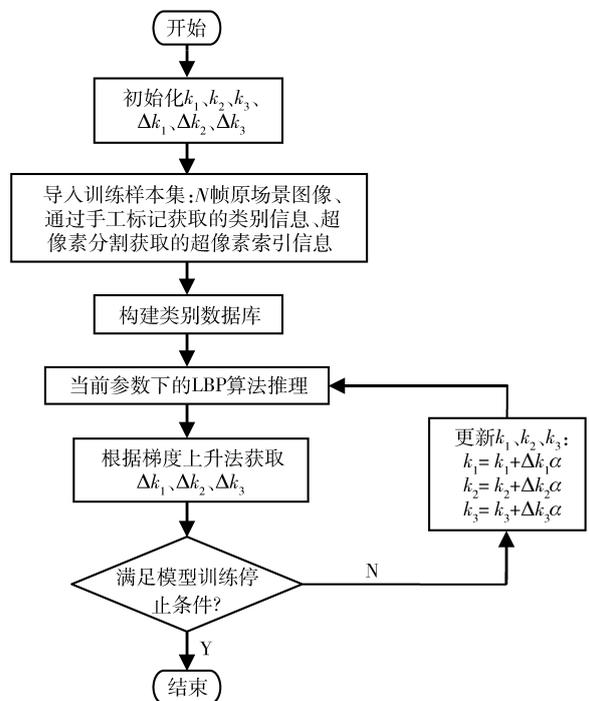


图 2 模型训练流程图

Fig. 2 Flow chart for model training

其中,初始化时令 $k_1, k_2, k_3, \Delta k_1, \Delta k_2, \Delta k_3$ 取值为零, N 为训练样本集帧数,根据梯度上升法推导所得式(6)、(7)、(8)获得 $\Delta k_1, \Delta k_2, \Delta k_3$,模型训练停止条件为 $\Delta k_1, \Delta k_2, \Delta k_3$ 绝对值之和小于某一阈值或者 $\Delta k_1, \Delta k_2, \Delta k_3$ 更新次数达到模型训练最大次数 N_{\max} , α 为学习率,根据经验获取。

3.3 模型推断

超像素的类别分类基于最大后验边缘概率准则(Maximum posterior marginal, MPM)

$$\hat{l}_i = \arg \max_{l_i} \left[\sum_{L \setminus l_i} \frac{1}{Z} \exp \left(\sum_{i \in S} \phi_i(l_i, \mathbf{X}) + \sum_{i \in S} \sum_{j \in N_i} \phi_{ij}(l_i, l_j, \mathbf{X}) \right) \right] \quad (9)$$

其中, $L \setminus l_i$ 为不包含超像素 i 的其余超像素集合,超像素的后验概率通过环状置信传播(Loopy belief propagation, LBP)算法^[19]计算。

4 实验结果与分析

在南京农业大学江浦农场园艺站离线采集梨园图像,分辨率为 320 像素 \times 240 像素。采用 Visual C++ 6.0 编写算法程序。

样本数据类别通过手工标记获取,所选样本场景中包含树干、树叶、杂草、地面、天空等内容,其中树干、树叶为梨树类,杂草、地面、天空归为非梨树类。实验中训练样本集帧数 N 取值为 20,模型训练最大次数 N_{\max} 取值为 25,根据图 2 所示训练流程图获取条件随机场模型参数。同时,为突出本算法利用图像空间上下文信息进行梨园

场景分割的性能,将本文算法与 MKNN^[18]算法对同一场景获取的实验结果进行对比,如图 3 所示。

从整体上看,CRF 能够将场景中的梨树与地面上的杂草正确分类,CRF 分割结果要优于 MKNN。图 3 中前 2 个为光照非均匀分布场景。图像中地面上存在阴影,使地面上的杂草分为阴影区杂草跟非阴影区杂草。本文提出的算法由于使用了图像空间上下文信息,利用了阴影区杂草的邻域超像素类别信息以及颜色信息,能够将地面上阴影区杂草和非阴影区杂草正确分类。MKNN 算法进行分类时,只使用了场景中颜色特征信息,使得阴影区杂草分类出错。从而表明,本算法能更好地适应不同光照条件下的梨园场景应用。

第 3 个场景具有地面出现大面积杂草区域、梨树分布随机性很大等特性。本算法所示结果表明,由于利用了邻域超像素的类别信息以及颜色信息,能够将场景中存在的梨树正确分割出来。而 MKNN 算法对于连片杂草区域(不论远处的连片杂草区域,还是近处的连片杂草区域)出现了严重的错分。从而表明本算法对于梨园中杂草的随机性分布具有很好的适应能力。

