

# 基于图像多尺度分解的前景提取

王斌, 何坤, 王丹

(四川大学计算机学院, 成都 610065)

**摘要:** 为了弥补纹理对传统 GrabCut 提取结果的负面影响, 本文分析了图像边缘和颜色分布的尺度特性, 结合图像多尺度分解和 GrabCut, 提出了基于图像多尺度分解的前景提取模型。首先, 该模型运用全变分对图像进行多尺度分解得到一系列平滑图像, 该分解保护了图像边缘并平滑了纹理, 压缩了图像区域颜色的分布范围; 其次, 将给定平滑图像前景颜色分布表示为高斯混合模型, 并运用直方图形状分析方法优化了高斯混合模型的高斯函数个数, 弥补了传统固定高斯函数个数的负面影响; 最后, 根据不同平滑图像的分割结果设计了迭代终止条件, 使得从适当的分解尺度中提取前景。与传统前景提取算法相比较, 该模型降低了纹理对前景提取的负面影响, 其测评分数高于传统算法。

**关键词:** 前景提取; 多尺度分解; 直方图形状分析; 分解尺度

中图分类号: TP391 文献标识码: A DOI: 10.19907/j.0490-6756.2021.032001

## A foreground extraction model on image multiscale decomposition

WANG Bin, HE Kun, WANG Dan

(College of Computer Science, Sichuan University, Chengdu 610065, China)

**Abstract:** In order to make up for the negative impact of texture on the extraction results of the traditional GrabCut model, this paper analyzes the scale characteristics of the image edge and color distribution, and combines the image multiscale decomposition and GrabCut to propose a foreground extraction model based on image multi-scale decomposition. This model firstly decomposes an image into a series of smoothed images with the total variation regularization. In this decomposition process, the image edges are preserved, the textures are smoothed, and the color distribution range of the image regions is compressed. Secondly, the foreground color distribution of the given smoothed image is represented with the Gaussian mixture model, and the histogram shape analysis method is used to optimize the number of Gaussians in the Gaussian mixture model, which makes up for the negative effects caused by the fixed number of Gaussians. Finally, an iterative termination condition is designed according to the segmentation results of different smoothed images. Thus the foreground can be extracted from the appropriate decomposition scale. Compared with the traditional foreground extraction algorithm, this model reduces the negative effect of texture on foreground extraction, and the evaluation scores are higher than the traditional algorithms.

**Keywords:** Foreground extraction; Multiscale decomposition; The histogram shape analysis method; Decomposition scale

收稿日期: 2020-07-20

基金项目: 四川省科技支撑计划项目(2016JZ0014)

作者简介: 王斌(1994—), 男, 四川巴中人, 硕士研究生, 研究方向为图像处理. E-mail: 2522159881@qq.com

通讯作者: 何坤. E-mail: hekun@scu.edu.cn

# 1 引言

图像前景是指图像中用户感兴趣的语义对象,该对象是分析和理解图像内容的基础。由于图像内容理解受限于用户认知,因此其前景因人而异。为了提取用户指定的前景,研究者结合用户交互,根据图像低层特征提出了大量的算法,如随机游走<sup>[1]</sup>,水平集方法<sup>[2-4]</sup>和图论技术<sup>[5]</sup>等。然而,图像中的纹理、弱边缘和低对比度使得现有算法难以得到理想结果。

近年来,深度学习<sup>[6-7]</sup>通过训练卷积神经网络自适应地从训练集中挖掘图像的多尺度特征,并成功应用于图像前景提取。但是,深度学习需要海量的前景样本训练神经网络参数,而实际上,前景样本数量是有限的,这导致深度学习的前景提取效果较差。同时,该方法不能成功提取训练集中未包含的前景,因为缺乏学习样本。

基于图论的前景提取模型利用图像边缘和前、背景颜色分布构建了能量泛函,运用割图算法从图像中提取前景。现有前、背景颜色分布模型可分为局部直方图<sup>[8-9]</sup>和高斯混合模型<sup>[10]</sup>,前者虽然显式表示为前、背景像素的亮度分布,但其准确性依赖于人机交互量和图像亮度分布。相比于前者,高斯混合模型极大简化了用户交互量,它将前、背景像素颜色分布表示为固定个数的高斯函数加权和<sup>[10]</sup>。每个区域的像素分布对应一个高斯函数,其参数在前景提取过程中估计区域像素的一阶原点矩和二阶中心矩。高斯混合模型可有效刻画卡通图像的前、背景颜色分布,但对于自然图像其准确性受到纹理的负面影响。其原因是:1) 纹理加剧了区域颜色变化,降低了二阶中心矩估计精度;2) 纹理恶化了区域间颜色的显著差异,减少了不同区域的一阶原点矩的距离;3) 固定高斯个数导致了高斯混合模型负面影响。针对 1) 和 2),文献[11]引入了基于超像素抑制了纹理对前景提取的影响,针对 3) 文献[12]在分割之前使用聚类算法分析前景和背景中的区域数目,避免了不恰当高斯个数对前景提取的负面影响。

