



(12) 发明专利申请


(10) 申请公布号 CN 105321176 A
(43) 申请公布日 2016. 02. 10

(21) 申请号 201510641080. 3
(22) 申请日 2015. 09. 30
(71) 申请人 西安交通大学
地址 710049 陕西省西安市咸宁路 28 号
(72) 发明人 杨旻 谢明远 刘跃虎
(74) 专利代理机构 西安智大知识产权代理事务
所 61215
代理人 何会侠
(51) Int. Cl.
G06T 7/00(2006. 01)

权利要求书2页 说明书7页 附图2页

(54) 发明名称
一种基于分层高阶条件随机场的图像分割方法

(57) 摘要
一种基于分层高阶条件随机场模型的图像分割方法,首先对目标图像提取多类纹理特征,构建像素级的一元势函数和成对势函数;再使用无监督分割算法获得不同粒度的超像素片段;设计各粒度层对应超像素级的一元势函数和成对势函数;构建分层高阶条件随机场模型;利用人工标记样本,监督学习分层高阶条件随机场模型参数;最后对待测试的图像,经过模型推理获得最终的分割标记结果;本发明采用的分层高阶条件随机场模型融合了图像的多特征纹理信息和多层超像素分割信息,能够有效地提高图像中多目标对象的边界分割准确性。



1. 一种基于分层高阶条件随机场的图像分割方法,其特征在于:在构建条件随机场的底层能量函数方面:首先提取图像的像素级特征,包括纹理特征、颜色特征、尺度不变特征变换特征和局部二值模式特征,利用这些像素级特征训练分类器,把分类器对像素分类的输出值转化为概率表达,构造像素级的一元势函数;再利用邻域像素颜色差异的边界特征定义像素级的成对势函数;在构建条件随机场的中层能量函数方面:首先利用无监督分割算法得到不同分割粒度的超像素分割结果;再提取超像素特征构建超像素级的一元势函数和成对势函数;综合利用图像的像素级的一元势函数和成对势函数以及超像素级的一元势函数和成对势函数构建分层高阶条件随机场模型;进而利用人工标注的样本,通过逐层监督学习的方法估计模型参数;最后对目标图像应用图割算法推理得到最终的图像分割标记。

2. 根据权利要求1所述的一种基于分层高阶条件随机场的图像分割方法,其特征在于:所述的利用无监督分割算法得到不同分割粒度的超像素结果,具体方法为:先将图像从RGB空间转换到LUV颜色空间,利用均值漂移聚类算法,通过选择颜色搜索窗口参数,产生不同分割粒度的三层超像素结果。

3. 根据权利要求1所述的一种基于分层高阶条件随机场的图像分割方法,其特征在于:所述的提取超像素特征构建超像素级的一元势函数:具体方法为:定义超像素的特征响应值为超像素内该特征对应像素点所占的比例,通过该特征响应值训练分类器,并将分类器对超像素分类的输出值转化为概率表达,以此构造超像素级的一元势函数;具体数学模型为:设 x_c 表示某一超像素 c 的特征相应值, x_c^i 表示超像素 c 内第 i 个像素点的标签;为每个超像素寻找占主导比例的标签值赋予 x_c ,

$$x_c = \begin{cases} l, & \max_{i \in c} \frac{|x_c^i = l|}{|x_c|} \geq T, l \in L \\ l_F, & otherwise \end{cases} \quad (5)$$

其中, $|x_c^i = l|$ 表示 x_c 中标签为 l 的像素的个数, $|x_c|$ 表示超像素 c 内的像素的个数; T 是人工设定的阈值,取值大于0.5; l_F 定义为空标签,即不存在主导标签;

构造的超像素级的一元势函数 $\psi_c(x_c)$ 形式如下:

$$\psi_c(x_c) = \begin{cases} |c| \min(-H_l(c) + K, \alpha), & x_c = l \\ |c| \alpha, & x_c = l_F \end{cases} \quad (6)$$

