

高斯-瑞利混合模型在遥感图像分割中的应用

侯一民 唐玥 孙晓雪 隋文秀

东北电力大学自动化工程学院, 吉林 吉林 132012

摘要 在遥感图像的众多分割方法中,高斯混合模型(GMM)是一种常用的图像建模方法。提出了高斯-瑞利混合模型(GRMM)可能更适合对遥感图像建模。介绍了传统高斯混合模型和高斯-瑞利混合模型的区别。比较了这两种混合模型对图像建模的结果,并用数据说明高斯-瑞利混合模型拟合图像的像素分布误差更小。采用最大熵方法确定图像的最佳分类数,采用马尔可夫随机场(MRF)方法及新的势能函数完成图像的分割,采用迭代条件模型(ICM)完成分割过程中的最大后验概率计算问题。在实验中采用了 3 幅遥感图像,实验过程中比较了各个图像运用高斯混合模型和高斯-瑞利混合模型的分割和拟合结果,分别通过数据和分割结果体现了该分割方法的效果。

关键词 图像处理; 遥感图像分割; 高斯-瑞利混合模型; 最大熵; 马尔可夫随机场; 势能函数

中图分类号 TP391 文献标识码 A

doi: 10.3788/AOS201535.s110004

Application of Gaussian-Rayleigh Mixture Model in Remote Sensing Image Segmentation

Hou Yimin Tang Yue Sun Xiaoxue Sui Wenxiu

College of Automation Engineering, Northeast Dianli University, Jilin, Jilin 132012, China

Abstract Among the remote sensing images segmentation methods, Gaussian mixture model (GMM) is the widely used image model. Gaussian-Rayleigh mixture model (GRMM) is proposed, and it may be more suitable for remote sensing image modeling. The difference between classical GMM and GRMM is introduced. The modeling results of GMM and GRMM to the images are compared. The comparison data shows that the GRMM has less distribution errors than the GMM when modeling the images. The entropy-max method is utilized to determine the optimal class number. The Markov random field (MRF) and a new potential function is employed to segment the images. The iterative conditional model (ICM) is used to calculate the maximum posteriori probability. Three remote sensing images are utilized in the experiment, the fitting and segmentation results of GMM and GRMM are compared in the experiment process. The data and segmentation results show that the proposed method is more effective.

Key words image processing; remote sensing image segmentation; Gaussian-Rayleigh mixture model; entropy-max; Markov random field; potential function

OCIS codes 100.2000; 100.3005; 100.3008

1 引 言

遥感成像是一种广泛应用于农业、环境科学、地理学、气候预测以及军事领域的技术。遥感图像包含了大量的数据信息,但由于很难将图像中的细节信息准确分类,因此,遥感图像分割一直是本领域很受关注的科学问题^[1]。众多学者针对遥感图像的分割^[2-3]和目标检测^[4-5]进行了研究工作。

为了提高遥感图像的分割效果,研究者们采用了多种方法。Fan^[6]等在其文献中,运用基于图像先验信息的单点叠加加权模糊 C 均值分类算法对遥感图像进行分割。传统模糊 C 均值方法的问题是受数据分布和分类中心的随机初始化影响较大。该方法可以解决以上问题,运用了伯克利的图像分割数据库作为实验数据,实验结果验证了文中方法的效果。Mylonas 等^[7]在其文献中提出了模糊遥感图像的分割方法。首先,运用支持向量机对图像像素进行分类,之后,根据模糊成员图(FMM)理论,最终运用遗传序列图像分割来得

收稿日期: 2015-01-25; 收到修改稿日期: 2015-03-02

基金项目: 国家自然科学基金(60662003)、吉林省科技发展计划(20150414051GH)、吉林市科技计划(201362507)

作者简介: 侯一民(1978-),男,博士,副教授,主要从事图像处理与模式识别方面的研究。E-mail: ymh7821@163.com

到最终的分割结果。Wan 等^[8]提出了一种基于均值移动算法的遥感图像分割方法。在给定了初始的参数窗口之后,每个迭代步骤中,算法可以自适应的判断窗口的大小,而窗口的大小是随着迭代时间缩减,提高了分割算法的速度。Pal 等^[9]评价了基于核函数的学习机算法对遥感图像的分割结果,并将此方法与支持向量机分割法进行比较。Du 等^[10]提出了一种新的基于数据融合、多特征组合以及合作学习的算法来提高遥感图像的分割精度,在实验中采用了多光谱全色遥感图像并验证了结果。

图像分割过程中,经常根据混合模型为图像数据建模。这种方法将图像中的像素分为多个类,每一类认为是混合模型中的符合某种概率分布的数据组合。以最常用的高斯混合模型为例,每一类数据拥有自己特定的均值和方差,并且在进一步的图像分割中,将各个类的均值和方差认为是分割过程中不可或缺的参数。由此而形成的参数组合,经过一定方法的优化,最终完成对图像中所有像素的分类,即完成图像分割^[11]。Lunga 等^[12]采用了基于 Kent 混合模型的无监督图像分割方法,但是,从根本上说,Kent 模型是基于高斯模型的。高斯混合模型还是最普遍的混合模型方法。Zhang 等^[13]提出了一种基于高斯混合模型的脑核磁共振图像的分割方法。Deng 等^[14]提出了一种基于马尔可夫随机场的图像分割方法,方法中对图像数据的先验知识就是其符合高斯混合模型。Zhou 等^[15]提出了一种脑核磁图像的分割方法,也是认为脑核磁图像中,各个组织部分的图像数据符合高斯分布。

