

一种改进的遥感图像变化检测算法

袁琪 赵荣椿

(西北工业大学计算机学院 西安 710072)

摘要: 原有基于简单马尔可夫随机场(MRF)模型的变化检测算法基于全局一致性假设,这一假设往往与实际情况不符,影响到结果准确性。本文提出基于观察场与标号场互相关的改进 MRF 模型及相应的变化检测算法。以迭代条件模型解决后验概率最大化问题,为像素分类;根据当前分类,利用邻域中同类像素调整观察场中的像素特征值;以新的像素特征进一步优化分类。本文采用两段迭代算法,以多时相遥感图像的差值图像做为观察场。实验证明该算法能有效提高检测结果精度。

关键词: 多时相遥感图像; 互相关马尔可夫随机场; 最大后验概率; 同步自回归模型; 迭代条件模型

中图分类号: TP75

文献标识码: A

文章编号: 1009-5896(2008)11-2737-05

An Improved Approach to Change Detection in Multitemporal Remote-Sensing Images

Yuan Qi Zhao Rong-chun

(Department of Computer Science and Engineering, Northwestern Polytechnical University, Xi'an 710072, China)

Abstract: Traditional unsupervised change detection algorithms based on simple MRF model assume that subimages applied to extracting features are homogeneous, but that is not always true and causes low accuracy. Based on the fields Correlation Markov Random Field (CMRF) model, an adaptive algorithm is proposed in this paper. The labeling is obtained through solving a Maximum *A Posterior* (MAP) problem by Iteration Condition Model (ICM). Features of each pixel are exacted by using only the pixels currently labeled as the same pattern. With the adapted features, the new labeling is obtained. Under the idea of two-stage iteration algorithm, we use the difference image of multitemporal remote-sensing images as observation field. The satisfied experimental confirm the effectiveness of proposed techniques.

Key words: Multitemporal remote-sensing images; Correlation MRF (CMRF); Maximum *A Posterior* (MAP); Simultaneous auto-regressive; Iteration condition model

1 引言

遥感图像变化检测技术是遥感图像研究的重要组成部分,广泛用于地表利用分析、环境保护、城市发展规划以及军事领域。多时相遥感图像变化检测处理的难点主要在于如何获取土地变化与否的判定标准。因此,人们提出了许多在监督和无监督条件下的变化检测算法^[1-7]。而如何减少人工参与,提高无监督变化检测准确性,更是研究热点。

近几年,基于马尔可夫随机场(MRF)模型的遥感图像无监督分类及变化检测方法受到关注。主要是利用多时相图像的差值图像实现变化检测判别。Bruzzone^[2,8,9]等人以马尔可夫随机场模型为差值图像建立邻域像素光谱及空间关系模型,以统计分析的方法区分变化区域,以最大化期望(EM)算法,依靠像素空间分布特征,实现多时相遥感图像的无监督变化估计。Wiemker^[10]利用贝叶斯概率理论分析不同时相的两幅配准图像,以 MRF 模型提取图像特征的空间关系,

得到变化及无变化区域。Kasetkasem^[11]等基于最大后验概率(MAP)准则在 MRF 模型下同样实现了图像变化检测。由于以上方法基于简单的马尔可夫随机场 (Markov Random Field, MRF)^[12,13],这里将以上方法统称为基于简单 MRF 模型的方法 SMRF。

上述方法假设所处理的图像中变化检测区域足够大,在对图像中每个计算参数时,认为该像素服从整体分布特性或认为以该像素为中心的估计窗口中所有像素同类。这种算法尽管简单有效,但是由于其假设条件的缺陷,影响了结果的精确性。文献[11]虽对于邻域像素类型作了考虑,但仍局限于全局一致性假设。鉴于此,本文利用 MRF 模型突出局域性的优势,提出观察场与标号场互相关的变化检测算法。模型中包含两个互相关的组成部分:差值图像和对应像素分类的标号图像,以同步自回归模型(Simultaneous Auto-Regressive, SAR)提取特征,采用多级逻辑模型和基于 MAR-MAP 的算法框架描述,用 EM 算法估计先验概率,用最小二乘法估计特征。实现过程采用两段迭代算法,第 1 阶段基