其中, $H_l(c)$ 是超像素 c 的标签被分类器判断为 l 的概率; α 是一个人工设定的截断值常数; $K = \log \sum e^{H_l(c)}$ 是归一化系数。

4. 根据权利要求1所述的一种基于分层高阶条件随机场的图像分割方法,其特征在于:所述的提取超像素特征构建超像素级的成对势函数,具体方法为:首先计算超像素的颜色直方图,以相邻超像素之间归一化颜色直方图的欧氏距离作为超像素间的相似度,并以此构造超像素级的成对势函数;具体数学模型为:所述超像素级的成对势函数 $\psi_{cd}(x_c, x_d)$ 的形式如下:

$$\psi_{cd}(x_c, x_d) = \begin{cases} 0 & \text{if } x_c = x_d \\ g(c, d) / 2 & \text{if } (x_c \text{ or } x_d = l_F) \\ g(c, d) & \text{otherwise} \end{cases} \quad (7)$$

其中, $g(c, d) = |h(x_c) - h(x_d)|^2$; $h(\cdot)$ 是归一化的超像素片段的颜色直方图。

5. 根据权利要求 1 所述的一种基于分层高阶条件随机场的图像分割方法, 其特征在于: 所述的综合利用图像的像素级的一元势函数和成对势函数以及超像素级的一元势函数和成对势函数构建分层高阶条件随机场模型如下:

$$E(x) = \sum_{i \in v} \psi_i(x_i) + \sum_{i \in v, j \in N_i} \psi_{ij}(x_i, x_j) + \sum_{n=1}^3 \psi_{cd}(x_c^{(n)}, x_d^{(n)}) + \psi_c(x_c^{(n)}) \quad (9)$$

其中, $\psi_i(x_i)$ 为像素级一元势函数, $\psi_{ij}(x_i, x_j)$ 为像素级成对势函数, v 表示像素集合, N_i 表示第 i 个像素的相邻像素集合, $\psi_{cd}(x_c^{(n)}, x_d^{(n)})$ 和 $\psi_c(x_c^{(n)})$ 分别表示第 n 层的超像素级的成对势函数和一元势函数。

一种基于分层高阶条件随机场的图像分割方法

技术领域

[0001] 本发明涉及图像分割技术领域,具体涉及一种基于分层高阶条件随机场的图像多目标分割方法。

背景技术

[0002] 图像分割是计算机视觉领域中的一个关键问题。图像分割质量对后续的图像内容分析、模式识别等应用有着重要的影响。目前的图像分割算法主要包括以下几类:1) 基于阈值的图像分割。该类方法适合于目标和背景拥有不同灰度级范围的目标图像。2) 基于区域的图像分割。其思想是依据具有相似特性的像素,通过区域生长与区域合并的图像分割技术。3) 基于形变模型的分割。此类方法需要给出待分割对象的初始封闭分割曲线,再在一些启发式信息的作用下,曲线逐步变形到目标对象的边界处。4) 基于概率图模型的图像分割。针对实际中的噪声图像数据,该类技术利用概率图模型对自然图像中的统计信息以及先验知识准确建模,是目前针对不确定图像数据分割的最有效方法。

[0003] 基于条件随机场的概率图模型图像分割方法已成为图像分割领域一个研究热点。然而,此前方法大多基于像素级特征的条件随机场建模[1],忽略了图像中目标对象的边界信息,分割结果往往过于追求像素间的平滑。毛凌等[2]提出一种新的高阶条件随机场模型,将基于目标检测方法得到的全局形状信息和基于像素级特征的条件随机场模型统一在一个概率模型框架中,同时完成图像分割、目标检测与识别的任务,提升了图像分割的识别率。超像素是对图像的一种中层表示单位,相比于像素具有高层的语义。基于超像素的条件随机场模型[3]的基本思想是,首先通过无监督分割算法将图像过分割成小的区域像素块(超像素),然后以超像素为节点、空间相邻的超像素节点为边连接建立图模型。虽然该方法具有运行速度快的特点,但是类似基于超像素的条件随机场模型[4]通常强制了一个超像素内所有像素的分类标签的一致性,导致了分割结果严重依赖于无监督分割算法的优劣。例如若超像素分割粒度不合适,一个超像素内可能同时包含了不同目标,往往最后的分割准确率还不如基于像素的条件随机场模型。

[0004] [1]McCallum A,Ghamrawi N.Collective Multi-Label Classification. Proceedings of ACM International Conference on Information&Knowledge Managemen, 2005:195-200.