基于割图的方法利用边缘和区域分布特征提取前景,但提取质量敏感于特征尺度,即细尺度的局部最优和粗糙尺度较差的提取精度。为了从恰当尺度提取前景,本文将割图与多尺度分解相结合,运用全变分正则化<sup>[13]</sup>将一副图像分解为一系列平滑图像。该平滑模型既保护了图像边缘,又消除了

区域非均匀性,有助于提升区域分布参数估计准确性。对于每个平滑图像,前、背景颜色分布分别表示为优化的高斯混合模型(即 OGMMs)。在每个 OGMMs 中,运用直方图形状分析方法估计高斯函数个数。结合 OGMMs 和多尺度分解,本文将前景提取任务转换为分割和分解尺度的联合优化,通过分割和多尺度分解的交互,从适当的尺度提取前景。

## 2 本文模型

人眼观察图像时,图像信息被理解为一定尺度上有意义的内容。因此,我们将一幅图像分解成一系列具有不同分解尺度的平滑图像,保留了图像的边缘并消除了图像非均匀性。对于每个平滑图像,采用直方图形状分析方法对其颜色分布进行准确建模。结合 GrabCut 和平滑图像的颜色分布模型,将前景提取转换为分割和分解尺度的联合优化。一副具有  $N$  个像素的图像  $\mathbf{u}^0 : \Omega \rightarrow (\mathbf{u}_R, \mathbf{u}_G, \mathbf{u}_B)$  被初始矩形框划分为背景区域  $T_B$  和带有少量背景像素的前景区域  $T_F$ 。分割结果表示为  $\mathbf{x} = (x_1, \dots, x_i, \dots, x_N)$ , 其中,  $x_i = 1$  表示前景,  $x_i = 0$  表示背景。其前景提取的能量泛函为

$$\mathbf{x}^* = \operatorname{argmin}_{\mathbf{x}, \boldsymbol{\omega}, \mathbf{u}} \{ \alpha M(\mathbf{u}, \mathbf{u}^0) + \beta S(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u}) \} \quad (1)$$

式中,第一项  $M(\mathbf{u}, \mathbf{u}^0)$  是图像多尺度分解,  $\mathbf{u}$  为平滑图像; 第二项为平滑图像的前景提取,  $\boldsymbol{\omega}$  表示前、背景颜色分布参数, 该项  $S(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u})$  表示为

$$S(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u}) = U(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u}) + V(\mathbf{x}, \mathbf{u}) \quad (2)$$

式中,  $U(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u})$  为参数  $\boldsymbol{\omega}$  下  $\mathbf{x}$  对平滑图像  $\mathbf{u}$  的分割结果评价;  $V(\mathbf{x}, \mathbf{u})$  定义为将分割曲线放置在前景边界上的惩罚,如下式

$$V(\mathbf{x}, \mathbf{u}) = \sum_{i=1}^N \sum_{j \in \Lambda_i} \frac{\gamma [x_i \neq x_j]}{\operatorname{dis}(i, j)} \exp(-\beta(u(i) - u(j))^2) \quad (3)$$

式中,  $\Lambda_i$  是第  $i$  个像素的相邻像素集;  $\operatorname{dis}(\cdot)$  表示像素对的欧几里得距离;  $[\cdot]$  是指示函数。根据文献[5],本文  $\gamma = 50$ 。为确保式(3)的能量在低梯度时较大,而在高梯度时较小,其  $\beta$  如下式。

$$\beta = 0.5 \langle (u(i) - u(j))^2 \rangle^{-1} \quad (4)$$

式中,  $\langle \cdot \rangle$  表示均值。

### 2.1 多尺度分解

式(1)的最优解依赖于平滑图像的颜色分布参数,但该参数对分解尺度敏感。如,在细尺度平滑图像中,残留的纹理信息导致参数估计精度较差。在粗糙尺度上,图像被过度平滑,估计的参数不能近

