

用于图象分割的并行自适应 层次化网络模型¹⁾

郑南宁 刘健勤 王庆元

(西安交通大学人工智能与机器人研究所 710049)

摘 要

本文提出了一种新的用于图象分割的并行自适应层次化网络模型,该网络模型由并行局部特征提取与区域生成层、自适应统计聚类层和依据全局分布特性引导的决策层组成。各层次间的通讯由网络的协作机制来实现。该网络通过自适应非参数聚类方法,将局部灰度特征与全局随机场分布特征相结合,实现了非监督的图象分割。文中给出了该模型应用于室外自然景物的分割结果。实验表明,即使在自然景物环境变化的情况下,也能得到正确的分割结果。

关键词: 自适应图象分割,并行计算,统计聚类。

一、前 言

图象分割是机器视觉研究领域极为重要的内容之一,是实现自动图象分析时首先需要完成的操作。由于分割中出现的误差会传播至高层次处理阶段,因此分割的精确程度是至关重要的。传统的图象分割技术一般分为边缘检测与区域生长两大类。边缘检测方法使用局部窗口操作,可检测出通过给定点的边缘或曲线,但不能体现全局的区域边界,而且边缘跟踪的序贯操作在很大程度上限制了分割的速度。区域生长算法尽管其区域及边界分别满足封闭性和连续性,不需进行边缘连接操作,但其顺序操作仍然不能满足实时处理要求,特别是区域生长算法的计算复杂度一般比边缘操作大得多。

自适应图象分割是近年来一种新的方法,已引起人们的重视。文献[1]提出了一种仿真生物初级视觉功能的神经元网络,该网络应用协作与竞争反馈机制有效地实现了模板驱动的对比度检测。文献[2]通过 Gibbs 随机场中的 SAR 算法,在最大似然估计的条件下完成参数估计和自适应分割,其对象是被噪声污染的简单图象。A. Rosenfeld 在分析区域生长与边界检测算法的基础上,提出了一种并行层次化计算逻辑网络,该网络能有效仿真生物视觉的一些基本的认知功能^[3]。本文作者也提出了一种基于 BP 网络模型的室外景物图象分割算法^[4]。由于统一的自适应并行(神经元网络)分割理论尚未形成,在对任意复杂景物图象的分割算法研究中,还没有找到一种有效的方法。本文研究工作的主要贡献在于将局部并行区域感知与全局随机统计最佳逼近相结合,提出了图 1 所示的并行

本文于 1991 年 8 月 14 日收到。

1) 国家自然科学基金资助的课题。

自适应层次化图象分割网络模型。该网络模型由并行局部特征提取与区域感知层、自适应统计模式聚类层和全局分布特性引导的最优准则判定层组成。

在局部特征提取与区域感知层中,通过并行递归迭代操作,根据相邻局部特征向量的一阶导数变化和区域均一性进行聚类,将满足给定约束参数的像素归为相应类,并以所在区域的平均灰度值表示。在灰度图象中,特征向量 $V(i,j)$ 中的元素可取为灰度均值和方差或退化为一维灰度值;对于纹理图象 $V(i,j)$ 可取 6—12 组空域特征向量。对于给定的约束参数,经过若干次迭代运算后,总可得到稳定结果。给定约束参数在一次稳定操作中是一个常数,而在整个迭代运算过程中是变化的,其最佳值的确定是依据全局分布特性由高层次决策机制实现的。

自适应统计聚类是在局部特征向量 $V(i,j)$ 的统计分布的基础上,并行计算出特征向量的直方图。这样既能反映特征向量分布的特性,又可用统计分布的定量计算来代替特征向量的直接聚类。

全局分布特性引导的最优准则判定层是根据系统优化理论以反映聚类特性的能量函数的最小化来获取多参数多目标系统的最佳逼近。根据这一思想,在图象建模中将类内散布特征、类间散布特征和类间置信度的相对差异性相综合来构造图象分割中的聚类终止准则和相应判定函数,用以引导最低层的递归运算过程。

二、并行局部特征向量计算

为了降低自适应聚类的运算复杂度和提高特征属性隶属程度,这里不是对图象的初始子块或像素进行聚类操作,而是先对初始聚类进行均一化操作,再进行聚类操作。

设图象像素集为

$$P = \{I(i,j)\}, i = 0,1,2,\dots,n, j = 0,1,2,\dots,n,$$

相应局部特征向量集为

$$L = \{V(i,j)\}, i = 0,1,2,\dots,m, j = 0,1,2,\dots,m.$$

由于局部特征向量集的求取只对一部分像素值进行外推计算得到,故存在 $m \leq n$ 。相邻特征向量的差异比较阈值定义为

$$T = \{t(i,j)\}, i = 0,1,2,\dots,m, j = 0,1,2,\dots,m.$$

为简单起见,令 $t(i,j) = t^{(k)}$, $k = 0,1,\dots,K$ 表示均一化过程次数, K 的取值由全局最优过程给出。

均一化操作过程如下:

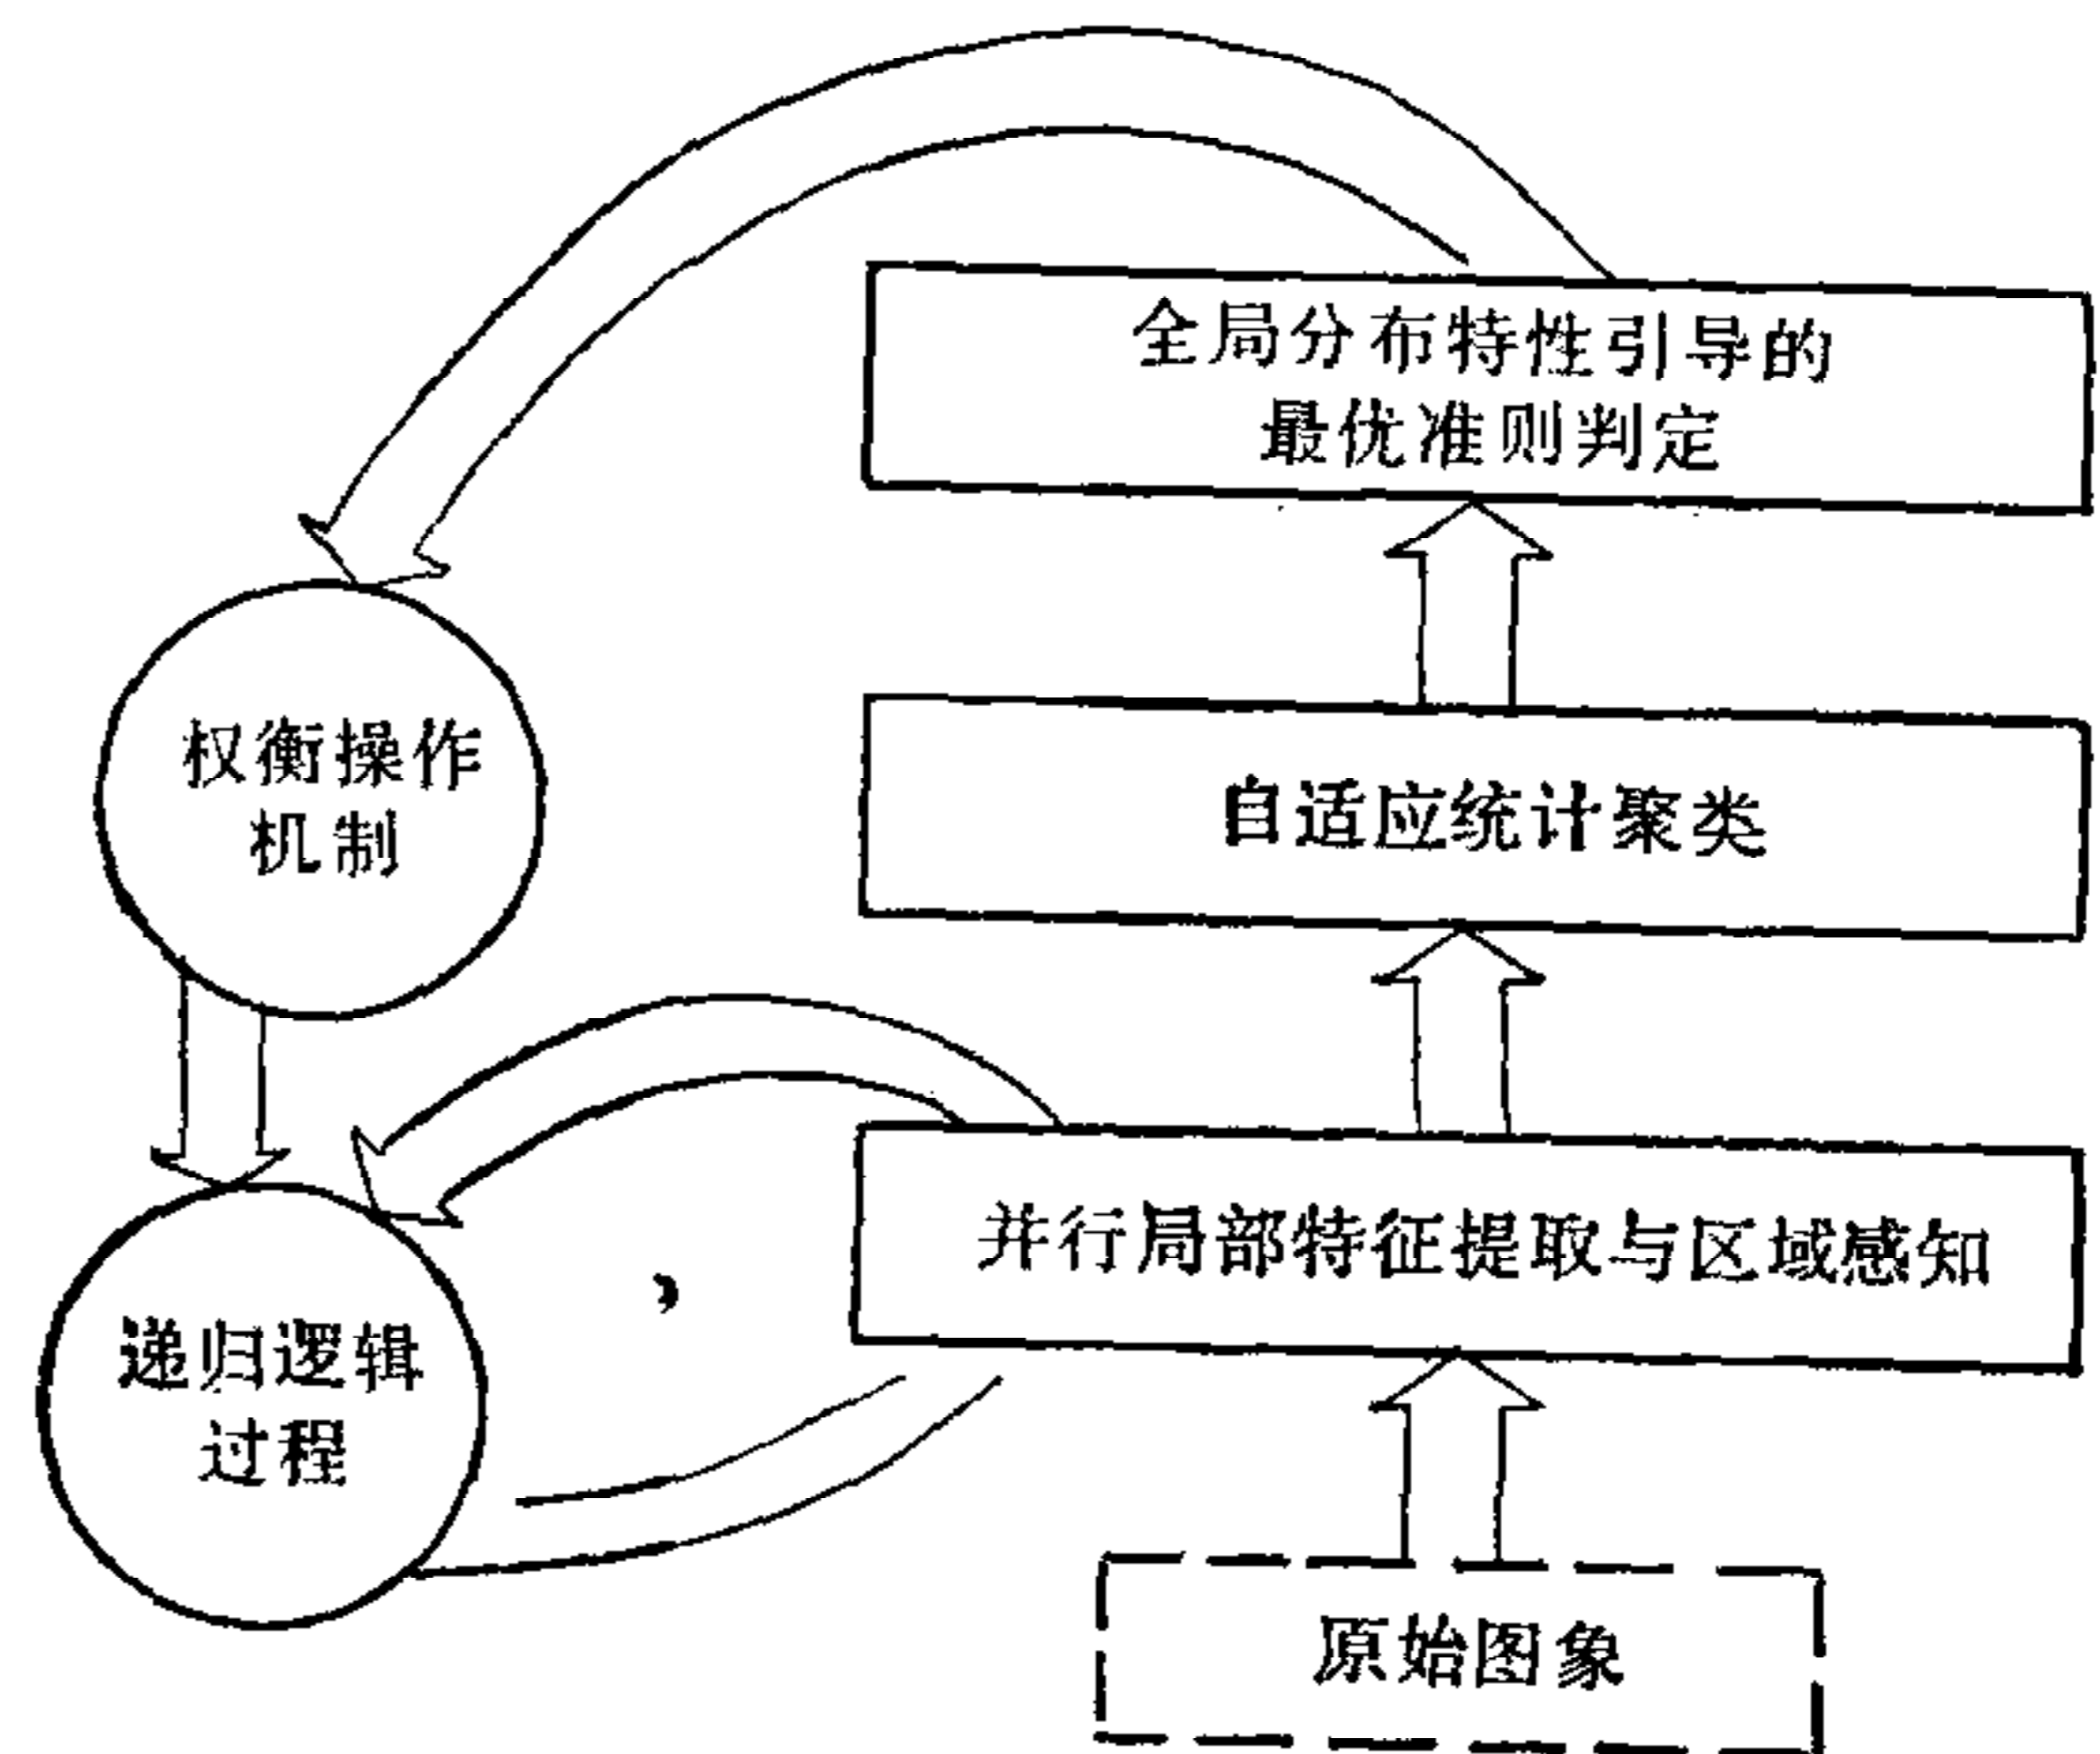


图1 并行自适应层次化图象分割网络模型框图

step 1. 计算 $V(i, j) = \{v_1(i, j), v_2(i, j), \dots, v_q(i, j)\}$, (q ——向量维数).

step 2. 考虑 $V(i, j)$ 的二阶邻域(即八邻域) $W: V(i-1, j-1), V(i-1, j), V(i-1, j+1), V(i, j-1), V(i, j+1), V(i+1, j-1), V(i+1, j), V(i+1, j+1)$,