[0005] [2] 毛凌,解梅. 基于高阶条件随机场模型的图像语义分割. 计算机应用研究, 2013,30(11):3514-3517.

[0006] [3] 张微,汪西莉. 基于超像素的条件随机场图像分类. 计算机应用,2012,32(5):1272-1275.

[0007] [4] 吴士林,耿佳佳,朱枫等. 基于区域的多类目标识别与分割算法研究. 中国图象图形学报,2011,16(9):1607-1614.

发明内容

[0008] 为了解决上述现有技术存在的问题,本发明采用一种基于分层高阶条件随机场的图像分割方法,使其能够融合图像的像素级和超像素级的信息。结果显示针对图像的多目标分割,分层高阶模型可以提高分割对象边界的准确性。

[0009] 为达到以上目的,本发明采用如下技术方案:

[0010] 一种基于分层高阶条件随机场的图像分割方法,在构建条件随机场的底层能量函数方面:首先提取图像的像素级特征,包括纹理特征、颜色特征、尺度不变特征变换特征和局部二值模式特征,利用这些像素级特征训练分类器,把分类器对像素分类的输出值转化为概率表达,构造像素级的一元势函数;再利用邻域像素颜色差异的边界特征定义像素级的成对势函数;在构建条件随机场的中层能量函数方面:首先利用无监督分割算法得到不同分割粒度的超像素结果;再提取超像素特征构建超像素级的一元势函数和成对势函数;综合利用图像的像素级的一元势函数和成对势函数以及超像素级的一元势函数和成对势函数构建分层高阶条件随机场模型;进而利用人工标注的样本,通过逐层监督学习的方法估计模型参数;最后对目标图像应用图割算法推理得到最终的图像分割标记。

[0011] 所述的利用无监督分割算法得到不同分割粒度的超像素结果,具体方法为:先将图像从 RGB 空间转换到 LUV 颜色空间,利用均值漂移聚类算法,通过选择颜色搜索窗口参数,产生不同分割粒度的三层超像素结果。

[0012] 所述的提取超像素特征构建超像素级的一元势函数:具体方法为:定义超像素的特征响应值为超像素内该特征对应像素点所占的比例,通过该特征响应值训练分类器,并将分类器对超像素分类的输出值转化为概率表达,以此构造超像素级的一元势函数;具体数学模型为:设 x_c 表示某一超像素 c 的特征相应值, x_c^i 表示超像素 c 内第 i 个像素点的标签;为每个超像素寻找占主导比例的标签值赋予 x_c ,

$$[0013] \quad x_c = \begin{cases} l, & \max_{i \in c} \frac{|x_c^i = l|}{|x_c|} \geq T, l \in L \\ l_F, & otherwise \end{cases} \quad (5)$$

[0014] 其中, $|x_c^i = l|$ 表示 x_c 中标签为 l 的像素的个数, $|x_c|$ 表示超像素 c 内的像素的个数; T 是人工设定的阈值,取值大于 0.5; l_F 定义为空标签,即不存在主导标签;

[0015] 构造的超像素级的一元势函数形式如下:

$$[0016] \quad \psi_c(x_c) = \begin{cases} |c| \min(-H_l(c) + K, \alpha), & x_c = l \\ |c| \alpha, & x_c = l_F \end{cases} \quad (6)$$

[0017] 其中, $H_l(c)$ 是超像素 c 的标签被分类器判断为 l 的概率; α 是一个人工设定的截断值常数; $K = \log \sum e^{H_l(c)}$ 是归一化系数。