高斯混合模型虽然是最常用的模型,但未必适合所有的图像,有很多图像更加符合高斯-瑞利模型的分布。例如,Seng 等^[16]提出了基于高斯-瑞利混合模型的图像分割方法,文中主要针对雷达图像进行分割,其结果较好。但该文仅仅将图像像素的 K 类中第 1 类和最后一类认定为瑞利分布,而中间的各个类都认为是高斯分布。这是由于图像像素有固定的值域,第 1 类和第 K 类受到值域的限制更加符合瑞利分布。Debes 等^[17]也将雷达图像进行了以上的定义。但是根据观察,除了处于值域两端的类,处于值域中间的像素类也有更趋近于瑞利分布的模型。

本文提出了一种基于高斯-瑞利混合模型的遥感图像分割方法,将遥感图像数据认为是高斯-瑞利的混合分布,并且对图像中的各个类在高斯分布和瑞利分布中进行选择,以分布拟合精度来判断最终的图像混合模型。确定混合模型之后,采用改进的马尔可夫随机场(MRF)算法进行最终的图像分割。原始图像经过 K 均值分割之后,得到了 2 类分割,3 类分割,以至 10 类分割的结果。根据确定的最佳分类数及相应的 K 均值初始分割结果,将各类数据分别采用高斯模型(GM)和瑞利模型(RM)进行拟合,取高斯-瑞利混合模型(GRMM)中拟合精度最小的情况作为混合模型结果。最终在基于 MRF 的分割方法下,得到高斯混合模型(GMM)和 GRMM 两种分割结果并进行对比。实验采用多个遥感图像验证了所提方法的效果。

2 高斯-瑞利混合模型

混合模型是常用的图像数据概率分布模型,其形式为

$$f(x | \Theta) = \sum_{k=1}^K [\omega_k \times f_k(x | \theta_k)], \quad (1)$$

式中 ω_k 为各类在整个混合模型中所占的比例,即权值。 Θ 为整个混合模型的参数组合。 $f_k(\cdot)$ 为各类具体的概率分布表达, θ_k 为每一类的参数组合。在众多的混合概率模型中,高斯混合模型是最常用的一种。详细的高斯混合模型中,各类分布可以表示为

$$f_k(x | \theta_k) = \frac{1}{\sqrt{2\pi\sigma_k}} \exp \frac{-(y_n - \mu_k)^2}{2\sigma_k}, \quad (2)$$

式中 μ_k 和 σ_k 分别为第 k 类的均值和方差。

但认为大部分的图像中的类并非严格符合高斯分布,瑞利分布更加符合其数据分布。而文献[16,17]中高斯-瑞利混合模型定义为

$$f_k(x_n | \theta_k) = \begin{cases} \frac{x_n}{|v_k|} \exp \frac{-x_n^2}{2|v_k|}, & k = 1 \\ \frac{1}{\sqrt{2\pi|v_k|}} \exp \frac{-(x_n - \mu_k)^2}{2|v_k|}, & 1 < k < K, \\ \frac{255 - x_n}{|v_k|} \exp \frac{-(255 - x_n)^2}{2|v_k|}, & k = K \end{cases} \quad (3)$$

在以上模型中,假设图像中的数据可以分为 K 类, k 是类序号, x_n 代表图像像素, θ_k 是混合模型中的参数组合, v_k 是混合模型中 高斯分布和瑞利分布的方差,而 μ_k 是混合模型中高斯分布的均值。由以上模型可知,仅将像素值域两端类别认为是瑞利混合模型,这并不符合大多数图像分布规律。因此,可以将图像中的数据分布写为高斯-瑞利混合分布形式

$$f_k(y_n | \theta_k) = \begin{cases} \frac{\omega_k}{\sqrt{2\pi\sigma_k}} \exp \frac{-(y_n - \mu_k)^2}{2\sigma_k}, & 1 < k \leq m \\ \frac{\omega_k y_n}{\sigma_k} \exp \frac{-y_n^2}{\sigma_k}, & m < k < K \end{cases}, \quad (4)$$

此时的参数组合 $\Theta = (\mu_1, \mu_2, \dots, \mu_m; \sigma_1, \sigma_2, \dots, \sigma_K)$ 。由(4)式可以看出,假设整个混合模型中有 K 类数据,其中有 m 类符合高斯分布,其余的各类符合瑞利分布。其中 ω_k 为各类的权值,即其数据量在混合模型中所占的比例。以 1 幅遥感图像为例,对比其直方图分布所接近的混合模型,根据分布情况,可以将其分为 3 类。其分类过程采用了一种无监督的形式,即运用文献[18]中论述的原始最大熵方法判断最为合理的分类数。主要过程是首先运用 K 均值分割方法对图像进行初始分割,获取 2 类分割至 10 类分割的结果,计算每种分割结果的熵值,并选取熵最大的分割结果所对应的类数作为最佳分类数,具体分割流程如图 1 所示,其公式表达为

$$C_{opt} = \operatorname{argmax}_{C=2 \sim 10} H = \operatorname{argmax}_{i=1}^{C_n} H_{C_i}, \quad (5)$$