图 3 后 2 个场景为农业机器人即将行进到田头,图像内容出现严重突变,梨树区域减少,天空面积增大。本算法表现依旧好于 MKNN 算法所得结果。从而表明本算法对梨园中田头场景分割具有很好的鲁棒性,从而为自主导航中的田头转向提供有用信息。

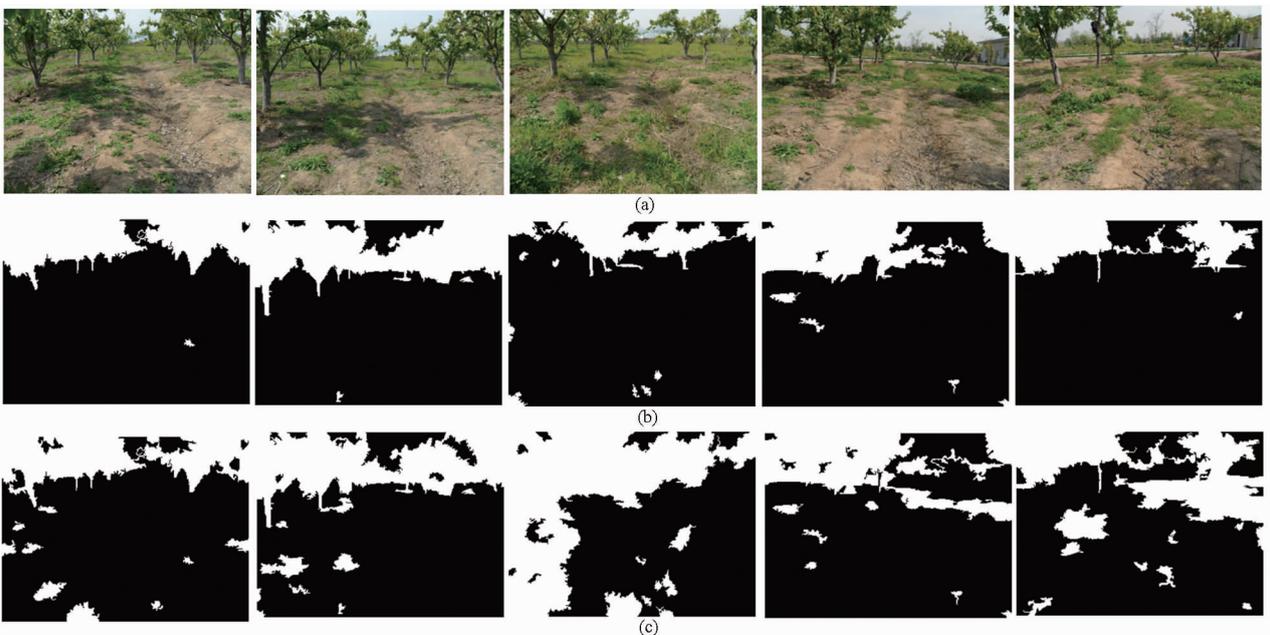


图 3 实验结果

Fig. 3 Experimental results

(a) 梨园场景原图 (b) CRF 分割结果 (c) MKNN 分割结果

5 结束语

针对梨园自然场景梨树分割问题,提出了一种以超像素作为图像处理单元,利用 CRF 对场景特征与空间关系建模,使用图像中颜色特征信息和空间

上下文信息对场景图像进行分割。对比实验结果表明,本文提出的算法对于梨园场景中的光照不均匀分布、杂草分布随机性、田头场景内容突变等因素都具有很好分割结果,从而说明本文所提出的算法对于梨园自然环境具有很好的适应性。

