

# 一种改进的 Laplacian SVM 的 SAR 图像分割算法

刘若辰<sup>1</sup>, 邹海双<sup>1</sup>, 张莉<sup>2</sup>, 张萍<sup>1</sup>, 焦李成<sup>1</sup>

(1. 西安电子科技大学智能信息处理研究所 智能感知与图像理解教育部重点实验室, 陕西 西安 710071;

2. 苏州大学 计算机科学与技术学院, 机器学习与数据分析研究中心, 江苏 苏州 215006)

**摘要:** 当有标识的样本数量有限时, Laplacian SVM 算法需要加入尽量多的无标识样本, 以提高分类精度. 但同时当无标识样本数很大时, 算法的时间和空间复杂度将难以接受. 为了将 Laplacian SVM 应用于 SAR 图像分割这样的大规模分类问题中, 提出了一种改进的 Laplacian 支持向量机算法 (Improved Laplacian Support Vector Machine, Improved Laplacian SVM), 首先采用分水岭算法将原始 SAR 图像分成多个小原型块, 提取每个小原型块的图像特征作为训练样本. 再采用改进的 Laplacian SVM 算法得到小原型块分类结果. 通过 3 幅 SAR 图像验证了提出的方法, 实验表明该方法不仅提高了分割的准确性同时减少了 Laplacian SVM 算法用于图像分割时的运行时间.

**关键词:** LapSVM 算法; 图像分割; 分水岭算法; SAR 图像

**中图分类号:** TP751 **文献标识码:** A

## An improved Laplacian SVM algorithm for SAR image segmentation

LIU Ruo-Chen<sup>1</sup>, ZOU Hai-Shuang<sup>1</sup>, ZHANG Li<sup>2</sup>, ZHANG Ping<sup>1</sup>, JIAO Li-Cheng<sup>1</sup>

(1. Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education of China, Institute of Intelligent Information Processing, Xidian University, Xi'an 710071, China;

2. Research Center of Machine Learning and Data Analysis, School of Computer Science and Technology, Soochow University, Suzhou 215006, China)

**Abstract:** When the number of labeled samples is limited, Laplacian SVM needs as many as possible unlabeled samples to improve the performance of classification. However, when the number of unlabeled samples is large, the required time and space complexity would be unacceptable. In order to apply it to large-scale classification problems like SAR image segmentation, a new method for SAR image segmentation named as improved Laplacian support vector machine algorithm (Improved Laplacian SVM) was proposed. Watershed algorithm was first used to decompose the original image into several small prototype blocks, and image features of each small prototype blocks were extracted as training samples. Then an improved Laplacian SVM algorithm was proposed to classify data sets. The proposed method was verified on three SAR images. The experiments show that the method not only improves the accuracy of segmentation but also greatly reduces the running time of Laplacian SVM algorithm for image segmentation.

**Key words:** Laplacian SVM; image segmentation; watershed algorithm; SAR image

**PACS:** 40. 41. 20. Jb

## 引言

近年来,随着合成雷达孔径(SAR)技术的发展, SAR 图像分割作为 SAR 图像分析的基础,已经受到越来越多的重视<sup>[1,2]</sup>. SAR 图像分割就是把一副给定的 SAR 图像按照一定的分割准则分成各具特点的区域. 通过 SAR 图像分割,提取出感兴趣的目标区域,为后期的目标识别和分类奠定基础. 而有效

的分割方法是得到更好的目标区域的关键.

分类方法是模式识别领域中一种基本的学习分析方法,也是一种重要的图像分割方法. 分类的目的是利用已知类别的训练样本集在图像的特征空间(或其变换空间)找到分类决策的点、线、面或超面以实现图像像素的分类,从而达到图像分割的目的. 传统的分类方法都是基于监督学习的算法. 然而,监督学习算法需要通过大量有标识的训练样

收稿日期:2010-12-21,修回日期:2011-02-18

Received date: 2010-12-21, revised date: 2011-02-18

基金项目:国家自然科学基金(60803098, 60970067); 国家教育部博士点基金(20070701022), 高等学校学科创新引智计划(111计划)(B07048), 陕西省自然科学基金(2010JM8030)

作者简介:刘若辰(1974-),女,陕西武功人,副教授,主要研究领域为免疫计算和数据挖掘. E-mail: aliang3399@gmail.com.