式中 C_{opt} 为最佳分类数, H 为 K 均值分割之后的熵值。 H_{C_i} 为图像中第 C_i 类的熵,可以表示为

$$H_{C_i} = - \sum_{h \in \text{Class}C_i} \left(\frac{p_h}{p_{C_i}} \log_2 \frac{p_h}{p_{C_i}} \right), \quad (6)$$

式中 p_h 为像素 h 在图像中出现的概率, p_{C_i} 为第类 C_i 在整个图像中所占的比例。

根据此方法,认为该图像分为 3 类为最佳。其分割结果如图 2 中所示。图 2(a)为原始图像,图 2(b)为分割结果。关注其混合模型拟合结果,如果认为该图像符合混合高斯模型,其数据分布如图 2(c)直方图及曲线所示,3 类的高斯分布如彩色曲线所示,其叠加结果为图中黑色曲线。如果认为该图像是符合高斯-瑞利混合分布,则这 3 类的概率分布曲线如图 2(d)中彩色曲线所示,叠加之后的分布曲线为图中黑色曲线。概率分布曲线拟合结果中的具体参数如表 1 所示,参数中包含了各类的均值、方差以及权值。同时此高斯混合模型对整个图像的直方图拟合的误差为 18.4%。分割结果中,绿色圆环中的分类代表的像素符合瑞利分

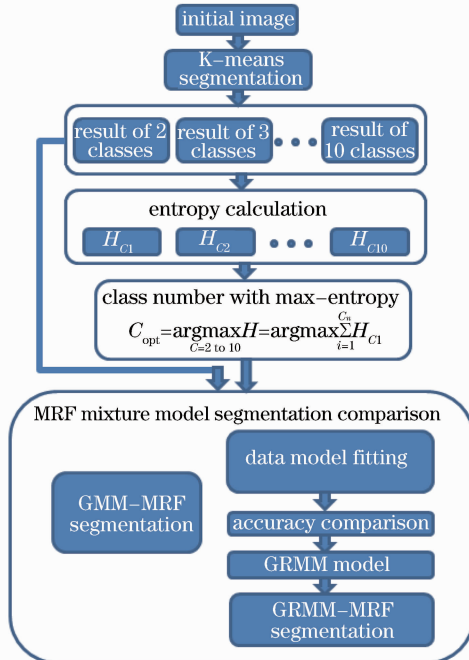


图 1 分割方法框架流程图

Fig. 1 Framework of segmentation method

布,而红色圆环中类代表的像素符合高斯分布。图中的瑞利分布的参数仅包含方差和权值,不包含均值参数。高斯-瑞利混合模型的拟合结果误差为 9.2%。

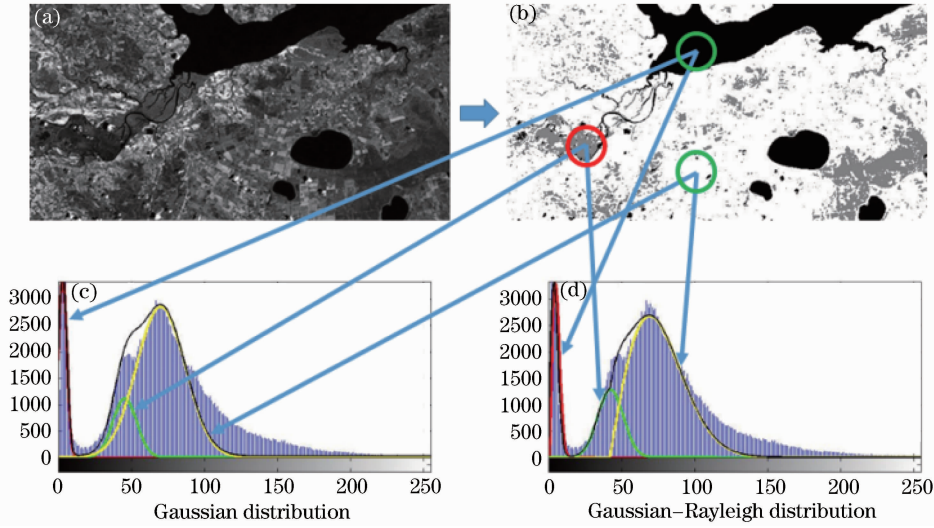


图 2 高斯混合模型及高斯-瑞利混合模型拟合图像比较。(a) 原图; (b) 分割图像; (c) 混合高斯模型直方图; (d) 高斯-瑞利模型直方图

Fig. 2 Image fitting comparison of GMM and GRMM. (a) Original image; (b) segmented image; (c) GMM model histogram; (d) GRMM model histogram