似颜色分布。为了获得具有适当尺度的颜色分布模型,我们根据全变分正则化将图像分解为一系列平滑图像,即最小化下述问题。

$$M(\mathbf{u}, \mathbf{u}^0) = \frac{\lambda}{2} \int_{\Omega} (\mathbf{u} - \mathbf{u}^0)^2 d\Omega + \int_{\Omega} |\nabla \mathbf{u}| d\Omega \quad (5)$$

式中,第一项为数据保真项,用于保护图像边缘特征;第二项为正则项,用于平滑图像非均匀区域; $\lambda$ 为保边平滑参数。假设(5)存在最小解,其解满足欧拉-拉格朗日方程。

$$\lambda(\mathbf{u} - \mathbf{u}^0) - \operatorname{div}\left(\frac{\nabla \mathbf{u}}{|\nabla \mathbf{u}|}\right) = 0 \quad (6)$$

运用后向差分方法和固定点迭代算法,平滑图像 $\mathbf{u}^k(i)$ 可离散计算为

$$\begin{aligned} \mathbf{u}^k(i) &= \frac{1}{\lambda + \sum_{j \in \Delta_i} \bar{\omega}^k(j)} (\lambda \mathbf{u}^0(i) + \\ &\quad \sum_{j \in \Delta_i} \bar{\omega}^k(j) \mathbf{u}^{k-1}(j)) \end{aligned} \quad (7)$$

其中,

$$\bar{\omega}^k(j) = |\nabla \mathbf{u}^{k-1}(j)|^{-1} \quad (8)$$

在式(7)中,平滑图像 $\mathbf{u}^k$ 依赖于 $\mathbf{u}^0$ 和 $\mathbf{u}^{k-1}$ ,前者有利于保留图像边缘,而后者则有利于平滑非均匀区域。通过迭代计算,图像被分解为一系列平滑图像。随着迭代次数的增加,分解尺度不断增加,图像中非均匀区域也会逐渐趋于平滑。

## 2.2 优化的高斯混合模型

假设平滑图像中每个区域颜色分布紧凑,区域颜色分布可表示为高斯函数。以第 $m$ 个区域为例:

$$\begin{aligned} G(\boldsymbol{\mu}_m, \sum_m, \mathbf{u}(i)) &= \\ &\frac{\exp(-0.5(\mathbf{u}(i) - \boldsymbol{\mu}_m)^T \sum_m^{-1}(\mathbf{u}(i) - \boldsymbol{\mu}_m))}{\sqrt{(2\pi)^3 \det(\sum_m)}} \end{aligned} \quad (9)$$

式中, $\boldsymbol{\mu}(m)$ 和 $\sum(m)$ 分别是该区域颜色分布的均值向量和协方差矩阵。假设前景和背景中区域个数已知,前景和背景表象可表示为高斯混合模型。其参数 $\boldsymbol{\omega} = \{\boldsymbol{\omega}_F, \boldsymbol{\omega}_B\}$ 为

$$\begin{cases} \boldsymbol{\omega}_F = \{n_F, \pi_m^F, \boldsymbol{\mu}_m^F, \sum_m^F, m = 1, \dots, n_F\} \\ \boldsymbol{\omega}_B = \{n_B, \pi_m^B, \boldsymbol{\mu}_m^B, \sum_m^B, m = 1, \dots, n_B\} \end{cases} \quad (10)$$

式中, $\pi(m)$ 表示第 $m$ 个区域的面积系数; $n_F$ 和 $n_B$ 分别表示前、背景区域个数。

实际上前、背景包含的区域个数并非已知,传

统方法常常采用固定个数。为了弥补固定个数对前景提取的负面影响,本文分析平滑图像亮度直方图形状与图像区域个数之间的关系:直方图的每个波峰表示图像区域亮度分布,如由两个或多个均匀区域构成的图像,其亮度直方图形状为双峰或多峰,相邻峰之间的波谷对应的亮度可用于图像区域分割的阈值。由于在平滑图像中存在残余的纹理,其亮度直方图形状通常存在许多局部最小值,即伪谷。为了去除伪谷并保护波峰,本文运用中值滤波进行平滑处理,平滑后的直方图为 $H^s = (H_0^s, H_1^s, \dots, H_{255}^s)$ 。