本进行学习,从而建立模型对未标识样本进行预测. 这些算法都忽略了未标识样本的作用. 另一方面,实际应用中获取大量未标识样本相对于获取大量有标识样本要容易得多,因为对未知标识的样本进行标识,可能要花费大量的人力和物力. 基于这些事实,提出了半监督学习算法<sup>[3,4]</sup>. 半监督学习在训练过程中同时利用了有标识样本和未标识样本,使得训练得到的判决函数中含有未标识样本的信息,用该函数对这些未标识样本进行判断,得到的正确识别率比仅仅利用有标识本来训练再判决所得到的识别正确率要高. 近几年,半监督学习逐渐成为机器学习领域的一个研究热点,在众多领域得到了广泛应用.

Jiazhen Xu 等人<sup>[4]</sup>在 2008 年提出利用 Laplacian SVM 算法进行自然图像的分割,能够得到较好的分割效果. Laplacian SVM<sup>[5]</sup>是 Belkin 等人提出的一种基于流形正则的半监督分类算法. 该算法在传统的 SVM 中加入了无标识样本的流形结构信息,并将这一信息以 Laplacian 正则项形式加入到 SVM 的优化函数中. 当有标识样本数目很少时,该算法的分类结果明显优于传统的 SVM 方法. 理论上,加入训练的无标识样本越多,训练精度越高. 但对于大规模数据的分类问题,将所有无标识样本作为训练样本是不现实的. 一方面由于需要计算的 Laplacian 矩阵过大,容易出现内存不足;另一方面过多的无标识样本导致检测时间太长. 所以要利用 Laplacian SVM 算法进行有效地图像分割,还需解决计算的空间和时间复杂度问题.

基于此,本文提出了一种改进的 Laplacian SVM 算法的 SAR 图像分割方法. 该方法利用分水岭<sup>[6,7]</sup>的过分割现象来减少参加 Laplacian SVM 分类的样本数,同时又能充分利用图像的所有像素特征来提高分类正确率. 在纹理和 SAR 图像分割上验证了本文提出的方法,实验结果显示本文方法不仅提高了分割的准确性也大大减少了 Laplacian SVM 算法用于图像分割时的运行时间.

## 1 Laplacian SVM 算法

Laplacian SVM (简称 LapSVM)算法是一种基于样本流形正则的半监督学习算法. 它将所有样本间的固有几何结构信息,即两个在空间距离上相邻的样本应该属于同一类,扩展到再生核希尔伯特空间(RKHS)的经典正则化框架中,并以附加的正则项表现出来,称为流形正则项. 将流形正则项加入

到传统的有监督学习算法 SVM 中,便得到 Laplacian SVM 算法.

### 1.1 Laplacian SVM 算法

SVM 算法是根据 Vapnik 结构风险最小化原则提出的学习方法. 对于给定的训练集  $\{(x_i, y_i)\}_{i=1}^l$ , 其中  $x_i$  表示第  $i$  个样本,  $y_i \in \{1, -1\}$  标识样本所属类别, SVM 算法选择 RKHS 作为假设空间  $H_K$ , 最小化结构风险泛函表示如下

$$f^* = \operatorname{argmin}_{f \in H_K} \frac{1}{l} \sum_{i=1}^l (1 - y_i f(x_i))_+ + \gamma \|f\|_K^2 \quad (1)$$

其中  $(1 - y_i f(x_i))_+ = \max(0, 1 - y_i f(x_i))$  表示边界损失函数,  $\|f\|_K^2$  是正定核诱导的  $H_K$  中函数  $f$  的范数,  $\gamma$  是用于控制分类器复杂度的参数.