表 1 图 2 中图像的混合模型参数表

Table 1 Mixture model parameters table of image in Fig. 2

| Class number | Gaussian distribution parameters | | | | Gaussian-Rayleigh distribution parameters | | | |
|--------------|----------------------------------|----------|----------|---------------|---|----------|----------|---------------|
| | μ | σ | ω | Fitting error | μ | σ | ω | Fitting error |
| 1 | 3.01 | 7.2 | 0.069 | | * | 42.7 | * | |
| 2 | 45.5 | 65.78 | 0.137 | 18.4% | 3.5 | 75.9 | 27.38 | 9.2% |
| 3 | 70.2 | 273.38 | 0.794 | | 0.071 | 0.139 | 0.79 | |

3 图像分割过程

经过上一个节验证,可以认为在众多图像中,运用高斯-瑞利混合模型进行拟合比运用高斯混合模型可能更为合理。针对图像对应的高斯-瑞利混合模型,采用了基于 MRF 的分割方法,并利采用迭代条件模型(ICM)进行参数优化。

首先,根据贝叶斯定理和最大后验概率准则,可以得到

$$X_{\text{opt}} = \max_{X \in \Omega} \arg [P(X | Y)] = \max_{X \in \Omega} \arg \left[\frac{P(Y | X)P(X)}{P(Y)} \right] \propto P(Y | X)P(X), \quad (7)$$

式中 X_{opt} 为最佳的分割结果, Y 为被处理图像, X 为当前的分割标记场。求取最佳分割结果 X_{opt} 的过程可以转化为求后验概率 $P(X|Y)$ 的最大值的过程,同时由于给定图像之后 $P(Y)$ 为定值,则可以将求取最佳分割的过程转化为求取 $P(Y|X)P(X)$ 的过程^[19]。

如果图像的分布符合高斯混合模型,则可以将(7)式中的 $P(Y|X)$ 转化为

$$P(Y | X) = \prod_{d \in L} \left\{ \frac{1}{\sqrt{2\pi\sigma_d}} \exp \left[-\frac{(y_q - \mu_d)}{2\sigma_d} \right] \right\} \propto \exp \left[-\sum_{d \in L} \frac{(y_q - \mu_d)^2}{2\sigma_d^2} \right], \quad (8)$$

式中 d 为图像中类标号, y_q 为某像素邻域内集簇 q 内的像素, μ_d 和 σ_d 为类 d 的均值和方差^[20,21]。

由于认为图像的像素概率分布符合高斯-瑞利混合模型,则可以将(7)式中的 $P(Y|X)$ 转化为

$$P(Y | X) = \prod_{d_1, d_2 \in L} \left\{ \left[\frac{1}{\sqrt{2\pi\sigma_{d_1}}} \exp \left(-\frac{(y_q - \mu_{d_1})}{2\sigma_{d_1}} \right) \right] \left[\sigma_{d_2} \exp \left(-\frac{y_q^2}{2\sigma_{d_2}} \right) \right] \right\} \propto \exp \left\{ -\left[\sum_{d_1 \in L} \frac{(y_q - \mu_{d_1})^2}{2\sigma_{d_1}^2} + \sum_{d_2} \frac{y_q^2}{\sigma_{d_2}} \right] \right\}, \quad (9)$$

式中 d_1, d_2 分别为图像对应的混合模型的高斯分布的类标号和瑞利分布的类标号。 μ 和 σ 分别代表均值和方差。

值得注意的是,采用了文献[1]中 MRF 势能函数的定义方式

$$V'_c[x(i,j), x(i_1, j_1)] = \begin{cases} -\beta, & x(i,j) = x(i_1, j_1) \\ \frac{-\beta\sigma_d}{\sigma_{id} + D_{x(i,j)x(i_1, j_1)} \times g_{x(i,j)x(i_1, j_1)}}, & x(i,j) \neq x(i_1, j_1) \end{cases}, \quad (10)$$

式中 β 为分割参数, $x(i,j)$ 代表当前像素点 (i,j) 的分割结果, $D_{x(i,j)x(i_1, j_1)}$ 代表点 (i,j) 和 (i_1, j_1) 的空间距离, $g_{x(i,j)x(i_1, j_1)}$ 代表像素点 (i,j) 和 (i_1, j_1) 的灰度差异绝对值。这种改进形式将图像像素邻域内中心像素与邻域像素之间的位置关系以及强度差值引入了 MRF 势能函数中,其意义是,当中心像素距离某邻域像素距离越近,则其分入一类的可能性加大;中心像素与某邻域像素之间强度值差异越小,则越有可能被分入一类中。

根据吉布斯准则,即可得到 $P(X)$ 的具体表达形式

$$P(X) = \exp\left[-\sum_L V_c(x)/T\right] / \left\{ \sum_{x \in X} \exp\left[-\sum_L V_c(x)/T\right] \right\}, \quad (11)$$

将(9)和(11)式代入(7)式,则可以求取最佳分割结果 X_{opt} 。采用迭代条件模型,即 ICM 进行参数优化,最终得到图像分割结果^[22]。

4 实验结果与分析

实验采用 3 幅遥感图像作为实验对象。分别采用高斯混合模型和高斯-瑞利混合模型拟合图像,两种混合模型都采用 MRF 方法进行图像分割,其中优化过程采用 ICM 实现。