对满足不等式 $\|V(i, j) - V(i', j')\| < \epsilon^{(k)}$ 的 $V(i', j')$ 的集合定义为 R ($V(i', j') \in W$), 并进行如下运算:

$$V^*(i, j) = \frac{V(i, j) + \sum_{p=1}^r R_p}{r},$$

式中 R_p 为 R 集合中的元素, r 为 R 的元素个数.

step 3. 若 $d = \log \sum_{i=0}^m \sum_{j=0}^m \|V(i, j) - V^*(i, j)\| < D_T$ (D_T 为给定精度), 则转 step

4; 否则 $V \leftarrow V^*$.

step 4. 结束.

三、自组织均一化特征向量聚类

在自适应模式识别方法中,常用的是 K -均值及其改进算法和 ISODATA 方法;自适应共振网络 (ART) 也可用作自组织聚类. 但这些方法缺乏通用性和聚类的有效性,而且迭代过程的时间开销也较大. 为避免这些问题,本文提出了将直方图统计计算与峰值判定相结合,采用层次化锥形结构,自底向上逐层递减的方法计算每层中的结点其子邻域的灰度直方图,并在给定概率阈值内确定峰值与谷值. 每层的相对概率阈值是根据 Bayes 决策理论由每层子结点个数而定,随层次升高该层中每一结点的所属子结点个数单调增加.

图 2 给出了并行统计决策方法的框图. 图中 $T_{pmax}(i)$ 和 $T_{pmin}(i)$ 分别表示第 i 层的峰值和谷值的置信度判定阈值, $H(i)$ 表示第 i 层对其子结点统计而得到的特征向量