对 SVM 算法进行扩展,假设  $\{(x_i, y_i)\}_{i=1}^l$  表示有标识样本集,其中  $x_i$  表示第  $i$  个样本,  $y_i \in \{1, -1\}$  标识样本所属类别,  $\{x_j\}_{j=l+1}^{l+u}$  表示无标识样本集,将无标识样本信息以流形正则项形式加入进来,得到 LapSVM 的学习模型:

$$f^* = \operatorname{argmin}_{f \in H_K} \frac{1}{l} \sum_{i=1}^l (1 - y_i f(x_i))_+ + \gamma_A \|f\|_K^2 + \frac{\gamma_I}{(l+u)^2} f^T L f \quad (2)$$

由表示理论<sup>[9]</sup>得到该问题的解具有如下形式:

$$f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x, x_i) \quad (3)$$

利用拉格朗日乘子法得到公式(4)和(5):

$$\alpha^* = (2\gamma_A I + 2 \frac{\gamma_I}{(u+l)^2} LK)^{-1} J^T Y \beta^* \quad (4)$$

$$\beta^* = \max_{\beta \in \mathbf{R}^l} \sum_{i=1}^l \beta_i - \frac{1}{2} \beta^T Q \beta$$

$$s. t. \quad \sum_{i=1}^l y_i \beta_i = 0$$

$$0 \leq \beta_i \leq \frac{1}{l} \quad i = 1, \dots, l \quad (5)$$

其中:  $Q = YJK(2\gamma_A I + 2 \frac{\gamma_I}{(l+u)^2} LK)^{-1} J^T Y$ .

优化问题(2)可采用类似于标准 SVM 中求解二次规划的方法得到该问题的最优解  $\beta^*$ , 将  $\beta^*$  代入公式(4)中便得到原规划问题的最优解  $\alpha^*$ . 当  $\gamma_I = 0$  时, LapSVM 就成为标准的 SVM. 表 1 给出了 LapSVM 算法的具体执行步骤.

### 1.2 改进的 Laplacian SVM 算法

LapSVM 算法中采用无标识样本和有标识样本

表 1 LapSVM 算法  
Table 1 LapSVM algorithm

输入:	$l$ 个有标识样本 $\{(x_i, y_i)\}_{i=1}^l, u$ 个无标识样本 $\{x_j\}_{j=l+1}^{l+u}$
输出:	判决函数 $f: R^n \rightarrow R$
Step1:	用 $l+u$ 个结点建立一个数据邻接图, 如果结点 $i$ 在结点 $j$ 的 $n$ 近邻中或者 $j$ 在 $i$ 的 $n$ 近邻中, 利用热核函数 $W_{ij} = e^{-\ x_i - x_j\ ^{2/4t}}$ 计算连接 $i$ 和 $j$ 的边的权值 $W_{ij}$ , 否则, $W_{ij} = 0$ .
Step2:	计算图的 Laplacian 矩阵: $L = D - W$ , $D$ 是一个对角矩阵, $D_{ii} = \sum_{j=1}^{l+u} W_{ij}$
Step3:	选择一个核函数: $K(x, y)$ , 计算 Gram 矩阵 $K_{ij} = K(x_i, x_j)$ .
Step4:	选择正则化参数 $\gamma_A$ 和 $\gamma_I$ .
Step5:	利用 SVM 方法中求解二次规划问题的方法求解最优化问题 (5), 得到 $\alpha^*$ .
Step6:	输出函数 $f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x, x_i)$ .

共同来构造图, 进而用图来逼近流形. 构造的图的好坏直接影响到能否准确地反映数据的内在结构. 当样本具有明显流形结构, 但有标识样本很少不足以反映这种结构时, 图将对分类结果起主要作用. 所以有必要在 LapSVM 算法中构造一种尽可能逼近流形的图. 在 LapSVM 算法中通常采用热核函数  $W_{ij} = e^{-\|x_i - x_j\|^{2/4t}}$  来构造图, 然而该函数中参数  $t$  的取值在不同的数据集上是不确定的, 不正确的取值将会影响识别的正确率.

为了避免选择  $t$  所带来的问题, 我们采用 Zelnik-Manor<sup>[8]</sup> 等人提出的基于样本局部邻域性质的图, 由于该方法中两两样本间的相似度是随局部统计量自适应改变的, 所以本文称它为自调节图, 用它来替代热核函数构造的图.