为了检测直方图形状波谷,本文分析直方图 $H^s$ 后向差分的符号,其符号 $\operatorname{Sgn}(\cdot)$ ,如下式。

$$\operatorname{Sgn}(i) = \begin{cases} 1, \delta(H_i^s) > 0 \\ 0, \delta(H_i^s) = 0 \\ -1, \delta(H_i^s) < 0 \end{cases} \quad (11)$$

$\delta(\cdot)$ 是后向差分算子,且波谷处亮度为

$$v_n = \frac{i+j-1}{2}, \quad \begin{array}{l} \text{if } \operatorname{Sgn}(i) = -1, \operatorname{Sgn}(j) = 1, \\ \operatorname{Sgn}(k) = 0, \text{and } k \in (i, j) \end{array} \quad (12)$$

利用波谷 $v = (v_1, v_2, \dots, v_n)$ 将图像分为 $n$ 个区域,结合分割曲线可计算出前景和背景中区域个数。在已知参数 $\omega$ 的前提下,像素 $\mathbf{u}(i)$ 属于前景或背景的可能性为

$$\begin{cases} L_F(x, \omega_F, \mathbf{u}(i)) = \max\{\pi_m^F G(\boldsymbol{\mu}_m^F, \sum_m^F, \mathbf{u}(i))\}, \\ (m = 0, 1, \dots, n_F) \\ L_B(x, \omega_B, \mathbf{u}(i)) = \max\{\pi_m^B G(\boldsymbol{\mu}_m^B, \sum_m^B, \mathbf{u}(i))\}, \\ (m = 0, 1, \dots, n_B) \end{cases} \quad (13)$$

式(2)中数据项 $U(\cdot)$ 可计算为

$$U(\mathbf{x}, \boldsymbol{\omega}, \mathbf{u}) = \sum_{i \in T_F} (-\log(L_F(x, \omega_F, u(i))) - \log(L_B(x, \omega_B, u(i)))) \quad (14)$$

## 2.3 前景提取算法

在式(1)中,如果 $\alpha \rightarrow 0$ ,该模型等效于原始图像的前景提取;如果 $\beta \rightarrow 0$ ,该式简化为多尺度分解。为了抑制纹理对前景提取质量的影响,本文设置 $\alpha = \beta = 1$ 。式(1)可简化为

$$x^* = \operatorname{argmin}_{\mathbf{x}} \min_{\omega^k} \{M(\mathbf{u}^k, \mathbf{u}^0) + V(\mathbf{x}, \mathbf{u}^k) + U(x, \omega^k, \mathbf{u}^k)\}, \quad k = 0, 1, \dots \quad (15)$$

(15)式的最优结果可以通过分割和颜色分布参数的交替优化得到,如图1所示。对于给定平滑图像 $\mathbf{u}^k$ , (15)式中 $V(\mathbf{x}, \mathbf{u}^k)$ 仅需计算一次且可以重复使

用。由于前景区域中存在一些背景像素,前景提取过程中应更新数据项  $U(\mathbf{x}, \boldsymbol{\omega}^k, \mathbf{u}^k)$ 。因此,(15)式的最优解通过交替执行以下步骤得到:(1) 给定颜色分布参数  $\boldsymbol{\omega}$ ,利用最大流算法<sup>[14]</sup>计算分割结果  $\mathbf{x}$ ;(2) 给定分割结果  $\mathbf{x}$ ,运用 EM 算法更新参数  $\boldsymbol{\omega}$ 。在此交替优化过程中,参数  $\boldsymbol{\omega}$  的估计精度得到进一步的提升,前景区域中的背景像素被逐渐剔除,其能量逐步降低并趋于收敛,如图 1(b)所示。为了评价每个平滑图像的前景提取性能,本文基于相邻尺度上提取的前景定义了一个相似性指标,如下。

$$Sm(k) = \frac{\text{card}(T_F^k \cap T_F^{k-1})}{\text{card}(T_F^k \cup T_F^{k-1})} \quad (16)$$

式中,  $\text{card}(\cdot)$  统计像素点个数。

(15)式的最优解不仅依赖于平滑图像的边缘和颜色分布,还取决于分解尺度。在细尺度下,图像

中残余的非均匀性导致前、背景颜色分布参数估计精度较差。随着分解尺度增大,残余非均匀性被逐渐消除,前景边界得到保留,提取性能不断提升,相似度保持不减。在粗尺度下,图像被过度平滑,使前景和背景之间产生伪重叠效应,提取性能较差,相似性不增,如图 1(e)所示。根据相似性随分解尺度的变化,本文在满足下述约束条件时找到合适的尺度进行前景提取。

$$Sm(k) \leq Sm(k-1) \quad (17)$$

本文将图像分解为一系列平滑图像,对每幅平滑图像首先运用直方图形状分析方法估计前景和背景的区域数目,然后通过分割和颜色分布参数的交替优化提取前景。根据相邻尺度上分割结果计算其相似性,当满足迭代终止条件时算法停止,其算法流程如图 2 所示。