[0018] 所述的提取超像素特征构建超像素级的成对势函数,具体方法为:首先计算超像素的颜色直方图,以相邻超像素之间归一化颜色直方图的欧氏距离作为超像素间的相似度,并以此构造超像素级的成对势函数;具体数学模型为:所述超像素级的成对势函数的形式如下:

$$[0019] \quad \psi_{cd}(x_c, x_d) = \begin{cases} 0 & \text{if } x_c = x_d \\ g(c, d) / 2 & \text{if } (x_c \text{ or } x_d = l_F) \\ g(c, d) & \text{otherwise} \end{cases} \quad (7)$$

[0020] 其中, $g(c, d) = |h(x_c) - h(x_d)|_2$; $h(\cdot)$ 是归一化的超像素片段的颜色直方图;

[0021] 所述的综合利用图像的底层像素级能量函数和超像素级能量函数, 构建分层高阶条件随机场模型如下:

$$[0022] \quad E(x) = \sum_{i \in v} \psi_i(x_i) + \sum_{i \in v, j \in N_i} \psi_{ij}(x_i, x_j) + \sum_{n=1}^3 \psi_{cd}(x_c^{(n)}, x_d^{(n)}) + \psi_c(x_c^{(n)}) \quad (9)$$

[0023] 其中, $\psi_i(x_i)$ 为像素级一元势函数, $\psi_{ij}(x_i, x_j)$ 为像素级成对势函数, v 表示像素集合, N_i 表示第 i 个像素的相邻像素集合, n 为超像素层数。

[0024] 本发明与现有技术相比较, 具有如下优点:

[0025] 传统的图像分割方法多数以底层像素级特征为单位构建条件随机场模型, 虽设计了成对势函数作为相邻像素标记的光滑项, 但依然不能保证分割结果对目标边界拟合的光滑性。超像素是图像的中层表示, 能够拟合目标边界, 但由于对图像中目标未知, 超像素粒度即像素块的大小对分割结果有很大的影响。本发明采用了三种不同粒度的超像素预分割结果, 避免了对无监督分割质量的判断, 同时结合了像素级能量函数和超像素级能量函数, 定义了新的分层超像素级的一元势函数和成对势函数。相比于传统的仅基于像素级能量函数或超像素能量函数的分割方法, 本发明的结果能够实现对多目标分割边界的光滑拟合, 获得更理想的分割结果。

附图说明

[0026] 图 1 为本发明基于分层高阶条件随机场图像分割算法流程图。

[0027] 图 2 为不同条件随机场模型在 Sowerby 数据集上的实验结果比较, 其中: 图 2(a) 为原始图像, 图 2(b) 为人工标注的图像, 图 2(c) 是基于像素级能量函数的条件随机场模型的结果, 图 2(d) 为基于超像素级能量函数的条件随机场模型的结果, 图 2(e) 为分层高阶条件随机场模型的结果。

具体实施方式

[0028] 以下结合附图及具体实施例对本发明作进一步的详细描述。

[0029] 1. 图像像素级特征的提取

[0030] (1) 纹理特征

[0031] 本发明采用 Malik 等人提出的基于滤波器组的方法, 先将图像由 RGB 颜色空间转换为 CIE - Lab 颜色空间, 然后使用一个 17 维的多通道多尺度高斯型滤波器组提取每个像素点的纹理信息, 该滤波器组包括不同尺度和通道下的基本高斯型滤波器、X 和 Y 方向的一阶偏导型滤波器以及拉普拉斯型滤波器, 那么每个像素点关联一个 17 维的特征向量, 每个向量中包含了对应像素点的区域纹理信息。最终一个像素点关联一个 17 维的向量, 用该向量作为图像的纹理特征。

[0032] (2) 局部二值模式特征 (Local Binary Patterns, LBP)