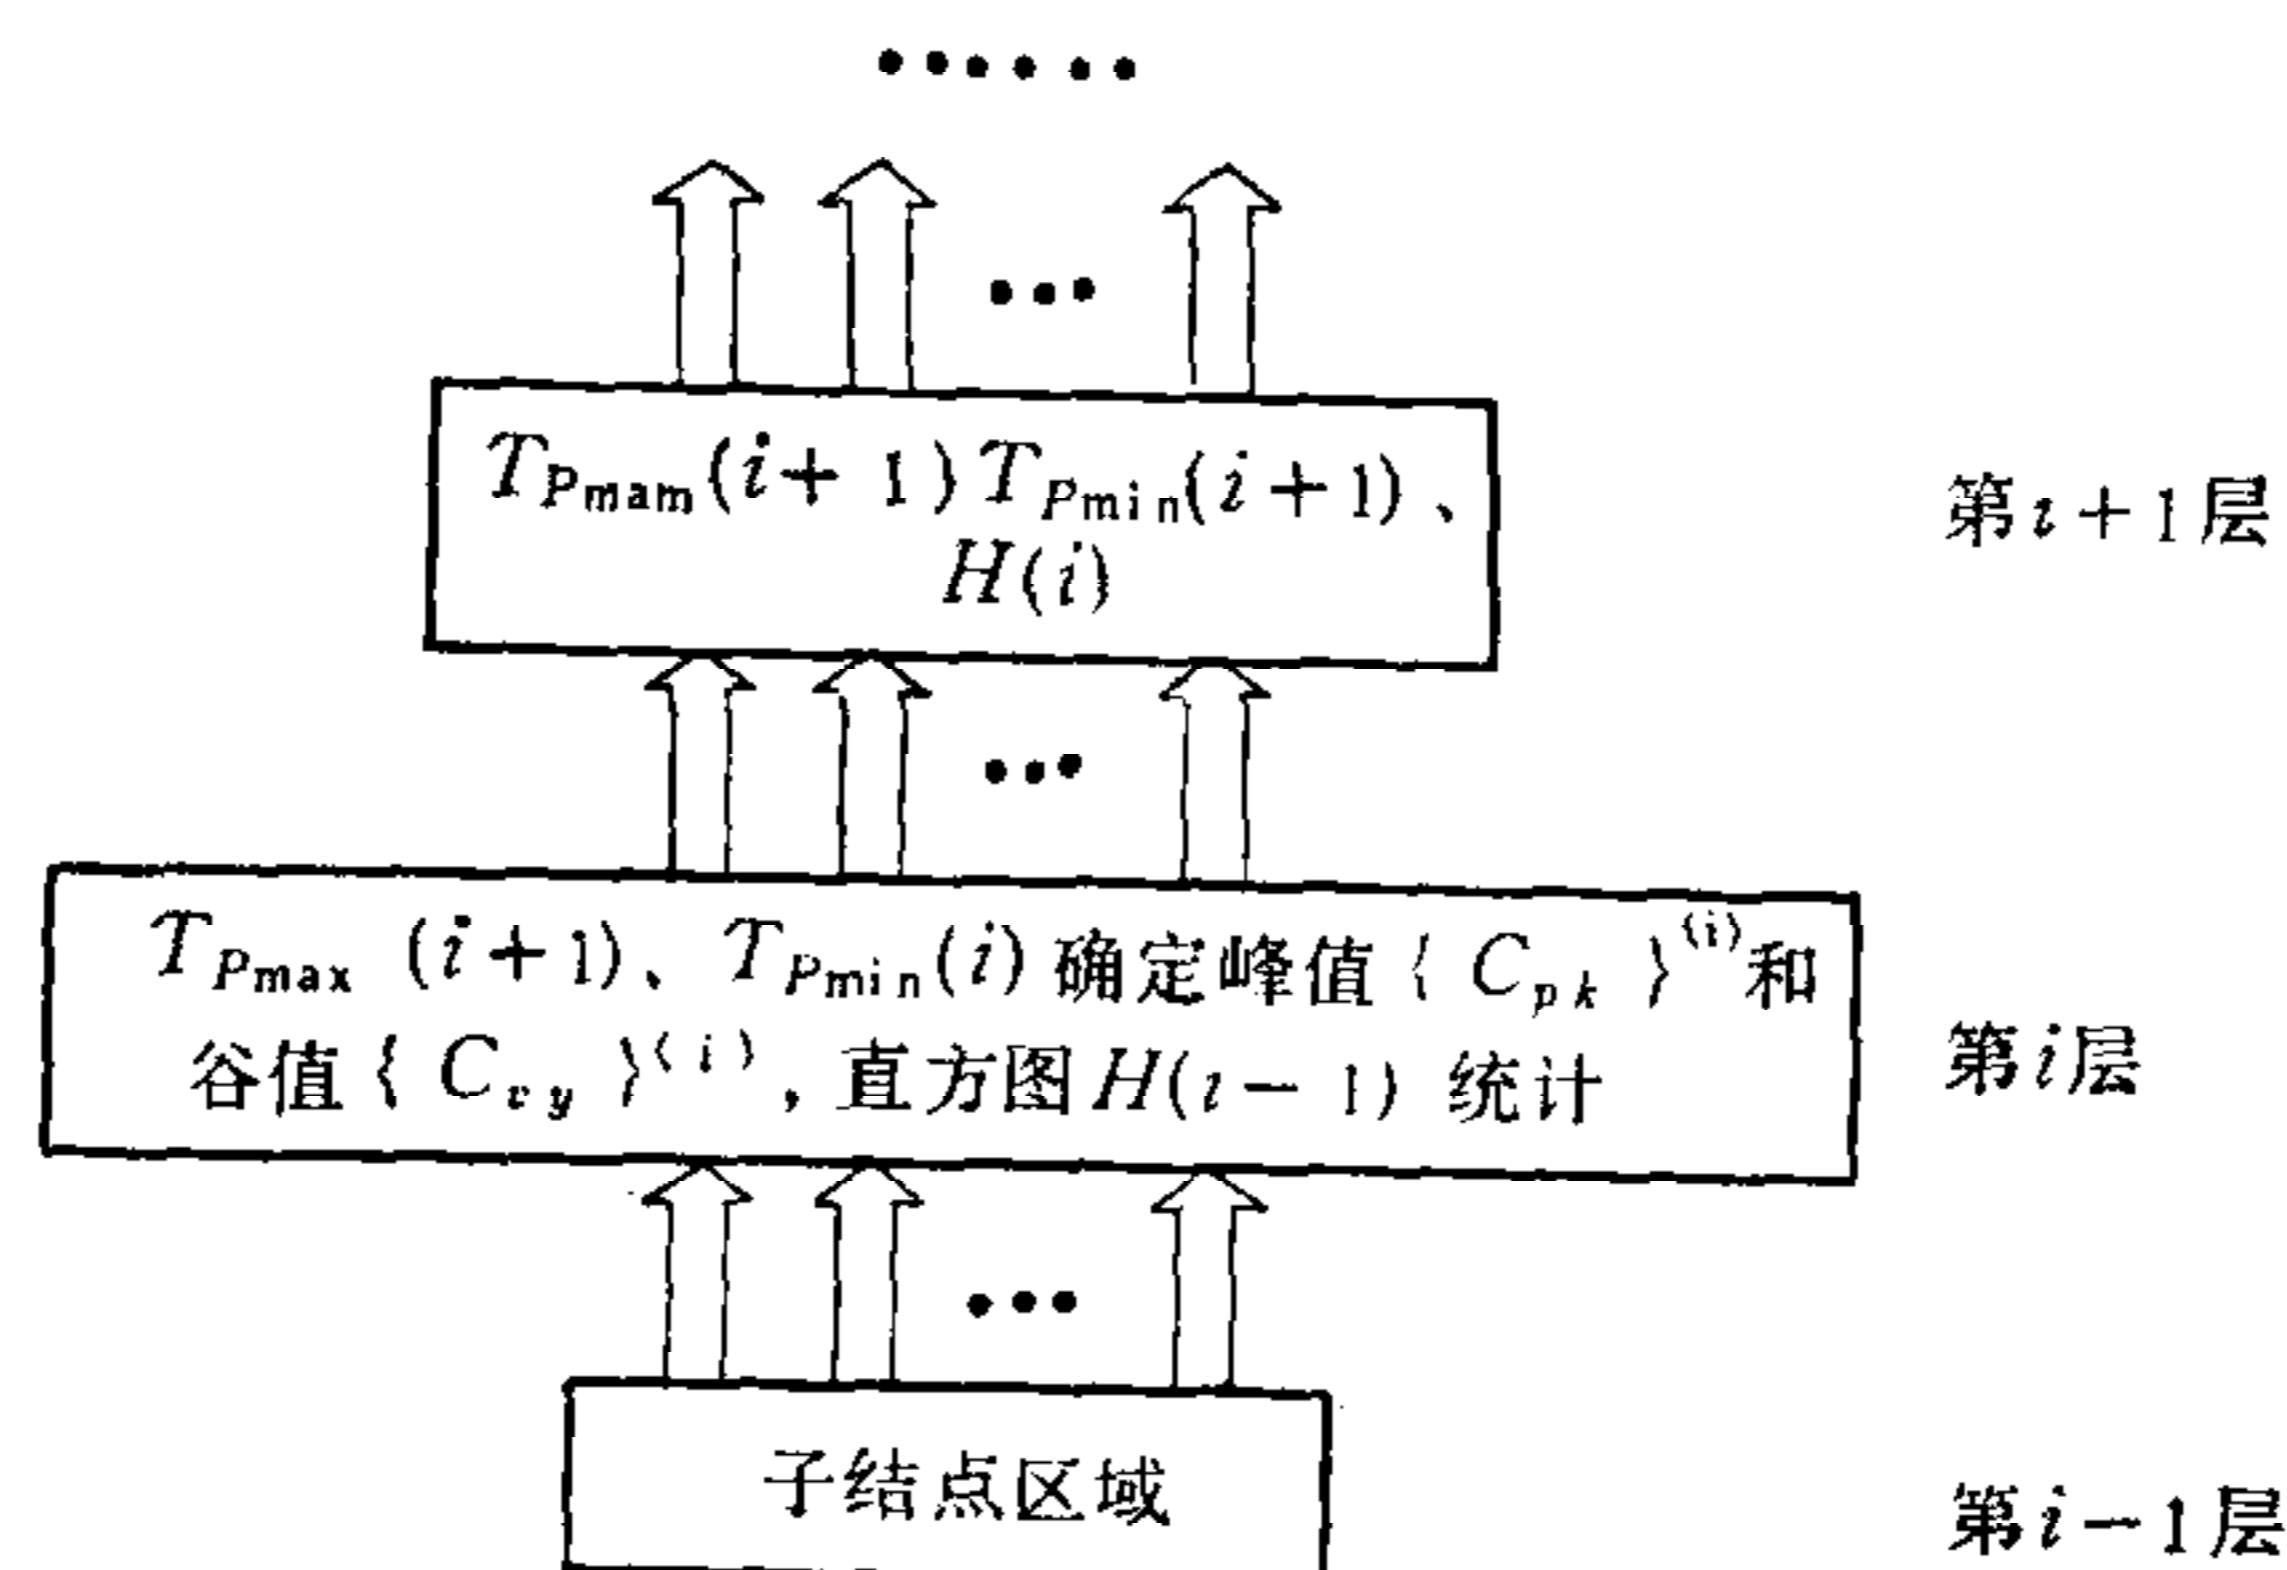


图 2 并行统计决策方法框图

直方图, $\{C_{pk}\}^{(i)}$ 和 $\{C_{vy}\}^{(i)}$ 分别表示该层所求得的峰值和谷值集合, 并分别对应于候选的区域向量中心和概率阈值边界。