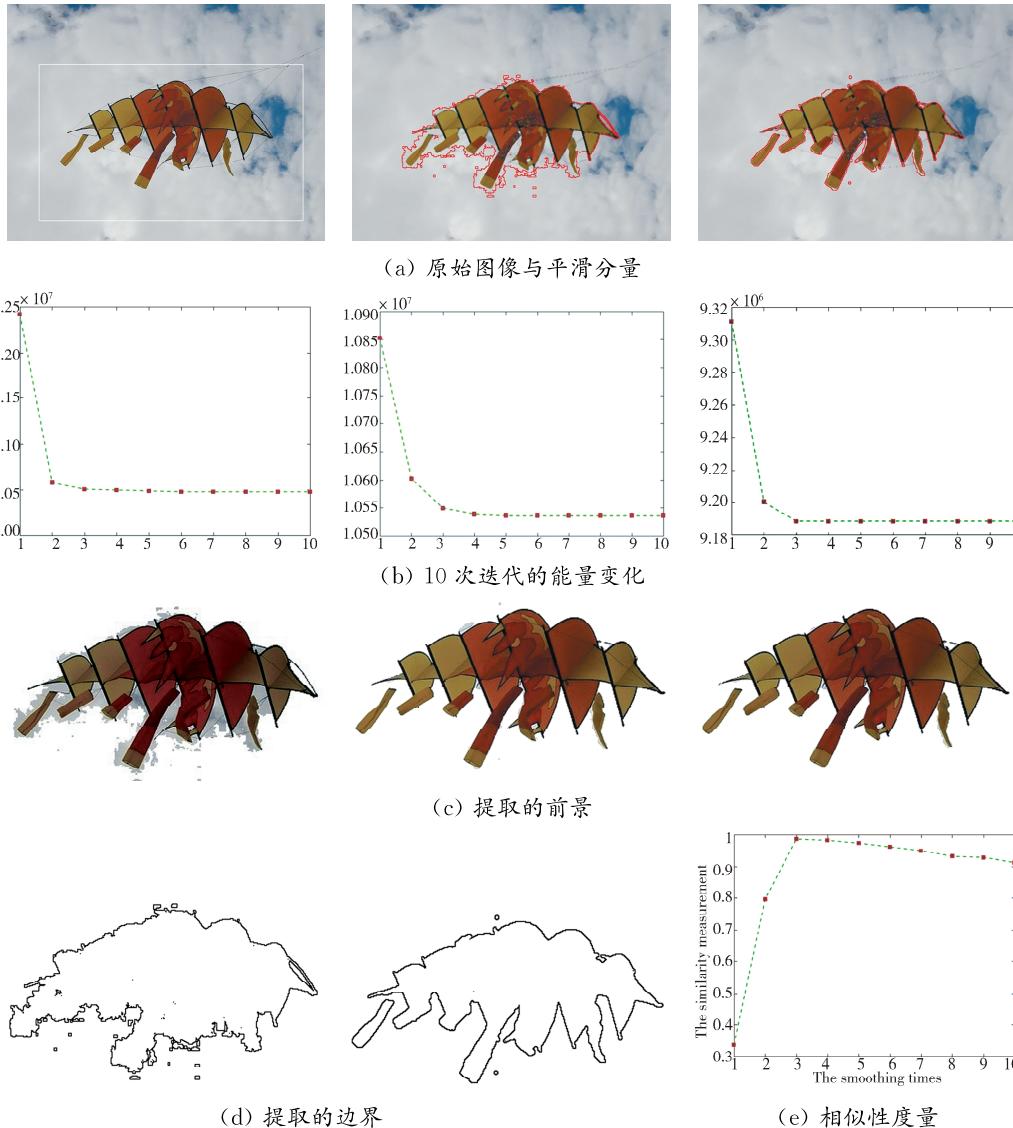


图 1 本文模型的前景提取过程  
Fig. 1 Process of foreground extraction by the proposed model

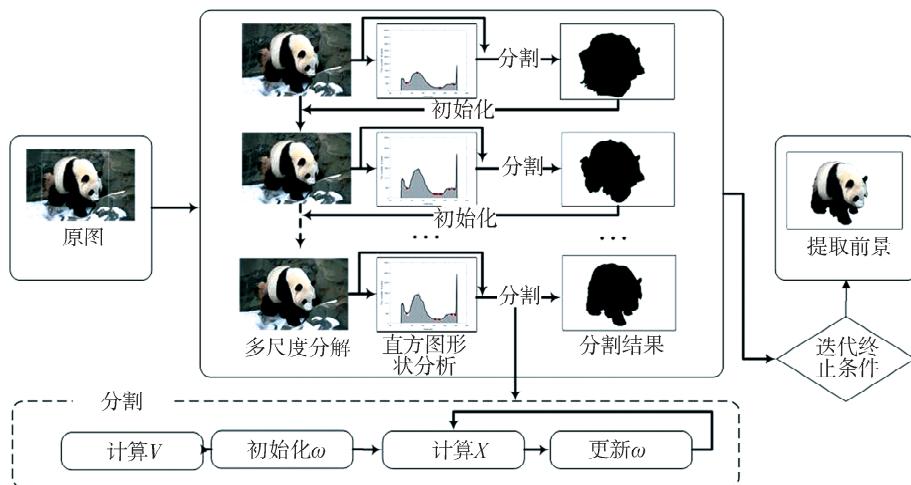


图2 本文模型的流程  
Fig. 2 The flowchart of the proposed model

### 3 实验及分析

基于多尺度分解的前景提取模型由图像分解和GrabCut两部分构成,在图像分解过程中引入参数 $\lambda$ 。为了分析参数 $\lambda$ 对前景提取性能的影响,对一副来自BSD300数据集的 $480 \times 320$ 像素图像选用不同的 $\lambda$ 值进行平滑处理,部分平滑图像以及对应的分割结果如图3所示。当 $\lambda=100.0$ 时,平滑图像中残余的非均匀性导致过分割现象,如图3(b)所示。当 $\lambda=0.001$ 时,图像被过度平滑从而导致欠分割效果,如图3(d)所示。不同参数 $\lambda$ 平滑处

理图像的前景提取评测分数如表1所示。依据表1,该参数在接近0.1时取得较为理想的结果。