将样本  $x_j$  到样本  $x_i$  的距离定义为  $d(x_i, x_j)/\sigma_i$ , 类似的, 从样本  $x_j$  到样本  $x_i$  的距离定义为  $d(x_j, x_i)/\sigma_j$ . 这样传统意义上的平方距离  $d^2$  可以记作:

$$\frac{d(x_i, x_j)d(x_j, x_i)}{\sigma_i\sigma_j} = \frac{d^2(x_i, x_j)}{\sigma_i\sigma_j}, \quad (6)$$

两样本间的相似度定义为:

$$\hat{W}_{ij} = \exp\left(-\frac{d^2(x_i, x_j)}{\sigma_i\sigma_j}\right), \quad (7)$$

其中, 局部核参数  $\sigma_i$  和  $\sigma_j$  分别通过学习  $x_i$  和  $x_j$  的局部统计特性得到.  $\sigma_i$  可用下面的式子计算得到:

$$\sigma_i = d(x_i, x_K), \quad (8)$$

这里  $x_K$  表示样本点  $x_i$  的第  $K$  个近邻,  $d(x_i, x_K)$

表 2 改进的 LapSVM 算法  
Table 2 Improved LapSVM algorithm

输入:	$l$ 个有标识样本 $\{(x_i, y_i)\}_{i=1}^l, u$ 个无标识样本 $\{x_j\}_{j=l+1}^{l+u}$ .
输出:	判决函数 $f: R^n \rightarrow R$
Step1:	用 $l+u$ 个结点建立一个数据邻接图, 如果结点 $i$ 在结点 $j$ 的 $n$ 近邻中或者 $j$ 在 $i$ 的 $n$ 近邻中, 根据 (11) 得到参数 $\sigma_i$ 和 $\sigma_j$ , 用式 (7) 计算连接 $i$ 和 $j$ 的边的权值 $\hat{W}_{ij}$ , 否则, $\hat{W}_{ij} = 0$ .
Step2:	计算图的 Laplacian 矩阵: $L = D - \hat{W}$ , $D$ 是一个对角矩阵, $D_{ii} = \sum_{j=1}^{l+u} \hat{W}_{ij}$ .
Step3:	选择一个核函数: $K(x, y)$ , 计算 Gram 矩阵 $K_{ij} = K(x_i, x_j)$ .
Step4:	选择正则化参数 $\gamma_A$ 和 $\gamma_I$ .
Step5:	利用 SVM 方法中求解二次规划问题的方法求解最优化问题 (4), 得到 $\alpha^*$ .
Step6:	输出函数 $f^*(x) = \sum_{i=1}^{l+u} \alpha_i^* K(x, x_i)$ .

表示样本  $x_i$  和  $x_K$  间的欧式距离. 类似的, 用样本  $x_j$  到其第  $K$  个近邻  $x'_K$  的欧式距离作为参数  $\sigma_j$  的取值. 在我们的实验中, 设置  $K=7$  就可以得到较好的结果. 表 2 给出了改进的 LapSVM 算法的具体执行步骤.

上述算法利用训练集中的未标识样本和有标识样本共同参与图的建立、图的 Laplacian 矩阵的求解以及 Gram 矩阵的计算, 在得到判决函数后, 分别对未标识样本及测试样本进行分类. 未标识样本的作用是与有标识样本一起建立图, 进而用图来逼近流形. 由于我们是利用流形结构来帮助挖掘数据的内在结构, 所以数据越充分, 对于流形的逼近会越有利. 学习中有标识样本数量是有限的, 我们可以将测试集中的无标识样本加入到训练集中来参加图的建立, 而且加入的无标识样本越多, 越能逼近数据的内在结构. 然而, 随着训练集中无标识样本的增多, 训练的时间和空间复杂度都会增加. 特别是对于像图像分割这样的大规模数据分类问题, 将所有无标识样本用于构造图是不现实的. 另外, 大规模数据分类中对无标识样本的测试也需要大量的时间. 如何才能使更多的无标识样本加入到图的构造中, 同时又能缩短测试时间. 针对该算法用于图像分割中出现的计算复杂度问题, 本文提出了一种新的解决方法.