图 3 为第 1 幅遥感图像分割结果,其原始图像为微波遥感图像,采用的传感器为成像雷达,空间分辨率为 1 km。图 3(a)为原始遥感图像,根据 K 均值分割结果以及相应最大熵计算结果,可以确定将图像分为 3 类是最佳选择。高斯混合模型拟合的曲线如图 3(d)所示。如果采用高斯-瑞利混合模型拟合图像像素分布,则像素分布及拟合曲线如图 3(e)所示。采用 MRF 分割($\beta=2.5$)之后,高斯混合模型的分割结果如图 3(b)所示,高斯-瑞利混合模型的分割结果如图 3(c)所示。但是如图 3(b)圆环内分类结果所示,高斯混合模型的分割结果中,陆地

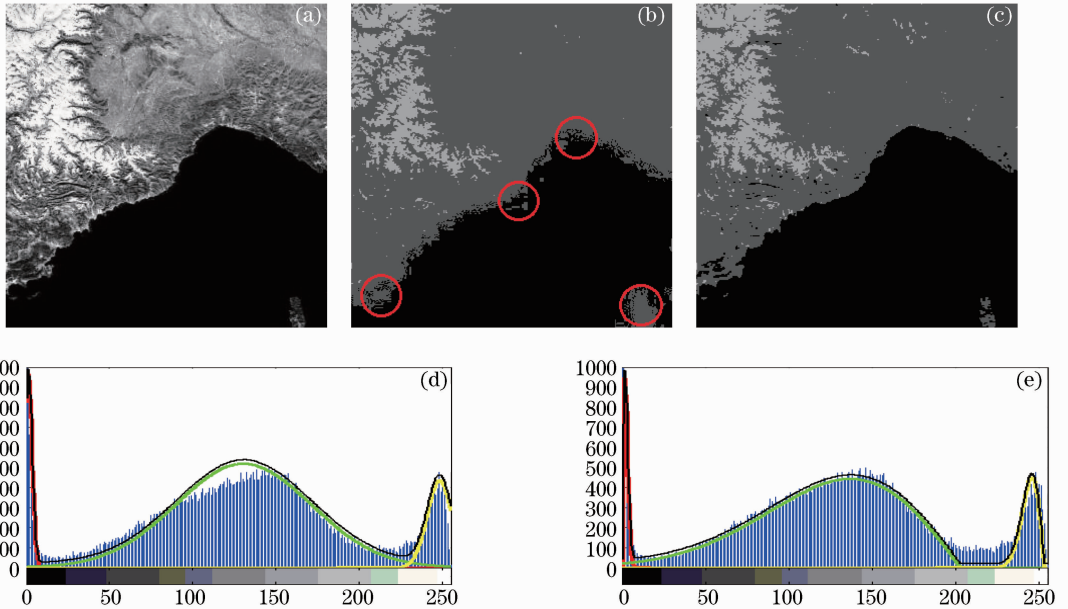


图 3 第 1 幅图像运用 GMM 和 GRMM 的分割结果。(a) 原始图像;(b) GMM 分割结果;(c) GRMM 分割结果;
(d) GMM 图像分布拟合结果;(e) GRMM 图像分布拟合结果

Fig. 3 1st image segmentation results using GMM and GRMM. (a) Original image; (b) segmentation result with GMM; (c) segmentation result with GRMM; (d) image distribution fitting with GMM; (e) image distribution fitting with GRMM

与海洋交界之处,分割结果并不理想,此外,水中的岛屿部分采用高斯-瑞利混合模型分割也比高斯混合模型结果有一定提高。高斯混合模型和高斯-瑞利混合模型对图像分布进行拟合的参数如表 2 中 Image 1 内容所示。高斯-瑞利混合模型中,高斯混合模型中的两类都拟合为瑞利分布,其拟合结果比高斯混合模型有一定的提高,误差由 8.4% 提高至 7.1%。

实验 1 图像结构简单,并且目标中包含水,易于分割。为了体现该方法的稳健性,采用较高分辨率遥感图像作为实验对象,其结果如实验 2 和实验 3 所示。图 4 为较高分辨率遥感图像的分割结果,其原始图像为采用互补金属氧化物半导体(CMOS)传感器的可见光黑白全色成像,空间分辨率为 5 m。图 4(a)为原始遥感图像,根据 K 均值分割结果以及相应的最大熵计算结果,可以确定将图像分为 5 类是最佳选择。高斯混合模型拟合的曲线如图 4(d)所示。如果采用高斯-瑞利混合模型拟合图像像素分布,则像素分布及拟合曲线如图 4(e)所示。采用 MRF 分割($\beta=1.5$)之后,高斯混合模型的分割结果如图 4(b)所示,高斯-瑞利混合模型的分割结果如图 4(c)所示。图像中各个部分代表的目标如图 4(f)所示,其中包括了湖泊、植被和河流、空地、道路和建筑物。在高斯-瑞利混合模型分割结果中,对河流目标的分割较之高斯混合模型分割结果更为完整;植被和建筑物的分割也更加符合原始图像的情况。高斯混合模型和高斯-瑞利混合模型对图像分布进行拟合的参数如表 2 中 Image 2 内容中所示。高斯-瑞利混合模型中,高斯混合模型中的两类都拟合为瑞利分布,其拟合结果比之高斯混合模型有较大的提高,误差由 6.8% 提高至 3.1%。