通常, 在图象中所抽取的特征结构方面的知识事先知道得很少, 诸如图象中均一化区域的数目(对应特征空间中聚类的数目)和随机特征向量概率密度的形式都是未知的。因此, 采用非参数聚类来实现图象的聚类适应化是很重要的。直方图综合反映了特征向量的分布和图象数据的概率密度, 直方图中明显的峰值被选作统计意义上需要加以区分的聚类, 不同类的概率阈值边界对应于围绕每个峰值的局部极小值或谷值。这里需要指出的是: 对每层中的峰值集合 $\{C_{pk}\}^{(i)}$ 和谷值集合 $\{C_{vy}\}^{(i)}$, 根据概率是否大于给定阈值 $T_{pmax}(i)$ 和 $T_{pmin}(i)$, 对相邻距离作出判定, 距离比较阈值为 T_R , 它等于对应层次结点象素灰度量化基本单位的 α 倍(本文试验中取 $1 < \alpha \leq 4$), 以消除峰值与区域对应关系中的和歧义性。

四、基于全局分布特性的聚类决策

在全局统计分布的分析基础上, 可寻求出全局最优的分类结果。当分类较多时, 类内方差小, 说明各类的内聚性 (Cohesiveness) 好, 而类间方差也小, 则说明各类的分离程度 (Isolation) 不明显。当分类较小时, 类内方差较大, 内聚特性有所下降, 但类间方差的增加, 使分离程度趋于明显。同时对应各峰值的概率值, 也对应着各类的相对概率分布值(即在全部可能性中所占的相对比例)。各类概率的相对均等程度也应是聚类性能优劣的尺度之一。从最优化角度来看, 应该是各类均有较大的置信度, 而且在复杂图象中不宜存在概率过大或概率过小的聚类分区。

由以上讨论, 定量化准则 S 定义为

$$S = C_s \cdot S_I \cdot S_B \cdot S_P, \quad (1)$$

式中 C_s 为归一化系数, 以使 S 取值范围为 $[0.00, 1.00]$, S_I 为类内平均散布值

$$S_I = n_{cl} / \sum_{i=1}^{n_{cl}} \sigma_i^2, \quad (2)$$

其中 σ_i^2 ——各类的灰度区域方差, n_{cl} ——聚类个数, S_B 为类间平均散布值, 即

$$S_B = \sum_{i=1}^{n_{cl}} \sum_{\substack{j=1 \\ (i \neq j)}}^{n_{cl}} \|L_{pk}^{(i)} - L_{pk}^{(j)}\|^2 / n_{cl} \cdot (n_{cl} - 1), \quad (3)$$

$L_{pk}^{(i)}$ ——表示 i 类的聚类中心的空间位置, $L_{pk}^{(j)}$ ——表示 j 类的聚类中心的空间位置, S_P 为相对概率散布值

$$S_P = \sum_{i=1}^{n_{cl}} \sum_{\substack{j=1 \\ (i \neq j)}}^{n_{cl}} (C_{pk}^{(i)} - C_{pk}^{(j)})^2 / n_{cl} (n_{cl} - 1), \quad (4)$$

$C_{pk}^{(i)}$ ——表示 i 类的聚类中心的概率值, $C_{pk}^{(j)}$ ——表示 j 类的聚类中心的概率值。于是, 式(1)可表示为

$$S = C_S \cdot S_I \cdot S_B \cdot S_P = \frac{n_{cl}}{\sum_{i=1}^{n_{cl}} \sigma_i^2} \cdot \frac{\sum_{i=1}^{n_{cl}} \sum_{j=1}^{n_{cl}} \|L_{pk}^{(i)} - L_{pk}^{(j)}\|^2}{n_{cl}(n_{cl} - 1)} \cdot \frac{\sum_{i=1}^{n_{cl}} \sum_{j=1}^{n_{cl}} (C_{pk}^{(i)} - C_{pk}^{(j)})^2}{n_{cl}(n_{cl} - 1)}, i \neq j. \quad (5)$$


经整理,得

$$S = \frac{\sum_{i=1}^{n_{cl}} \sum_{j=1}^{n_{cl}} \|L_{pk}^{(i)} - L_{pk}^{(j)}\|^2 \sum_{i=1}^{n_{cl}} \sum_{j=1}^{n_{cl}} (C_{pk}^{(i)} - C_{pk}^{(j)})^2}{n_{cl}(n_{cl} - 1)^2 \sum_{i=1}^{n_{cl}} \sigma_i^2}, i \neq j. \quad (6)$$