2007-04-23 收到, 2007-09-24 改回

国家自然科学基金(60472072)和博士点基金(20040690034)资助课题

于原有 MRF 模型;第2阶段采用本文提出的 CMRF 模型直到收敛。试验证明该方法能有效提高遥感图像无监督变化检测的准确性。

2 基于 CMRF 的变化检测理论

2.1 基本原理

对于大小为 $I \times J$ 的两个不同时相遥感图像的差值图像 $S = \{s = (i, j); 1 \leq i \leq I, 1 \leq j \leq J\}$, 存在可能的灰度分布 $X = \{X_s, s \in S\}$ 和一个对应的标记像素分类的标号分布 $l = \{l_s; l_s \in \omega, \omega \in \{\omega_n, \omega_c\} | s \in S\}$, 其中 $l \in L, L = 2^M$ 是所有可能标号的集合, 标号集 ω_c 和 ω_n 分别代表两时相地物发生变化及未发生变化类别标号。令 x 为实际得到的差值图像, l 为对应的实际标号图像, 分别表示观察场 X 和标号场 L 的一个实现。

根据统计决策理论和 Bayes^[14]最小误差法则, 图像变化检测问题可转化为在一系列约束条件和已知观察场条件下, 找出最优标号图, 使得到的后验概率分布 $p(x/l)$ 在全图上有全局最大值问题, 即求:

$$l^* \propto \arg \max_{l \in L} P(L=l)P(X=x|L=l) \quad (1)$$

其中 $P(L=l)$ 是标号图的先验模型, $P(X=x|L=l)$ 是 x 像素灰度的联合密度函数。

2.2 互相关 MRF 理论

以往基于 MRF 的变化检测算法^[1,2,8,9,11,15]基于全图分布一致性假设计算概率密度函数和分类的阈值, 同时基于这一假设, 算法在计算像素 x_s 的性质时通常假设以 x_s 为中心的邻域所有像素分布遵循整体统计分析结果。假设图像服从 Gibbs 分布(Gibbs Random Field, GRF), 图中每个像素满足 MRF 要求。在算法处理过程中, 观察场中特征的提取和对标号场的计算分成两个独立过程, 对像素的特征计算一次完成, 进入标号场优化的迭代过程后, 不再重新计算特征。

多数情况下, 这种假设不成立。以遥感图像变化检测处理中的差值图像为例, 实际图像中, 变化区域在图中分布不均匀, x_s 邻域内的像素可能属于变化区域, 也可能属于无变化区域。而马尔可夫性要求像素 x_s 的特征只能由邻域中标号同为 l_s 的像素决定。变化检测正是标号在迭代中不断优化的过程, 标号图在整个迭代过程中不断调整。初始阶段的特征计算会导致对 x_s 不正确的特征估计, 并对后续计算直至最终变化检测结果精度产生不利影响。为避免错误, 对 x_s 的处理需要同时考虑特征和标号, 因此问题转化为如下形式的优化问题:

$$\left. \begin{aligned} f_s^* &= T(x, l^*) \\ l^* |_f &= \arg \max_{j \in F} [p(L=l | F=f)] \end{aligned} \right\} \quad (2)$$

f_s^* 和 l^* 分别表示优化的特征集和标号集。我们称该模型为观察场与标号场互相关 MRF(Correlation MRF, CMRF)模型。模型假设图像符合 Gibbs 分布, 则以 x_s 为中心的一个大小为

$w \times w$ 的矩形估计窗口内的所有像素分为两类: ω_c 和 ω_n , 其中与 x_s 同属于 l^* 类的像素的灰度级构成了一个集合 W_s , 则集合 W_s 包含的所有像素组成的子图像可以被假设为一个 MRF。不失一般性, 用带二阶邻域的同步自回归模型^[16]描述如下:

$$x_s = \sum_{t \in N_s} \theta_{s,t} x_t + e_s, (x_s, x_t) \in W_s \quad (3)$$

其中 $\{\theta_{s,t}, t \in N_s\}$ 是反映邻域像素与中心像素关系的一系列模型参数, $N_s = \{(0, \pm 1), (1, \pm 1), (-1, \pm 1), (\pm 1, 0)\}$ 是二阶邻域系统所对应的坐标偏移量, $\{e_s\}$ 是方差为 σ_s^2 的平稳高斯噪声序列。该模型还存在一个对称图形模型: $\theta_{s,t} = \theta_{s,-t}, t \in N'_s, N'_s = \{(0, 1), (1, 1), (-1, 1), (1, 0)\}$ 。用最小二乘法(LSE)来估计模型中未知参数。