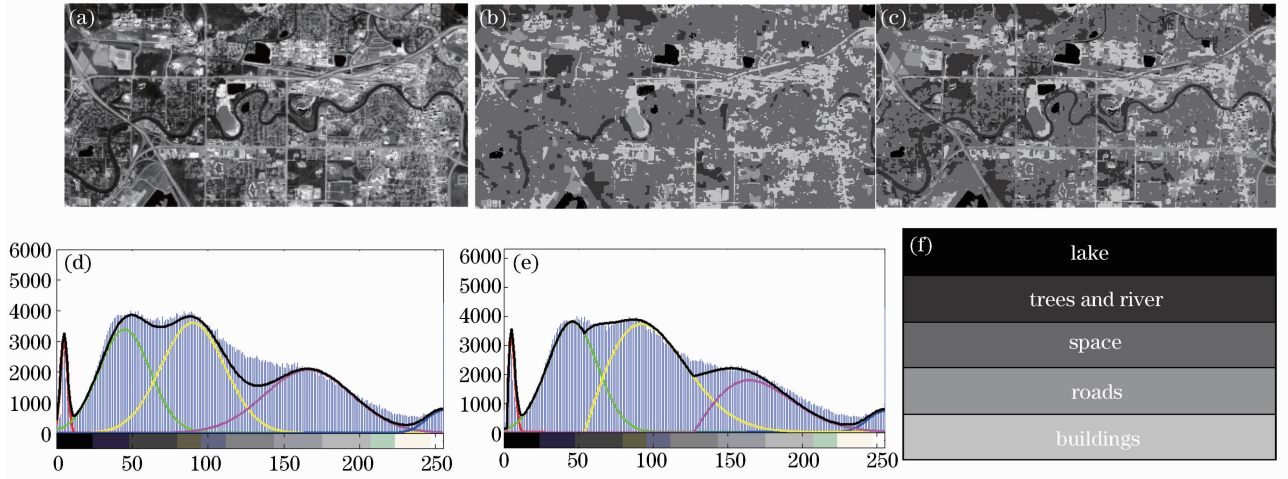


图 4 第 2 幅图像运用 GMM 和 GRMM 的分割结果。(a) 原始图像;(b) GMM 分割结果;(c) GRMM 分割结果;
(d) GMM 图像分布拟合结果;(e) GRMM 图像分布拟合结果;(f) 分割结果对应的目标

Fig. 4 2nd image segmentation results using GMM and GRMM. (a) Original image; (b) segmentation result with GMM; (c) segmentation result with GRMM; (d) image distribution fitting with GMM; (e) image distribution fitting with GRMM; (f) objects corresponding to the experiments results

图 5 为第 3 幅高分辨率遥感图像的分割结果,其原始图像为采用 CMOS 传感器的可见光黑白全色成像,空间分辨率为 1 m。图 5(a)为原始遥感图像,根据 K 均值分割结果以及相应的最大熵计算结果,可以确定将图像分为 4 类是最佳选择。高斯混合模型拟合的曲线如图 5(d)所示。如果采用高斯-瑞利混合模型拟合图像像素分布,则像素分布及拟合曲线如图 5(e)所示。采用 MRF 分割($\beta=2.0$)之后,高斯混合模型的分割结果如图 5(b)所示,高斯-瑞利混合模型的分割结果如图 5(c)所示。图像中各个部分代表的目标如图 5(f)所示,其中包括了树木、草地、空地和道路和建筑物。在高斯-瑞利混合模型分割结果较之高斯混合模型,对树木目标的分割更加符合原始图像的情况;建筑物的分割结果更为完整。高斯混合模型和高斯-瑞利混合模型对图像分布进行拟合的参数如表 2 中 Image 3 内容中所示。高斯-瑞利混合模型中,高斯混合模型中的两类都拟合为瑞利分布,其拟合结果比之高斯混合模型有较大的提高,误差由 15.4% 提高至 10.2%。

图 4 和图 5 实验中,地形更加复杂,包含了更多的目标,总体来说较之地形简单的遥感图像,分割精度有所减低,但采用 GRMM 分割的结果比 GMM 分割结果更加合理。