[0033] 本发明采用原始的 LBP 算子,从图中提取一个 3*3 的像素窗口,以窗口中心像素的值为阈值,将相邻的 8 个像素的灰度值与其进行比较,如果大于该阈值,则该像素点被标记为 1,否则标记为 0。那么在 3*3 邻域内的 8 个像素点可产生 8 位的二进制数,将这个二进制数作为该窗口的特征,通常将其转换为十进制数,共 256 种。显然,LBP 算子在图像中的每个像素点都可以得到一个 LBP 编码,那么对一幅图像提取其 LBP 算子之后,将获得一个 LBP 特征图。

[0034] (3) 尺度不变特征变换特征 (Scale-Invariant Feature Transform, SIFT)

[0035] 一幅图像的 SIFT 特征向量的生成主要包括四步:尺度空间极值检测、关键点位置及尺度确定、关键点方向确定、特征向量生成。本发明以筛选后的极值点作为关键点,以关键点为中心设定局部区域,用 36 维直方图统计该区域中像素梯度的方向分布,直方图的峰值反映了关键点所处邻域梯度的主方向。以关键点为中心取 8*8 像素的区域,然后在每 4*4 的小块上计算 8 个方向的梯度方向直方图,绘制每个梯度方向的累加值,即可形成一个种子点。每个关键点使用 16 个种子点来描述,这样对于一个关键点就可以产生 128 个数据,即最终形成 128 维的 SIFT 特征向量。此时 SIFT 特征已经去除了尺度变化、旋转等几何形变因素的影响,再将特征向量的长度进行归一化处理,则可以进一步去除光照变化的影响。

[0036] (4) 颜色特征

[0037] 本发明采用 Koen 提出的 Opponent-SIFT 特征,该特征在 SIFT 特征的基础上,融合了图像的 (R, G, B) 颜色信息,对于图像具有更强的描述力。其方法对颜色信息进行编码,使之具有更高的鲁棒性,形式如下:

$$[0038] \quad \begin{pmatrix} O_1 \\ O_2 \\ O_3 \end{pmatrix} = \begin{pmatrix} \frac{R-G}{\sqrt{2}} \\ \frac{R+G-2B}{\sqrt{6}} \\ \frac{R+G+B}{\sqrt{3}} \end{pmatrix} \quad (1)$$

[0039] 式中,分量 O_1 和 O_2 描述了图像的颜色信息,分量 O_3 描述了图像的亮度信息。由于分量 O_1 和 O_2 中存在相减,显然这两个分量对于光照变化是平移不变的,分量 O_3 不具备平移不变性。

[0040] 2. 构造像素级的一元势函数和成对势函数

[0041] (1) 像素级的一元势函数

[0042] 对于纹理特征、颜色特征以及 SIFT 特征,由于其维度较高,为了降低模型的训练和推理的计算代价,首先使用 K-Means 聚类算法对这些特征聚类,然后图像中的每一个像素点均用其最近聚类中心表示,这样,每个图片可以得到四个特征图。LBP 特征由于维度较低,不再对其进行聚类。

[0043] 本发明使用的矩形滤波器是由图像特征类型 f , 聚类中心 t , 矩形区域 r 构成。像素点 i 的响应值 $v_{[t,r]}^f(i)$ 等于以 i 点为中心的区域 r 内特征为 f 、聚类中心为 t 的特征的数量占区域总体像素的比例:

$$[0044] \quad v_{[t,r]}^f(i) = \frac{1}{\text{area}(r)} \sum_{i \in r} [x_i = t] \quad (2)$$

[0045] 设定一个阈值之后,基于该响应值以及设定阈值 θ 可以构建一个弱分类器。这样得到了一组包含了四种特征的弱分类器,每一个分类器都可以在标签集中判断像素的最优标签。

[0046] 由于从训练集图像中提取的弱分类器的数量特别庞大,而且随着待识别物体类别数目、图像数量的增加而急剧增长,为了满足计算要求并使用较少的弱分类器达到较强的识别率,采用 Joint Boosting 算法训练具有较高可信度的强分类器。最后还把强分类器的输出值转化为概率表达,作为条件随机场模型的像素级一元势。