## 2 结合分水岭和改进的 LapSVM 算法的图像分割

分水岭算法容易出现过分割现象, 但同时又很

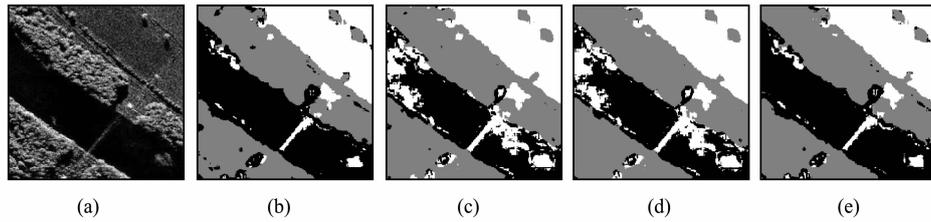


图 1 SAR 图像 1 的分割 (a)原图 (b)SVM 算法 (c)LapSVM 算法 (d)结合分水岭和 LapSVM 算法 (e)结合分水岭和改进的 LapSVM 算法

Fig. 1 Segmentation Results of SAR Image1 (a)Original image (b)SVM (c)LapSVM (d)Image segmentation method combining watershed and LapSVM (e)Image segmentation method combining watershed and improved LapSVM

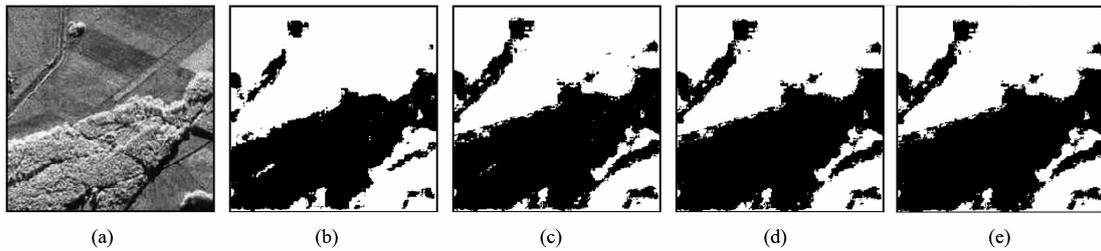


图 2 SAR 图像 2 的分割 (a)原图 (b) SVM 算法 (c)LapSVM 算法 (d)结合分水岭和 LapSVM 算法 (e)结合分水岭和改进的 LapSVM 算法

Fig. 2 Segmentation Results of SAR Image2 (a)Original image (b)SVM (c)LapSVM (d)Image segmentation method combining watershed and LapSVM (e)Image segmentation method combining watershed and improved LapSVM

好地保持了图像边界. 本文中的算法利用分水岭的过分割现象来减少参加 LapSVM 训练和测试的样本数,同时又能充分利用图像的所有像素特征来提高识别正确率. 我们首先采用分水岭算法将原始图像分成多个小原型块,提取每个小原型块的图像特征作为进行后续分类的样本数据,再采用改进的 LapSVM 算法对样本进行分类从而得到最终的分割结果.

设  $X = \{x_1, x_2, \dots, x_n\}$  是分水岭过分割产生的块特征向量集,其中  $n$  为原型块个数,  $\{(x_i, y_i)\}_{i=1}^l$  表示  $l$  个有标识像素的特征向量集,具体算法描述如下:

Step 1: 将  $n$  个块特征向量作为无标识样本,  $l$  个有标识像素的特征向量作为有标识样本,利用基于自调节图的 LapSVM 算法进行分类,得到  $n$  个块特征向量的类别标识;

Step2: 每个小原型块中像素的类别标识与块特征向量的类别标识保持一致,从而得到整幅图像的初始分割结果;

Step3: 计算初始分割结果图的梯度,得到梯度图;

Step4: 提取梯度值非零的像素所在的小原型块内的所有像素,将这些像素的特征向量作为无标识

样本,  $l$  个有标识像素的特征向量作为有标识样本,再次利用基于自调节图的 LapSVM 算法进行分类,重新得到边缘附近的小原型块内像素的类别标识;

Step5: 将初始分割结果图中对应于步骤 4 中的那部分像素的类别标识进行重新标记,其余像素的类别标识保持不变,从而得到最终的分割结果图.

### 3 实验与结果分析

为了验证新方法的有效性,将其用于 SAR 图像分割,并分别采用 SVM 算法、LapSVM 算法、结合分水岭和 LapSVM 算法的图像分割方法和结合分水岭和改进的 LapSVM 算法的图像分割方法进行对比实验.