标号场也可被假设为一个 MRF, 用带二阶邻域的多级逻辑模型(Multi-Level Logistic, MLL)描述, 由 Hammersley-Clifford 等价定理, 所有像素类别标号的联合概率分布可用 Gibbs 分布表示为

$$P(L=l) = Z^{-1} \exp\left\{-\frac{1}{T} U_L(l)\right\} \quad (4)$$

$U_L(l)$ 是 Gibbs 能量函数, Z 是归一化常数, T 是系统温度。由 Bayes 理论, 式(2)用二阶邻域系统 MLL 模型描述标号场联合概率分布表示为

$$\begin{aligned} l^* |_f &= \arg \min(U_L(l, x)) \\ &= \arg \min(U_{\text{data}}(x, l) + U_{\text{context}}(l)) \end{aligned} \quad (5)$$

其中 $U_{\text{context}}(l)$ 是基团势能函数, 用于描述像素间的相关性, $U_{\text{data}}(x, l)$ 是条件概率模型能量函数。

为计算得到最优标号场, 同时为简化计算, 在此引入两个假设。首先, 先验概率服从 Gibbs 分布, 其能量函数是所有二阶基团势能之和。基于这一假设, 一个属于变化区域的像素, 其周围的像素属于变化区域的可能性较大, 未变化区域像素属性具有同样性质。利用这一像素间类别依赖性, 可以更为精确的得到变化检测结果。因此能量函数可用如下模型表示:

$$U_{\text{context}}(l_s / \{l_t, t \in N_s\}) = \sum_{s \in S} \sum_{t \in N_s} V_l(f_s, f_t) = \sum_{t \in N_s} \beta \delta(f_s, f_t) \quad (6)$$

常数 β 反映了检测过程中空间上下文相关性影响:

$$\beta = \begin{cases} -\beta, & (l_s = l_t, t \in N_s) \\ \beta, & (l_s \neq l_t, t \in N_s) (\beta > 0) \\ 0, & \text{其他} \end{cases}$$

其次, 假设观察场中的每个随机变量满足多元独立高斯分布, 其均值矩阵 \mathbf{M}_r 和协方差矩阵 Σ_s 均通过对同类像素计算获得, 能量函数模型定义为

$$U_{\text{data}}(x, l) = 2^{-1} ((f - \mu_l)^T \Sigma_l^{-1} (f - \mu_l) + \ln((2\pi)^D |\Sigma_l|)) \quad (7)$$

基于 SAR 模型, 为每个像素定义多维特征 f_s :

$$f_s = (\mu_s, \hat{\sigma}_s^2, \hat{\theta}_{s,t}, t \in N_s) \quad (8)$$

μ_s , $\hat{\sigma}_s^2$ 分别是对 $w \times w$ 窗口子图像内同类像素的灰度均值以及噪声方差的估计, $\hat{\theta}_{s,t}$ 是相对系数的估计, 对于非对称图形, $\hat{\theta}_{s,t}$ 是 8 个, 当假设图形对称时, $\hat{\theta}_{s,t}$ 减少为 4 个。以权值 k 来平衡能量函数对后验概率函数的影响, 问题转化为

$$l^*|_f \propto \min_{l \in L} \left[\sum_{s \in S} k U_L(l_s, x_s) + \sum_{s \in S} \sum_{t \in N_s} V_t(f_s, f_t) \right] \quad (9)$$

3 算法实现及参数设置

3.1 二段迭代过程

基于本文提出的 CMRF 模型的变化检测过程通过迭代处理不断优化标号场, 采用 EM 算法和最小二乘法分别在每次迭代过程中重估先验概率和特征集。考虑到 CMRF 模型与标号场关系紧密, 而在优化过程早期, 标号场极不准确, 由此产生的错误估计会在后续迭代处理中不断放大。因此在开始的 N_i 次迭代过程中, 不重估特征集。同时, 在 N_i 次迭代中采用模拟退火算法^[17]以减少结果最终收敛于局域最优而不是全局最优的可能。之后, 采用本文提出的基于 CMRF 模型, 并采用迭代条件模型(Iterated Conditional Model, ICM)以提高执行效率, 直到得到收敛的最优结果。在实现过程中, 为减少计算量, 可考虑在第二阶段迭代前期先采用式(3)的对称模型, 待收敛到一定程度后采用非对称模型提高精确度。具体实现步骤如下:

第 1 阶段

(1) 以同地区两幅不同时相的遥感图像的差值图像作为观察场, 假设图像满足矩形窗内像素同类假设, 以大小 $w \times w$ 的固定窗计算所有像素初始特征值。

(2) 设定最初标号场(标号分别属于 ω_n / ω_c), 同时将像素分为两组: 初始化时标号可以确定的像素组及标号待优化的像素组, 后续步骤中仅重新讨论后一组像素标号优化问题。分类及分组策略稍后说明。

(3) 在开始的 N_i 次循环中, 以栅格顺序计算并比较 U_{l_s} 和 $U_{l_{s'}}$ (U_{l_s} 和 $U_{l_{s'}}$ 分别表示像素当前标号 l_s 和置换标号 $l_{s'}$ 对应的能量)。

(4) 如果 $U_{l_{s'}} < U_{l_s}$, 以标号 $l_{s'}$ 替代原标号, 否则, 按如下概率接受新标号, 返回 3)

$$p_s(n) = \exp\left(-\frac{U_{s'} - U_s}{T(n)}\right)$$

n 是循环次数, $T(n)$ 为第 n 次循环时的温度。

第 2 阶段

- (5) 按当前标号场重新估计观察场像素特征。
- (6) 以栅格顺序计算并比较能量对 U_{l_s} 和 $U_{l_{s'}}$ 。
- (7) 选择使能量小的标号作为新标号。
- (8) 重复(5)–(7)直至收敛。

3.2 初始标号场的获取

考虑差值图像的特性, 灰度越低的像素代表所在区域发

生变化的概率越小, 像素标号属无变化类可能性越大, 灰度高的像素标号分类推理类似。步骤 2 中提到的分组主要是为了提高运行效率, 说明如下: 第一组: 设置阈值 T_c 和 T_n , $T_n = T(1 - \alpha)$, $T_c = T(1 + \alpha)$, 分别对应无变化像素集 S_n 的灰度上限和变化像素集 S_c 灰度下限, 通过试验, T 利用直方图阈值确定方法——大津法(OTSU)的计算结果。第二组: 即子集 $S_u = \{X_s | T_n \leq X_s \leq T_c\}$, 其中所有像素的初始标号在 ω_n 和 ω_c 标号中随机抽取获得。

调整系数 α 是 (0,1) 之间的实数, 当 α 逐渐增大时, 多数像素在初始化标号场时的分类都需要在以后迭代中优化, 每次迭代过程计算时间增加, 系统运行效率降低; 而当 α 逐渐减小趋向于 0 时, 场中多数像素遵循最初的阈值判定结果, 系统每次迭代的运算速度得到提高, 但由于最初阈值选择准确性缺陷, 像素误分类的可能性增大, 结果准确性降低。因此, 需要根据具体图像和经验调整 α 。

4 试验分析

为验证所采用的 CMRF 模型正确性及算法鲁棒性, 采用同一地区不同时期得到的真实遥感图像做不同参数条件下的变化检测试验, 同时以文献[2]提出的算法结果作试验, 并对比结果。原图像是 1991 年 7 月和 2000 年 10 月的多波段 TM 图像对, 地点是东经 120° 北纬 30°, 地物以农用地和河流为主。为简化试验, 采用第一波段(可见光)局部, 处理区域大小 450 * 400 像素。试验中选择初始温度 $T = 3$, $N_i = 10$, $w = 5$ 。

由于本文的目的在于基于同等条件, 对所提出的算法与原有算法检测结果的准确性进行比较, 因此在进行变化检测前, 对实际图像对只做了图像配准处理, 没有进行辐射校正。具体应用时需要根据具体情况做相应的辐射校正。

图 1 是原图及检测结果。图 1(a), 图 1(b) 分别是原图像, 图 1(c), 图 1(d) 是采用 SMRF 和 CMRF 模型得到的结果比较, 可以看出, 本文提出的算法获得的结论有明显的改善。基于 CMRF 模型的算法得到的结果更接近实际变化区域, 同时误判区域更少。也可看到由于没有做辐射校正, 对于地物反射条件不同引起的两幅图的变化,