[0047] (2) 像素级的成对势函数

[0048] 通过观察可以看出,相邻像素有很大可能属于同一个类别,构建成对势对于图像分割起到平滑作用,它鼓励条件随机场模型中相邻像素拥有相同的标签。本发明基于 LUV 颜色空间定义条件随机场模型的像素级成对势函数 $\psi_{ij}(x_i, x_j)$, 取对比敏感的 Potts 模型形式,定义如下:

[0049]

$$\psi_{ij}(x_i, x_j) = \begin{cases} 0 & x_i = x_j \\ \theta_p + \theta_v \exp(-\theta_\beta \|I_i - I_j\|^2) & \text{其他} \end{cases} \quad (3)$$

[0050] 其中, I_i 、 I_j 分别为像素 i 、 j 的颜色向量, θ_p 、 θ_v 和 θ_β 是模型参数,其值从大规模数据中学习得到, θ_p 、 θ_v 是常数, θ_β 是一个三维向量,表示颜色的三个分量的权重。

[0051] 3. 利用无监督分割算法得到不同分割粒度的超像素分割结果

[0052] 先将图像从 RGB 转换到 LUV 颜色空间,再利用 mean-sift 算法对图像进行无监督分割。Mean-shift 算法采用如下方法定义像素点的概率密度:

$$[0053] \quad K_{h_s, h_r}(x) = \frac{C}{h_s^2 h_r^2} k\left(\left\|\frac{x^s}{h_s}\right\|^2\right) k\left(\left\|\frac{x^r}{h_r}\right\|^2\right) \quad (4)$$

[0054] 其中, h_s 表示空间搜索窗口, h_r 表示颜色搜索窗口。式中 x^s 越小,即表示 x 像素点的距离与核中心像素点越近,概率密度越高; x^r 越小,即表示 x 像素点的颜色与核中心像素点颜色越相近,概率密度越高。因此,只需要控制该核函数的参数 $h = (h_s, h_r)$, 以及过分割片段包含的最小像素数量即可决定分割结果。

[0055] 从分割效果来看,细粒度的分割处于模型的低层次,它们对细节把握准确,但是缺少高层语义信息;粗粒度的分割包含高层语义,因而更容易被正确标记。但是由于一个超像素片段内可能包含多个目标类别,高层信息如何获得,以及如何保证这个高层信息正确都是很难的问题。从对使用 mean-sift 算法的图像分割实验结果来看,不同类别目标对应的最适合的分割粒度是不同的。在多类别图像分割问题中,为所有类别选择同一分割粒度是不合理的。因此,本发明分别采用三种核函数参数 $h = (30, 0.3)$ 、 $h = (30, 0.6)$ 和 $h = (30, 0.9)$, 产生三层不同分割粒度的分割结果,避开了对超像素质量的判断。

[0056] 4. 构建超像素级的一元势函数

[0057] 设 x_c 是表示超像素的随机变量, x_c^i 表示超像素包含的像素点的标签,每个超像素都可能包含多种不同的标签,因此为每个超像素寻找一个占主导比例的标签 x_c 。另外设 1_F

为空标签,表示不存在主导标签。定义 x_c 为:

$$[0058] \quad x_c = \begin{cases} l & \max_{i \in c} \frac{|x_c^i = l|}{|x_c|} \geq T, l \in L \\ l_F & otherwise \end{cases} \quad (5)$$

[0059] 其中, $|x_c^i = l|$ 表示 x_c 中标签为 l 的像素的个数, $|x_c|$ 表示超像素 c 内的像素的个数。 T 是人工设定的阈值,本文中取 $T = 0.5$,当超像素内不存在主导标签时,定义超像素的辅助变量为 l_F , l_F 不属于已有标签集。

[0060] 定义超像素的特征响应值为超像素该特征对应像素点占超像素内所有像素点的比例。然后设定阈值,构建一个弱分类器。然后使用多类别 Joint Boosting 算法训练一个强分类器,该分类器可以对超像素分割块进行分类。