表1 不同参数 $\lambda$ 的评测分数

Tab. 1 The evaluation scores with different  $\lambda$

评测指标	参数 $\lambda$					
	0.001	0.01	0.1	1.0	10.0	100.0
准确率	0.990	0.992	0.993	0.982	0.968	0.936
召回率	0.923	0.929	0.950	0.951	0.954	0.956
F-测度	0.955	0.959	0.970	0.966	0.961	0.946



图3 不同参数 $\lambda$ 的前景提取结果

Fig. 3 Results of foreground extraction using the proposed model with different  $\lambda$

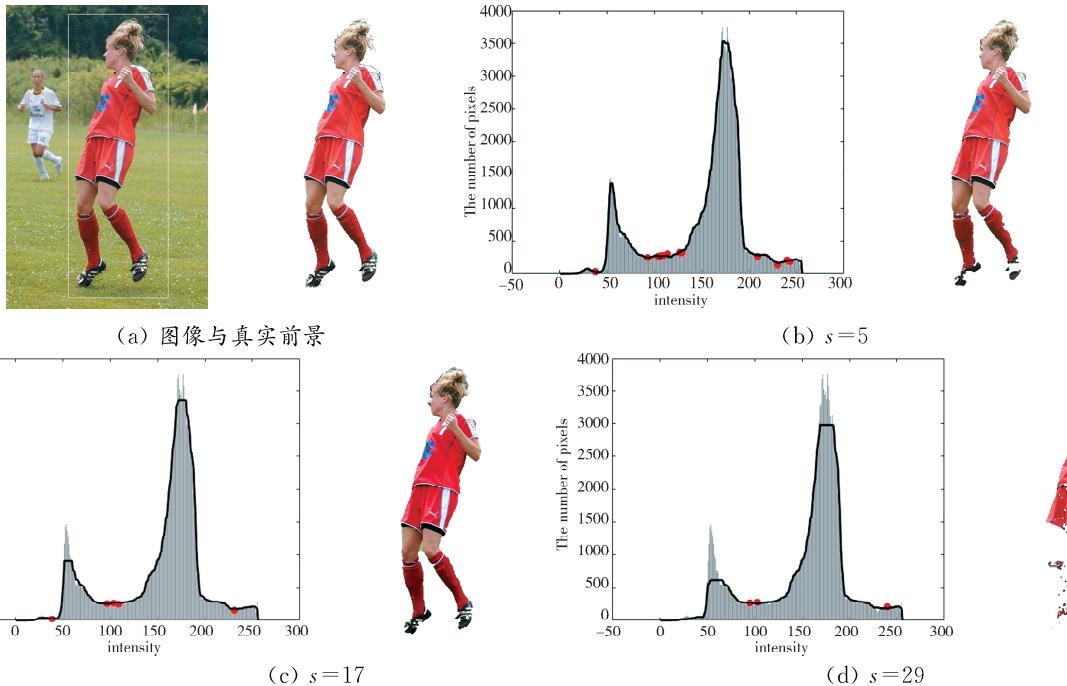
为了抑制纹理对平滑图像前、背景中区域个数估计的影响,本文运用中值滤波对平滑图像亮度直方图平滑处理。为了分析中值滤波参数 $s$ 对前景提取性能的影响,对一副来自iCoseg数据集的 $332 \times$