当 S 在给定精度 G_T 的情况下,满足 $1/S < G_T$ 关系时,就可认为此时状态为最佳或足够逼近最佳,所对应的聚类分布度确定下来以实现图象的最终分割。不难证明由上述讨论的聚类过程的收敛特性保证了图象分割结果是最优的。


五、实验结果

根据本文所提出的模型,作者仿真实现了用于图象分割的并行自适应分割算法。由于篇幅所限,这里给出了两幅 256×256 (象素量化为 8bit) 的室外自然景物图象的分割处理结果;例中所用的两维局部特征向量是由局部窗口均值与方差组成。图 3(a) 是复杂自然景物的原始图象,图 3(b) 是将图象分割为聚类较少的结果,阈值 $t = 9$; 图 3(c) 示出了对应于图 3(b) 的灰度图象;图 3(d) 是由 S 最佳准则所权衡确定的分割结果 ($t = 5$)。图 4(a) 给出了另一景物的原始图象,图 4(b) 给出了对应的分割结果 ($t = 7$)。从上述的分割结果可以看出,它们都突出了有意义的区域,如山、树木和云,又充分保留了对象原有的明暗变化的细节,如树木丛林的疏密和云层厚度的浓淡。实验结果表明,在自然景物



(a) 原始景物图象


(b) 分割结果($t = 9$)



(c) 对应图 3(b) 的灰度图象

(d) 分割结果 ($t = 5$)

图 3 实验结果(一)



(a) 原始图象

(b) 分割结果 ($t = 7$)

图 4 实验结果(二)

环境照度等物理因素变化较大时，本文所提出的方法是有效和实用的。在该模型的基础上可进一步引入竞争与协作机制，并完善网络本身的反馈机制，使多层网络成为更有效的用于图象分割的人工神经网络系统。

参 考 文 献

- [1] Grossberg, S., Mingolla, E. and Todorovic, D., A Neural Network Architecture for Preattentive Vision, *IEEE Trans. on Biomed. Eng.*, 36(1989), 1, 65—83.
- [2] Geman, S. and Geman, D., Stochastic Relaxation, Gibbs Distributions and the Bayesian Restoration of Images, *IEEE Trans. on PAMI*, 11(1984), 6, 721—741.
- [3] Rosenfeld, A., Computer Vision: A Source of Models for Biological Visual Processes?, *IEEE Trans. on Biomed. Eng.*, 36(1989), 1, 93—94.
- [4] Zheng Nanning and Liu Jianqin, An Approach to Image Segmentation with Neural Nets and Fuzzy Logic, *Proceedings of International Symposium Theory and It's Applications*, 11(1990), 723—726.
- [5] Khotanzad, A. and Bonarfa, A., Image Segmentation by a Parallel Non-parametric Histogram Based Clustering Algorithm, *Trans. on Pattern Recognition*, 23(1990), 9, 961—973.

A PARALLEL ADAPTIVE HIERARCHICAL NETWORK MODEL FOR IMAGE SEGMENTATION

ZHENG NANNING LIU JIANQIN WANG QINGYUAN

(*Institute of Artificial Intelligence and Robotics, Xi'an Jiaotong University, 710049*)


ABSTRACT

This paper describes a new parallel adaptive hierarchical network model for image segmentation. The model consists of a layer for extracting local features and forming region in a parallel recursive way, a layer for adaptive statistical clustering, and a layer for making decision under the guidance of global distribution features. The communication between these layers is realized by means of cooperation mechanism. With the automatic non-parameter clustering method, the un-supervised image segmentation is completed by integrating the local gray feature with the global random distribution features. The model has been applied to the adaptive segmentation of outdoor natural scene image. Even though in the case of different environment, the experimental result is rather satisfactory.

Key words Adaptive image segmentation, parallel computation, statistical clustering.



郑南宁 教授、工学博士, 1952年12月生于南京, 1975年10月毕业于西安交通大学工业自动化专业, 1981年5月获本校自动控制理论及应用专业硕士学位, 1985年3月获日本庆应大学工学博士学位。1981年至今先后在国内外发表论文多篇, 编著有“数字信号处理”、“计算机视觉与模式识别”。现主要从事机器视觉与模式识别、神经网络、并行处理的研究。



刘健勤 讲师, 1964年11月生于西安。1986年7月毕业于南开大学计算机应用专业。现在西安交通大学人工智能与机器人研究所工作。曾先后在国内外学术会议和国内期刊发表有关论文十七篇。目前主要从事人工智能、神经网络、并行算法的研究。



王庆元 讲师, 1954年9月生于陕西。1982年1月毕业于西安交通大学工业自动化专业, 1987年获自动控制理论及应用专业硕士学位, 现任西安交通大学人工智能与机器人研究所计算机视觉与模式识别研究室主任。曾先后在国内外学术会议及国内期刊上发表论文十四篇。现主要从事计算机视觉、模式识别、图象处理与人工智能方面的研究。