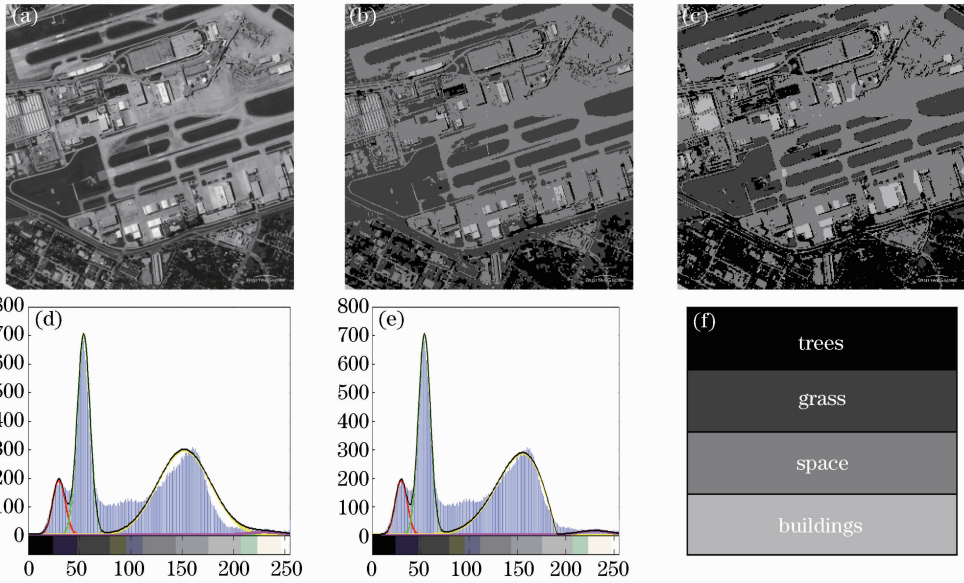


图 5 第 3 幅图像运用 GMM 和 GRMM 的分割结果。(a) 原始图像;(b) GMM 分割结果;(c) GRMM 分割结果;
(d) GMM 图像分布拟合结果;(e) GRMM 图像分布拟合结果;(f) 分割结果对应的目标

Fig. 5 3rd image segmentation results using GMM and GRMM. (a) Original image; (b) segmentation result with GMM;
(c) segmentation result with GRMM; (d) image distribution fitting with GMM; (e) image distribution fitting with GRMM; (f) objects corresponding to the experiments results

表 2 实验中图像的混合模型参数表

Table 2 Mixture model parameters table of image in the experiments

| Experiments | | Image 1(3 classes) | | | Image 2(5 classes) | | | | | Image 3(4 classes) | | | |
|---|----------|--------------------|-------|-------|--------------------|-------|-------|-------|-------|--------------------|-------|-------|-------|
| Class Number | | 1 | 1 | 2 | 1 | 2 | 3 | 4 | 5 | 1 | 2 | 3 | 4 |
| Gaussian Distribution Parameters | μ | 1.34 | 130.6 | 248.2 | 5.151 | 45.23 | 90.14 | 165.9 | 254.6 | 30.1 | 53.8 | 152.2 | 229.9 |
| | σ | 5.05 | 1665 | 53.4 | 5.23 | 285.8 | 440.4 | 835.5 | 122.3 | 38.26 | 38.71 | 680.4 | 302.5 |
| | ω | 0.007 | 0.952 | 0.041 | 0.037 | 0.252 | 0.337 | 0.318 | 0.056 | 0.092 | 0.378 | 0.521 | 0.009 |
| | error | 8.4% | | | 6.8% | | | | | 15.4% | | | |
| Gaussian-Rayleigh Distribution Parameters | μ | 1.38 | * | * | * | 46.1 | * | * | 254.3 | 30.2 | 54.1 | * | 229.5 |
| | σ | 5.2 | 65.78 | 7.38 | 3.2 | 286.2 | 38.42 | 37.38 | 124.5 | 38.34 | 39.1 | 35.38 | 302.5 |
| | ω | 0.007 | 0.949 | 0.044 | 0.036 | 0.306 | 0.374 | 0.231 | 0.053 | 0.101 | 0.430 | 0.459 | 0.010 |
| | error | 7.1% | | | 3.1% | | | | | 10.2% | | | |

所提出的 GRMM 针对遥感图像的分割实验中,不仅在 GMM 分割效果提高,还在运行速度上也有一定的提高。图 6 为运用 GRMM 和 GMM 针对实验中 3 幅图像的分割运行时间对比图。分割运行系统为 Windows 7.1,CPU 为 Intel i3(1.8GHz),内存为 2G。结果表明运用 GRMM 的分割过程用时较短,效率较

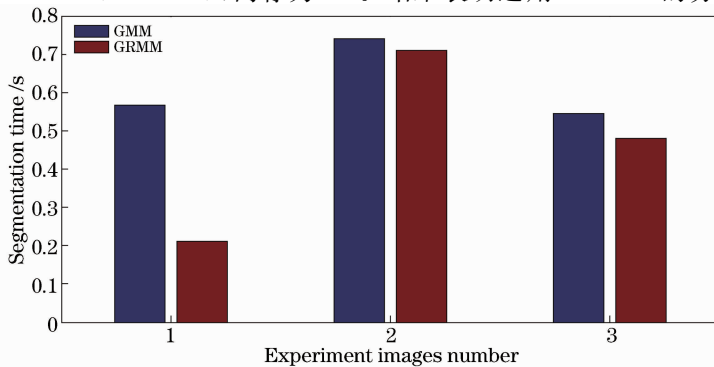


图 6 实验中图像分割时间对比

Fig. 6 Compare results for segmentation time in the experiments

高。但应该说明的是,GRMM 分割过程的时间并不包括混合模型拟合选优的过程。

5 结 论

针对遥感图像分割,提出了以 GRMM 代替 GMM 来对图像建模的思想。用最大熵分割来确定最合理的分类数。采用高斯-瑞利混合模型对图像建模之后,将此模型与 MRF 方法相结合,采用 ICM 作为计算 MAP 的方法。实验中,运用 3 幅遥感图像作为实验数据,分别采用 GMM 和 GRMM 对其进行建模并将结果进行比较。