500像素的人物图像选用不同的 $s$ 值进行直方图形状分析,部分前景提取结果如图4所示。当 $s=5$ 时,平滑后的直方图中仍然存在大量伪谷,导致前景提取效果较差,如图4(b)所示。当 $s=29$ 时,存在

多个区域被错误合并为一个区域,降低了前景提取效果,如图 4(d)所示。不同参数  $s$  滤波处理图像的前景提取评测分数如表 2 所示。依据表 2,该参数取为 17。

表 2 不同参数  $s$  的评测分数Tab. 2 The evaluation scores with different  $s$ 

评测指标	参数 $s$				
	5	11	17	23	29
准确率	0.992	0.988	0.987	0.990	0.989
召回率	0.932	0.950	0.959	0.589	0.573
F-测度	0.961	0.969	0.972	0.739	0.726

图 4 不同参数  $s$  的前景提取结果Fig. 4 Results of foreground extraction using the proposed model with different  $s$ 

为了测评本文算法的有效性,并与传统 GrabCut<sup>[10]</sup>, MIS<sup>[15]</sup>以及 Deep GrabCut<sup>[16]</sup>进行比较,对图 5 所示的自然图像进行前景提取,其评测分数如表 3 所示。其中,GrabCut<sup>[10]</sup>使用固定高斯个数的

高斯混合模型对图像前、背景区域颜色分布进行统计建模,并基于原始图像的参数估计和分割的交替优化提取前景,其前景提取效果受到高斯函数个数以及原始图像中纹理、噪声等的影响。

表 3 图 5 所示图像的评测分数

Tab. 3 The evaluation scores for images in Fig. 5

图像	本文算法			GrabCut			MIS			DeepGrabCut		
	召回率	准确率	F-测度	召回率	准确率	F-测度	召回率	准确率	F-测度	召回率	准确率	F-测度
图 5(a)	0.994	0.985	0.989	0.984	0.989	0.987	0.975	0.987	0.981	0.982	0.966	0.974
图 5(b)	0.995	0.904	0.947	0.373	0.987	0.541	0.995	0.845	0.914	0.874	0.935	0.904
图 5(c)	0.987	0.973	0.980	0.418	0.996	0.589	0.923	0.587	0.718	0.797	0.978	0.878
图 5(d)	0.971	0.983	0.977	0.861	0.990	0.921	0.798	0.985	0.882	0.778	0.947	0.854

MIS<sup>[15]</sup>将多尺度分解和水平集算法相结合,在多尺度边缘的约束下提取前景。Deep GrabCut<sup>[16]</sup>将矩形框转换为一个欧式距离图,然后将该图与 RGB 图像组合起来作为卷积编码—解码网络的输入,以前景预测为最终输出。对于近似卡通图像,4 种算法提取的前景在视觉上无差异,如图 5

(a) 所示。然而,与传统 GrabCut 相比,本文运用直方图形状分析方法自适应估计了高斯个数,弥补了传统 GrabCut 采用固定高斯个数的不足,得到了更准确的提取结果,如图 5(b) 所示。此外,本文引入 TV 模型对图像进行保边平滑处理,基于不同尺度的边缘和颜色分布模型从适当的尺度提取前景,