提取的图像特征分别是灰度共生矩阵统计特征<sup>[9]</sup>和小波变换特征<sup>[10]</sup>,其中图像的滑窗窗口的大小分别是:  $9 \times 9$  和  $16 \times 16$ . 对灰度共生矩阵分别取角二阶矩、熵、对比度和相关性在 0 度、45 度、90 度和 135 度四个方向上的统计量构成 16 维统计特征,对小波变换提取三层分解的 10 维能量特征,共构成 26 维特征向量,并将特征向量归一化到  $[-1, 1]$ . 实验中采用的图像大小均为  $256 \times 256$ .

图 1, 图 2 和图 3 分别给出了两类、三类的 SAR 图像分割结果. 原始 SAR 图像如图 1(a)、图

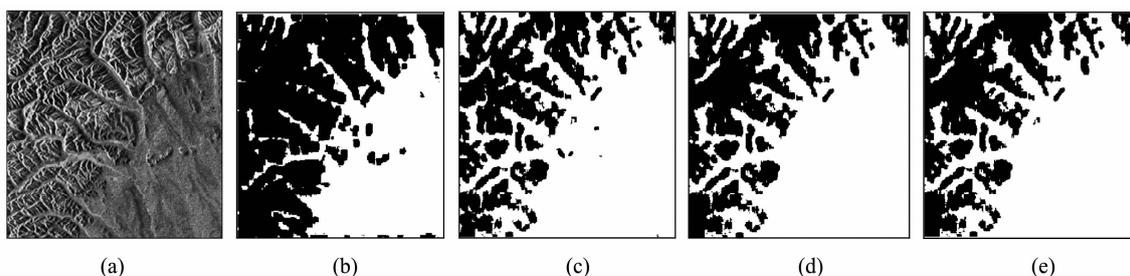


图3 SAR图像3的分割 (a)原图 (b)SVM算法 (c)LapSVM算法 (d)结合分水岭和LapSVM算法 (e)结合分水岭和改进的LapSVM算法

Fig. 3 Segmentation Results of SAR Image 3 (a)Original image (b)SVM (c)LapSVM (d)Image segmentation method combining watershed and LapSVM (e)Image segmentation method combining watershed and improved LapSVM

表3 SAR图像实验参数设置

Table 3 Parameters setting for SAR image segmentation

SAR 图像	分割方法	近邻核函数个数	高斯核函数参数 $\sigma$	$\gamma$	$\gamma_A$	$\gamma_I$	训练样本数 $l$
SAR1	SVM	-	2.0	10	-	-	150
	LapSVM	7	2.0	8	0.000417	27.58	150
SAR2	SVM	-	3.0	10	-	-	100
	LapSVM	7	3.0	8	0.000625	60.06	100
SAR3	SVM	-	3.0	10	-	-	100
	LapSVM	7	3.0	8	0.000625	60.06	100

2(a)、图3(a)所示。其中图1(a)是位于新墨西哥州 Albuquerque 城附近的 Rio Grande 河流的 Ku 波段 SAR 图像,分辨率为 1 米,其中包含 3 类地物:植被、河流和农作物。四种方法的具体参数设置如表 3 所示。

结合分水岭和 LapSVM 算法的图像分割方法和结合分水岭和改进的 LapSVM 算法的图像分割方法中相关参数的设置与基于 LapSVM 算法的图像分割方法中的参数取值相同。

从三幅 SAR 图像的分割结果可以看出,结合分水岭和改进的 LapSVM 算法的图像分割方法较 SVM 算法、LapSVM 算法和结合分水岭和 LapSVM 算法的图像分割方法,在图像的区域一致性上要好,区域内的离散点少了很多。

为了对 SAR 图像分割结果进行定性分析,我们对 SAR 图像正确识别率, Kappa 系数以及平均运行时间进行了统计。结果如表 4 所示。从表 4 中可以看出,结合分水岭和改进的 LapSVM 算法在正确率以及 Kappa 系数上都要比其余三个算法优。同样可以看出, SVM 算法所用时间最少,但是分割效果不如本文提出的结合分水岭和改进的 LapSVM 算法的图像分割方法。另外,结合分水岭的两种图像分割方法较原始 LapSVM 算法在运行时间上有较大的优势。

表4 SAR 图像的实验结果(正确率(%), Kappa 系数以及运行时间(秒))

Table 4 Results of SAR images (accuracy rate (%), Kappa coefficient and running time (in second))