图 1(e) 利用几个典型的迭代过程比较了采用不同算法或 α 取值时, 迭代过程中判定为变化像素数量; 为便于观察结果, 图 1(f) 仅对第 15 次循环之后的结果做了比较。分析可知, 前期不进行特征重估的迭代过程和 SMRF 算法得到的结果相差不大, 采用本文提出的算法, 虽然在第 30 次迭代结束时两种算法结论中标号为变化的像素数差别不大, 但由于 SMRF 算法误判区域较多, 因此准确率低于 CMRF 算法。

为测试算法稳定性, 标号场初始化时分别采用 $\alpha = 0.1 \sim 0.9$ 。结果证实当 $\alpha \geq 0.3$ 时, 得到的结果相差很小, 而当 $\alpha < 0.3$, 则与实际结果有较大偏差, 错误分类的像素主要属于标号场初始化时的第一组, 这一组像素在后来的迭

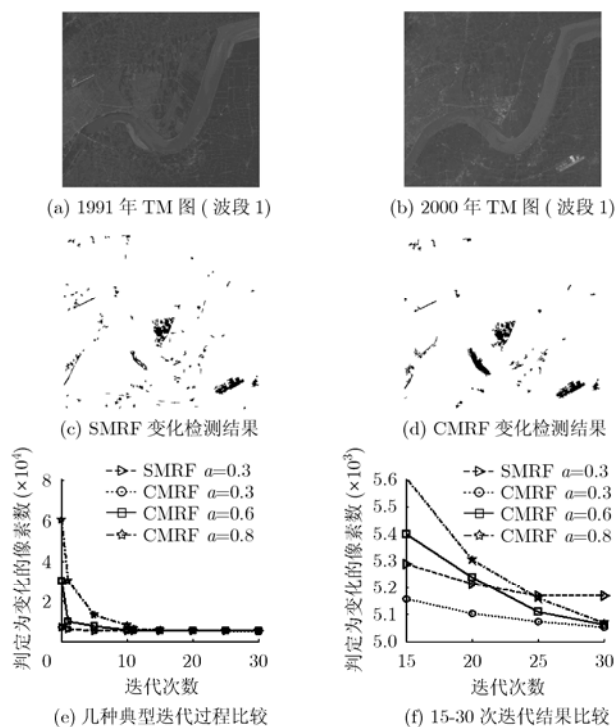


图1 两种算法对1991–2000年TM图像变化检测结果比较

代过程中没有再次进行标号重估,影响了标号估计的准确性。这说明如果观察场中所有像素均参与迭代过程,则初始标号场正确程度不影响实际检测结果。系数 α 只是用来提高执行效率。

原图变化前后图像对的直方图存在差异,说明图像对未做过校正,试验中分别采用原始图像对和经过直方图修正后的图像对作为原始图像,得到的结果基本相同,但采用不做修正的图像对,迭代次数多于校正后的图像对。说明基于CMRF模型的变化检测算法对光照变化鲁棒。

需要指出的是,CMRF尽管可以得到更准确的检测结果,但由于每次迭代过程需要重新计算像素特征,因此计算复杂度高,执行时间长,运行效率远低于SMRF算法。实际执行过程中,可根据具体图像和对变化检测结论精度要求,通过调整对称模型和非对称模型迭代次数、调整参数等手段达到效率和精度的平衡。

由以上试验可以看出,由于CMRF模型中观察场和标号场均服从MRF分布,两场中像素的特征与标号场的像素类别紧密相关,并随迭代过程不断优化,因此与其它无监督变化检测算法比较,基于CMRF的模型具有精度更高,处理过程无需先验知识,适用于不同光照及拍摄条件得到的图像的优势。

算法还具有较强的效率与精度的平衡能力。鉴于实际遥感图像情况多变,本算法提供多项可调节参数,如基团势能系数 β ,调整系数 α 、比例系数 k 以及温度 T 等,这些参数具有默认值,也可根据实际需要调整。设置参数的优势在于

提供无监督变化监测方法的同时,还可由用户根据具体需要调整,使系统具有更强适用性和更高效率。

5 结束语

本文在原有基于MRF的遥感图像变化检测理论的基础上,提出的基于双场互相关的马尔可夫随机场(CMRF)模型并通过试验证实利用该模型能够更准确获得变化检测结果。算法同时也有一些不足。如(1)计算量大。(2)根据差值图像实现的变化检测对土地变化类型无法判断。因此,基于差值灰度图像的变化检测算法作为遥感图像变化检测的方法,有两个作用:(0)作为其他变化检测算法(如基于PCA的算法或分类后比较法等)的辅助验证算法;或作为其他算法进一步判断处理的依据。(1)根据差值图像的变化检测结果,通过人工方式识别出变化类型,作为训练数据,提供给其他算法(如多时相直接分类法等)进一步分析土地变化类型,为土地开发利用分析预测提供依据。