[0061] 能量项定义如下:

$$[0062] \quad \psi_c(x_c) = \begin{cases} |c| \min(-H_l(c) + K, \alpha), & x_c = l \\ |c| \alpha, & x_c = l_F \end{cases} \quad (6)$$

[0063] 其中, $H_l(c)$ 是超像素 c 的标签被分类器判断为 l 的概率, α 是一个人工设定的截断阈值,取值为 -0.1 ,表示超像素内至多允许 10% 的像素取不同于主导标签的标签, $K = \log \sum e^{H_l(c)}$ 是归一化系数。

[0064] 5. 构建超像素级的成对势函数

[0065] 超像素成对势函数对相邻超像素的分割结果起到平滑作用,鼓励颜色特征相似的相邻超像素拥有相同的标签。首先计算超像素分割片段内的颜色直方图,以相邻超像素之间归一化的颜色直方图的欧氏距离计算超像素间的相似度,并以此作为超像素片段之间的成对势。

$$[0066] \quad \psi_{cd}(x_c, x_d) = \begin{cases} 0 & \text{if } x_c = x_d \\ g(c, d) / 2 & \text{if } (x_c \text{ or } x_d = l_F) \\ g(c, d) & otherwise \end{cases} \quad (7)$$

[0067] 其中 $g(c, d) = |h(x_c^{(n)}) - h(x_d^{(n)})|^2$, $h(g)$ 是归一化的超像素片段的颜色直方图。

[0068] 6. 估计分层高阶条件随机场模型参数

[0069] 本发明根据手工标记的训练图像集逐层确定条件随机场模型的参数,确定各势函数的系数。针对像素级的一元势和成对势函数,针对超像素级的一元势和成对势函数,在模型的每一层,尽可能的减小手工标记的标签与经过计算得到的辅助标签之间的差异,通过最小化下面的公式来计算权重:

$$[0070] \quad C(x^{(i)}) = \sum \Delta(x_c^{(i)} \neq l_c \wedge l_c \neq l_F) \quad (8)$$

[0071] 其中 l_c 表示手工标记的主导标签, l_F 表示空标签, $x_c^{(i)}$ 表示计算得到的第 i 层的辅助标签, $V^{(i)}$ 表示条件随机场模型第 i 层的节点集合。 Δ 是一个指示函数,如果其参数为真则值为 1,如果参数为假则其值为 0。在模型的每一层,通过求式 (13) 的最小值来得到条件随机场模型的各个参数。

[0072] 7. 构建分层高阶条件随机场模型

[0073] 构建分层高阶条件随机场模型如下：

$$[0074] \quad E(x) = \sum_{i \in v} \psi_i(x_i) + \sum_{i \in v, j \in N_i} \psi_{ij}(x_i, x_j) + \sum_{n=1}^3 \psi_{cd}(x_c^{(n)}, x_d^{(n)}) + \psi_c(x_c^{(n)}) \quad (9)$$

[0075] 其中， $\psi_i(x_i)$ 为像素级一元势函数， $\psi_{ij}(x_i, x_j)$ 为像素级成对势函数， v 表示像素集合， N_i 表示第 i 个像素的相邻像素集合， $\psi_{cd}(x_c^{(n)}, x_d^{(n)})$ 和 $\psi_c(x_c^{(n)})$ 分别表示第 n 层的超像素级的成对势函数和一元势函数。。

[0076] 8. 应用图割算法推理各层能量的局部最小值，获得最终的图像分割标记。

[0077] 为新输入的目标图像推理最优的分割标签，即求目标图像的能量项 $E(x)$ 的最小值。本发明采用基于图割算法对关联层次网络模型的推理方法求解分层高阶条件随机场模型的最小值。该算法从一个初始标记开始，使用了两个二值变量构建高阶能量项的转移函数，寻找标记的最优移动，迭代应用图割算法计算各层能量的局部最小值。表 1 给出了不同模型在三个数据集上的总体分类准确率对比。