SAR 图像	SVM 算法	LapSVM 算法	结合分水岭和 LapSVM 算法	结合分水岭和改进的 LapSVM 算法
正确率	91.45	73.24	74.21	<b>96.41</b>
SAR1 Kappa 系数	0.8709	0.5743	0.5896	<b>0.9453</b>
运行时间	3.85	312.93	108.79	122.28
正确率	98	98.5	98.67	<b>98.83</b>
SAR2 Kappa 系数	0.9543	0.9661	0.9697	<b>0.9735</b>
运行时间	2.63	106.5	44.81	48.33
正确率	72.67	92.17	93.33	<b>93.50</b>
SAR3 Kappa 系数	0.4969	0.8147	0.8421	<b>0.8463</b>
运行时间	1.3044	50.1771	23.9596	28.8863

## 4 结论

本文提出了一种结合分水岭和改进的 Laplacian SVM 算法的图像分割方法。为了避免构建图时出现的参数选择问题,将自调节图引入到 Laplacian SVM 算法中。另外,由于 Laplacian SVM 算法中用到图和核函数的思想,将其应用到图像分割问题时,会出现存储量和计算量大的问题。该算法利用分水岭算法对图像先进行粗分割,再使用改进的 Laplacian SVM 算法对过分割区域进行分类,从而加快了算法的速度。在图像分割的对比实验中,提出的算法取得了较好的分割效果。

## REFERENCES

- [1] Zhang X R, Jiao L C, Liu F, *et al.* Spectral Clustering Ensemble Applied to SAR Image Segmentation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, **46** (7):2126—2136.

(下转 259 页)

HEMT 在 10V 漏压下的  $f_T$  达到 44GHz,  $f_{max}$  达到 120GHz; 当漏压为 30V 时,  $f_T$  为 32GHz,  $f_{max}$  为 150GHz; 30GHz 连续波测试条件下, 线性增益达到 10.2dB.  $6 \times 75\mu\text{m}$  栅宽 AlGaIn/GaN HEMT 在漏压 30V 下  $f_T$  为 32GHz,  $f_{max}$  为 92GHz; 30GHz 连续波测试条件下, 线性增益 8.5dB. 受测试条件的限制, 没有得到这两种器件在 Ka 波段的最大输出功率. 但已有的测试数据表明, 所研制的 AlGaIn/GaN HEMT 是可以应用于 Ka 波段的. 这也说明所采用的提高 AlGaIn/GaN HEMT 频率的设计措施是有效的, 用国内的 GaN 外延片和工艺实现 Ka 波段甚至更高频率 AlGaIn/GaN HEMT 是可行的.