参 考 文 献

- 1 Sridevi M, Mala C. A survey on monochrome image segmentation methods[J]. *Procedia Technology*, 2012,6:548 – 555.
- 2 林开颜,吴军辉,徐立鸿. 彩色图像分割方法综述[J]. *中国图象图形学报*,2005,10(1):1 – 10.
Lin Kaiyan, Wu Junhui, Xu Lihong. A survey on color image segmentation techniques[J]. *Journal of Image and Graphics*, 2005, 10(1):1 – 10. (in Chinese)
- 3 许新征,丁世飞,史忠植,等. 图像分割的新理论和新方法[J]. *电子学报*,2010,38(2A):76 – 82.
Xu Xinzheng, Ding Shifei, Shi Zhongzhi, et al. New theories and methods of image segmentation[J]. *Acta Electronica Sinica*, 2010,38(2A):76 – 82. (in Chinese)
- 4 周俊,王明军,邵乔林. 农田图像绿色植物自适应分割方法[J]. *农业工程学报*,2013,29(18):163 – 170.
Zhou Jun, Wang Mingjun, Shao Qiaolin. Adaptive segmentation of field image for green plants[J]. *Transactions of the CSAE*, 2013,29(18):163 – 170. (in Chinese)
- 5 徐胜军,韩九强,刘光辉. 基于马尔可夫随机场的图像分割方法综述[J]. *计算机应用研究*,2013,30(9):2576 – 2582.
Xu Shengjun, Han Jiuqiang, Liu Guanghui. Survey of image segmentation methods based on Markov random fields[J]. *Application Research of Computers*, 2013,30(9):2576 – 2582. (in Chinese)
- 6 Jain K, Murthy N. Data clustering: a review[J]. *ACM Computing Surveys*,1999,31(3):264 – 323.
- 7 田莹,苑玮琦. 遗传算法在图像处理中的应用[J]. *中国图象图形学报*,2007,12(3):389 – 396.
Tian Ying, Yuan Weiqi. Application of genetic algorithm in image processing[J]. *Journal of Image and Graphics*, 2007,12(3):389 – 396. (in Chinese)
- 8 杨志明,王晓蓉,彭军,等. BP 神经网络在图像分割中的应用[J]. *计算机科学*,2007,34(3):234 – 236.
Yang Zhiming, Wang Xiaorong, Peng Jun, et al. The application of BP neural networks in image segmentation[J]. *Computer Science*, 2007,34(3):234 – 236. (in Chinese)
- 9 潘晨,闫相国,郑崇勋,等. 用于彩色图像分割的支持向量机的快速训练[J]. *模式识别与人工智能*,2005,18(4):392 – 398.
Pan Chen, Yan Xiangguo, Zheng Chongxun, et al. Fast training of SVM for color image segmentation[J]. *Pattern Recognition and Artificial Intelligence*, 2005,18(4):392 – 398. (in Chinese)
- 10 钟平. 面向图像标记的随机场模型研究[D]. 长沙:国防科学技术大学,2008.
Zhong Ping. Research on random fields model faced for image label[D]. Changsha: National University of Defense Technology, 2008. (in Chinese)
- 11 王春瑶,陈俊周,李炜. 超像素分割算法研究综述[J]. *计算机应用研究*,2014,31(1):6 – 11.
Wang Chunyao, Chen Junzhou, Li Wei. Superpixel segmentation algorithms review[J]. *Application Research of Computers*, 2014,31(1):6 – 11. (in Chinese)
- 12 韩守东,赵勇,陶文兵,等. 基于高斯超像素的快速 Graph Cuts 图像分割方法[J]. *自动化学报*,2011,37(1):11 – 20.
Han Shoudong, Zhao Yong, Tao Wenbing, et al. Gaussian super-pixel based fast image segmentation using Graph Cuts[J]. *Acta Automatica Sinica*, 2011,37(1):11 – 20. (in Chinese)
- 13 张微,汪西莉. 基于超像素的条件随机场图像分类[J]. *计算机应用*,2012,32(5):1272 – 1275,1279.
Zhang Wei, Wang Xili. Superpixel-based conditional random field for image classification[J]. *Journal of Computer Applications*, 2012,32(5):1272 – 1275,1279. (in Chinese)
- 14 Felzenszwalb P F, Huttenlocher D P. Efficient graph-based image segmentation[J]. *International Journal of Computer Vision*, 2004,59(2):167 – 181.
- 15 Lafferty J, McCallum A, Pereira F. Conditional random fields: probabilistic models for segmenting and labeling sequence data [C]//*Proceedings of the 18th International Conference on Machine Learning*,2001:282 – 289.
- 16 赵龙,郭立,谢锦生. 条件随机场模型的场景描述[J]. *中国图象图形学报*,2013,18(3):271 – 276.
Zhao Long, Guo Li, Xie Jinsheng. Scene description based on the conditional random fields model[J]. *Journal of Image and Graphics*, 2013,18(3):271 – 276. (in Chinese)
- 17 王明军,周俊,屠珺,等. 基于条件随机场的大范围地形感知框架[J]. *机器人*,2010,32(3):326 – 333.
Wang Mingjun, Zhou Jun, Tu Jun, et al. Long-range terrain perception based on conditional random fields[J]. *Robot*, 2010, 32(3):326 – 333. (in Chinese)
- 18 Kim D, Oh S M, Rehg J M. Traversability classification for UGV navigation: a comparison of patch and superpixel representations [C]//*IEEE International Conference on Intelligent Robots and Systems*,2007:3166 – 3173.
- 19 Frey B J, MacKay D J C. A revolution: Belief propagation in graphs with cycles[J]. *Advances in Neural Information Processing Systems*, 1997, 10:479 – 485.