[0078] 表 1 不同模型在三个数据集上的总体分类准确率对比

[0079]

总体分类准确率	道路场景图像数据集	CamVid 数据集	Sowerby 数据集
基于纹理的模型	92.28%	66.45%	83.73%
本发明模型	94.34%	78.96%	90.69%

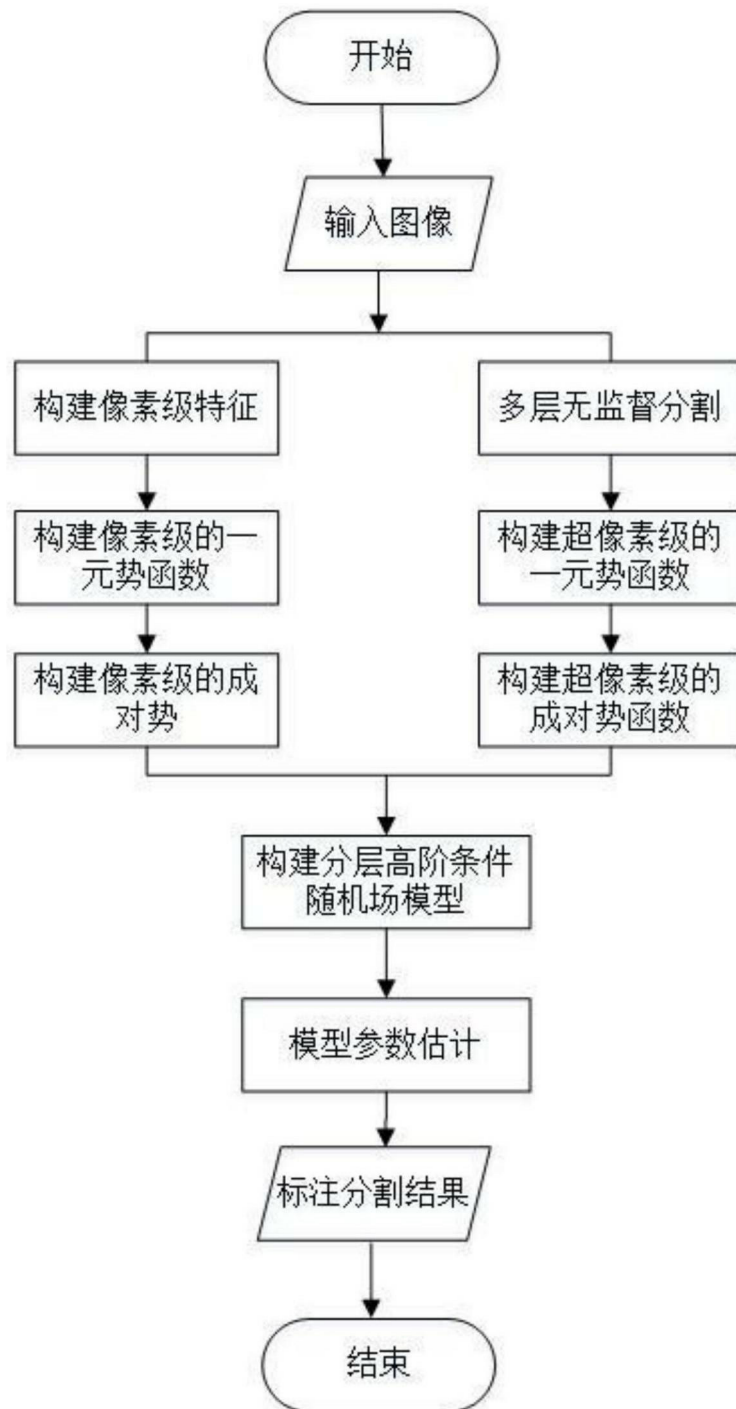


图 1



图 2 (a)

图 2 (b)

图 2 (c)

图 2 (d)

图 2 (e)

图 2