### REFERENCES

- [1] WU Y F, MOORE M, SAXLER A, *et al.* 40-W/mm double field-plated GaN HEMTs. IEEE 64th Device Research Conference, 2006[C]. Goleta; Cree Inc., 2006:151 - 152.
- [2] VETURY R, WEI Y, GREEN D S, *et al.* High power, high Efficiency, AlGaIn/GaN HEMT technology for wireless base station applications. IEEE MTT-S International Microwave Symposium digest, 2005 [C]. Charlotte; [s. n.], 2005: 487—490.
- [3] PALACIOS T, CHAKRABORTY A, RAJAN S, *et al.* High-power AlGaIn/GaN HEMTs for Ka-band applications [J]. *IEEE Electron Device Letters*, 2005, **26**(11):781—783.
- [4] WU Y F, MOORE M, SAXLER A, *et al.* 8-watt GaN HEMTs at millimeter-wave frequencies. IEEE International Electron Devices Meeting, 2005 [C]. [s. l.]: [s. n.], 2005:583—585.
- [5] MICOVIC M, KURDOGHLIAN A, HASHIMOTO P, *et al.* GaN HFET for W-band power applications. IEEE International Electron Devices Meeting, 2006 [C]. Malibu; [s. n.], 2006:1—3.
- [6] JIMENEZ J L, CHOWDHURY U. X-band GaN FET reliability. IEEE 46th International Reliability Physics Symposium, 2008 [C]. Richardson; [s. n.], 2008:429—435.
- [7] WANG Dongfang, CHEN Xiaojuan, LIU Xinyu. A Ku-band 3.4W/mm power AlGaIn/GaN HEMT on a sapphire substrate[J]. *Journal of Semiconductors* (王东方, 陈晓娟, 刘新宇. 基于蓝宝石衬底的 Ku 波段 3.4W/mm AlGaIn/GaN HEMT. *半导体学报*), 2010, **31**(2):024001-1 ~ 024001-2.
- [8] WANG Dongfang, WEI Ke, YUAN Tingting, *et al.* High performance AlGaIn/GaN HEMTs with 2.4 $\mu\text{m}$  source-drain spacing[J]. *Journal of Semiconductors* (王东方, 魏珂, 袁婷婷, 等. 源漏间距 2.4 $\mu\text{m}$  的高性能 AlGaIn/GaN HEMT. *半导体学报*), 2010, **31**(3):034001-1 ~ 034001-3.
- [9] SUN Y, EASTMAN L F. Trade-offs and challenges of short channel design on millimetre-wave power performance of GaN HFETs[J]. *Electronics Letters*. 2005, **41**(15).
- [10] WANG Dongfang, LIU Xinyu. Simulation on Gate Structure of Ka Band AlGaIn/GaN HEMT[J]. *Chinese Journal of Electron Devices* (王东方, 刘新宇. Ka 波段 AlGaIn/GaN HEMT 栅结构仿真. *电子器件*), 2009, **32**(5):859—863.
- [11] WANG Dongfang, YUAN Tingting, WEI Ke, *et al.* Gate-structure optimization for high frequency power AlGaIn/GaN HEMTs[J]. *Journal of Semiconductors* (王东方, 袁婷婷, 魏珂, 等. 高频功率 AlGaIn/GaN HEMT 的栅结构优化. *半导体学报*), 2010, **31**(5):054003-1—054003-4.
- [12] INOUE Takashi, ANDO Yuji, MIYAMOTO Hironobu, *et al.* 30-GHz-band over 5-W power performance of short-channel AlGaIn/GaN heterojunction FETs [J]. *IEEE Transactions on Microwave Theory and Technique*, 2005, **53**(1):74—80.
- [1] HOU Biao, ZHAI Yan-Xia, JIAO Li-Cheng. Second Generation Bandelet-Domain Hidden Markov Tree-3S Model For SAR Image Segmentation [J]. *J. Infrared Millim. Waves* (侯彪, 翟艳霞, 焦李成. 用于 SAR 图像分割的第二代 Bandelet 域 HMT-3S 模型, *红外与毫米波学报*), 2010, **29**(2):145—149.
- [2] Zhu X J. *Semi-supervised learning literature survey* [M]. Computer Sciences Technical Report 1530, University of Wisconsin-madison, July, 2008.
- [3] Xu J Z, Chen X M, Huang X J. Interactive Image Segmentation by Semi-supervised Learning Ensemble [C]. *Proceedings of the 2008 International Symposium on Knowledge Acquisition and Modeling*. IEEE Computer Society, 2008, 645—648.
- [4] Belkin M, Niyogi P, Sindhvani V. Manifold Regularization: a Geometric Framework for Learning from Labeled and Unlabeled Examples [J]. *Journal of Machine Learning Research*, 2006, **7**:2399—2434.
- [5] Vincent L, Solille P. Watershed in Digital Spaces: An Efficient Algorithm Based Immersion Simulations [J]. *IEEE Trans. on PAMI*, 1991, **13**(6):38—598.
- [6] Haris K. Hybrid Image Segmentation Using Watersheds and Fast Region Merging [J]. *IEEE Transactions on Image Processing*, 1998, **7**(12):1684—1699.
- [7] Zelnik M L, Perona P. Self-Tuning Spectral Clustering [C]. *Advances in Neural Information Processing Systems*, MIT Press, 2004, **17**:1601—1608.
- [8] Hu Z L, Guo D Z, Sheng Y H. Extracting textural information of satellite SAR image based on wavelet decomposition [J]. *Journal of Remote Sensing*, 2001, **5**:423—427.
- [9] Wu K P, Wang S D. Choosing the Kernel parameters of Support Vector Machines According to the Inter-cluster Distance [J]. *Pattern Recognition*, 2009, **42**(5):710—717.

(上接 254 页)