对于含有纹理的图像,本文算法提取结果在视觉上优于GrabCut算法,如图5(c)~5(d)所示。

相对于MIS,本文算法增加了不同分解尺度

的图像颜色分布特征,弥补了利用多尺度边缘特征对含有弱边缘图像前景提取的不足,改善了前景提取效果,如图5(c)所示。



图5 不同算法所提取的结果对比  
Fig. 5 Comparison of results extracted by different algorithms

Deep GrabCut<sup>[16]</sup>在PASCAL数据集上进行训练并学习20种对象的特征,其前景提取性能依赖于该训练集中对象的类别。相比而言,本文基于图像多尺度边缘和颜色分布特征,在提取该训练集不包含的前景时,取得了相对更优的结果,如图5(c)所示。

## 4 结 论

本文提出了基于多尺度分解的前景提取模型,有效克服了图像纹理细节对高斯混合模型参数估计的负面影响;运用直方图形状分析方法弥补了不恰当的高斯数目对前景提取造成的不良影响;结合不同尺度的边缘和区域颜色分布从恰当尺度提取前景。然而,图像多尺度分解过程中只保护了边缘而不能增强弱边缘,因此后续工作设计新的非线性平滑增强弱边缘,进一步提高前景提取质量。

## 参考文献:

- [1] Kang X, Zhu L, Ming A, *et al.* Dynamic random walk for superpixel segmentation [J]. IEEE T Image Process, 2020, 29: 3871.
- [2] Zhang H, Tang L, He C. A variational level set model for multiscale image segmentation [J]. Inform Sciences, 2019, 493: 152.
- [3] 夏欣, 葛龙, 孟宏源. 改进 CV 的图像分割[J]. 四川大学学报: 自然科学版, 2017, 54: 1185.
- [4] 杨秀杰, 李法平. 基于曲率和活动轮廓模型的重叠细胞分割算法[J]. 西南师范大学学报: 自然科学版, 2018, 43: 41.
- [5] Boykov Y Y, Jolly M P. Interactive graph cuts for optimal boundary & region segmentation of objects in n-d images [C]// Proceedings of the 8th IEEE International Conference on Comput Vis. Vancouver: IEEE Computer Society, 2001.
- [6] Xiong K, Kitamura T, Lwamoto Y, *et al.* Semi-automatic segmentation of paranasal sinus from CT images using fully convolutional networks [C]// Proceedings of the 2018 IEEE 7th Global Conference on Consumer Electronics. Nara: IEEE Computer Society, 2018.
- [7] 李顿, 王艳, 马宗庆, 等. 基于 DenseASPP 模型的超声图像分割[J]. 四川大学学报: 自然科学版, 2020, 57: 741.
- [8] Tang M, Gorelick L, Veksler O, *et al.* GrabCut in one cut [C]//Proceedings of the 2013 IEEE International Conference on Computer Vision (ICCV). Sydney: IEEE Computer Society, 2013.
- [9] 全苗, 何坤, 朱志娟. 基于多尺度平滑的前景提取 [J]. 四川大学学报: 自然科学版, 2020, 57: 271.
- [10] Rother C, Kolmogorov V, Blake A. GrabCut: Interactive foreground extraction using iterated graph cuts [J]. ACM T Graphic, 2004, 23: 309.
- [11] Wu S, Nakao M, Matsuda T. SuperCut: superpixel based foreground extraction with loose bounding boxes in one cutting [J]. IEEE Signal Proc Let, 2017, 24: 1803.
- [12] Chen D, Chen B, Mamic G, *et al.* Improved GrabCut segmentation via GMM optimization [C]//Proceedings of the Computing: Techniques and Applications. Canberra: IEEE, 2008.
- [13] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms [J]. Physica D, 1992, 60: 259.
- [14] Kolmogorov V, Zabin R. What energy functions can be minimized via graph cuts? [J]. IEEE T Pattern Anal, 2004, 26: 147.
- [15] Li Y, Feng X. A multiscale image segmentation method [J]. Pattern Recogn, 2015, 52: 332.
- [16] Xu N, Price B, Cohen S, *et al.* Deep GrabCut for object selection [C]//Proceedings of the British Machine Vision Conference. British: BMVA Press, 2017.

### 引用本文格式:

中 文: 王斌, 何坤, 王丹. 基于图像多尺度分解的前景提取[J]. 四川大学学报: 自然科学版, 2021, 58: 032001.  
 英 文: Wang B, He K, Wang D. A foreground extraction model on image multiscale decomposition [J]. J Sichuan Univ: Nat Sci Ed, 2021, 58: 032001.