多波段图像不同波段含有极为丰富的地质信息和地表环境信息,可以根据需要选择不同波段变化检测结果分析比较,动态监测土地利用情况,及时调整土地使用策略。

同时要指出的是,尽管在本文中,所提出的算法主要针对多时相遥感图像变化检测分析,但实际应用并不局限于此。本文所提出的基于CMRF的变化检测算法可应用于多种基于差值图像分析的变化检测。

参考文献

- [1] Carlotto M J. Detection and analysis of change in remotely sensed imagery with application to wide area surveillance. *Image Processing*, 1997, 6(1): 189–202.
- [2] Bruzzone L, and Prieto D F. Automatic analysis of the difference image for unsupervised change detection. *IEEE Trans. on Geosci and Remote Sensing*, 2000, 38(8): 1170–1182.
- [3] Fung T. An assessment of TM imagery for land-cover change detection. *IEEE Trans. on Geosci. Remote Sensing*, 1990, 28(12): 681–684.
- [4] Singh A. Digital change detection techniques using remotely sensed data. *Int. J. Remote Sensing*, 1989, 10(6): 989–1003.
- [5] Townshend Jr R G and Justice C O. Spatial variability of images and the monitoring of changes in the normalized difference vegetation index. *Int. J. Remote Sensing*, 1995, 16(12): 2187–2195.
- [6] Melgani F and Moser G. Unsupervised change-detection methods for remote-sensing images. *Opt. Eng*, 2002, 41(12): 3288–3297.
- [7] Nielsen A A, Conradsen K, and Simpson J J. Multivariate alteration detection(MAD) and MAF processing in multi-spectral, bitemporal image data: New approaches to change

- detection studies. *Remote Sensing Environ*, 1998, 64(1): 1-19.
- [8] Bruzzone L and Prieto D F. An adaptive semiparametric and context-based approach to unsupervised change detection multitemporal remote-sensing Images. *IEEE Trans. on Image Processing*, 2002, 11(4): 452-466.
- [9] Bazi Y, Bruzzone L, and Melgani F. An unsupervised approach based on the generalized Gaussian model to automatic change detection in multitemporal SAR images. *IEEE Trans. on Geosci and Remote Sensing*, 2005, 43(4): 874-887.
- [10] Wiemker D. An iterative spectral-spatial Bayesian labeling approach for unsupervised robust change detection on remotely sensed multispectral imagery. Proceedings of the 7th Int. Conf. on Computer Analysis of Images and Patterns, 1997, 1296: 263-270.
- [11] Kasetkasem T and Varshney P K. An image change detection algorithm based on Markov random field models. *IEEE Trans. on Geosci and Remote Sensing*, 2002, 40(8): 1815-1823.
- [12] Hammersley J M and Clifford P. Markov field on finite graphs and lattices. Unpublished manuscript, 1971.
- [13] Kashyap R and Chellappa R. Estimation and choice of neighbors in spatial interaction models of images, *IEEE Trans. on Inf. Theory*, 1983, IT-29(1): 60-72.
- [14] Geman S and Geman D. Stochastic relaxation, Gibbs distributions and the Bayesian restoration of images. *IEEE Trans. on Pattern Anal. Machine Intell*, 1984, MPAI-6(6): 721-741.
- [15] Li S Z, Rao C R, and Shanbhag D N. Modeling image analysis problems using Markov random fields. *Stochastic Processes: Modeling and Simulation*, 2000, 20(5): 1-43.
- [16] Jianchang M and Anil K J. Texture classification and segmentation using multiresolution simultaneous autoregressive models [J]. *Pattern Recognition*, 1992, 25(2): 173-188.
- [17] Kirkpatrick S, Gelatt C D, and Vecchi Jr M P. Optimization by simulated annealing. *Science*, 1983, 220(4598): 671-680.
- 袁 琪: 女, 1970年生, 博士生, 研究方向为图像处理, 模式识别、数据挖掘、数据库理论及应用。
- 赵荣椿: 男, 1937年生, 教授, 博士生导师, 主要研究方向为信号与信息处理、模式识别与智能控制。