分割结果表明,图像采用 GRMM 建模后的分割效果优于采用 GMM 模型的分割效果,尤其是对于图像的某些细节. 对此图像分割误差和分割效率都显示 GRMM 较之 GMM 更适合遥感图像的分割。在进一步的工作中,将针对其他类型图像比较 GRMM 和 GMM 图像分割结果。

参 考 文 献

- Hou Y, Yang y, Rao N, *et al.*. Mixture model and Markov Random field-based remote sensing image unsupervised clustering method[J]. *Opto-Electronics Review*, 2011, 19(1): 83-88.
- Fan Liheng, Lü Junwei, Deng Jiangsheng. Classification of hyperspectral remote sensing image based on bands grouping and classification ensembles[J]. *Acta Optica Sinica*, 2014, 34(9): 0910002.
樊利恒, 吕俊伟, 邓江生. 基于分类器集成的高光谱遥感图像分类方法[J]. *光学学报*, 2014, 34(9): 0910002.
- Su W, Li J, Chen Y, *et al.*. Textural and local spatial statistics for the object oriented classification of urban areas using high resolution imagery[J]. *International Journal of Remote Sensing*, 2008, 29(11): 3105-3117.
- Xue Feng, Wang Runsheng. Road extraction by combined using statistical and structural information[J]. *Acta Optica Sinica*, 2001, 21(4): 504-508.
薛 峰, 王润生. 组合利用统计和结构信息的道路提取算法[J]. *光学学报*, 2001, 21(4): 504-508.
- Zhong P, Wang R. A multiple conditional Random fields ensemble model for urban area detection in remote sensing optical images[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2007, 45(12): 3978-3988.
- Fan J, Han M, Wang J. Single point iterative weighted fuzzy C-means clustering algorithm for remote sensing image segmentation[J]. *Pattern Recognition*, 2009, 42(11): 2527-2540.
- Mylonas S K, Stavrakoudis D G, Theocharis J B. GeneSIS: A GA-based fuzzy segmentation algorithm for remote sensing images[J]. *Knowledge-Based Systems*, 2013, 54(12): 86-102.
- Wan F, Deng F. Remote sensing image segmentation using mean shift method[J]. *Simulation and Modeling Communications in Computer and Information Science*, 2011, 176(11): 86-90.
- Pal M, Maxwell A E, Warner T A. Kernel-based extreme learning machine for remote-sensing image classification[J]. *Remote Sensing Letters*, 2013, 4(9): 853-862.
- Du Peijun, Chen Yu, Xia Junshi, *et al.*. A novel remote sensing image classification scheme based on data fusion, multiple features and ensemble learning[J]. *Journal of Indian Soc Remote Sens*, 2013, 41(2): 213-222.
- Nikou C, Galatsanos N P, Likas A C. A class-adaptive spatially variant mixture model for image segmentation[J]. *Image Processing, IEEE Transactions on*, 2007, 16(4): 1121-1130.
- Lunga D, Ersoy O. Kent mixture model for classification of remote sensing data on spherical manifolds[C]. *Applied Imagery Pattern Recognition Workshop, IEEE*, 2011: 1-7.
- Zhang Y, Brady M, Smith S. Segmentation of brain MR images through a hidden Markov Random field model and the expectation-maximization algorithm[J]. *Medical Imaging, IEEE Transactions on*, 2001, 20(1): 45-57.
- Deng H, Clausi D A. Unsupervised image segmentation using a simple MRF model with a new implementation scheme[J]. *Pattern Recognition*, 2004, 37(12): 2323-2335.
- Zhou S, Chen W, Jia F, *et al.*. Segmentation of brain magnetic resonance angiography images based on MAP-MRF with multi-pattern neighborhood system and approximation of regularization coefficient[J]. *Medical Image Analysis*, 2013, 17(8): 1220-1235.
- Seng C H, Bouzerdoum A, Amin M G, *et al.*. A Gaussian-Rayleigh mixture modeling approach for through-the-wall radar image segmentation[C]. *Acoustics, Speech and Signal Processing (ICASSP)*, 2012 IEEE International Conference on, 2012: 877-880.
- Debes C, Amin M, Zoubir A. Target detection in singleand multiple-view through-the-wall radar imaging[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2009, 47(5): 1349-1361.
- Tao W B, Tian J W, Liu J. Image segmentation by three-level thresholding based on maximum fuzzy entropy and genetic algorithm[J]. *Pattern Recognition Letters*, 2003, 24(16): 3069-3078.
- Vivone G, Addesso P, Conte R, *et al.*. A class of cloud detection algorithms based on a MAP-MRF approach in space and time[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2014, 52(8): 5100-5114.
- Borges J, Bioucas-Dias J, Marcal A. Bayesian hyperspectral image segmentation with discriminative class learning[J]. *Geoscience Remote Sensing, IEEE Transactions on*, 2011, 49(6): 2151-2164.
- Zhang B, Li S, Jia X, *et al.*. Adaptive Markov random field approach for classification of hyperspectral imagery[J]. *Geoscience Remote Sensing Letters, IEEE*, 2011, 8(5): 973-977.
- Hegarar-Masclé S Le, Andre C. Use of Markov random fields for automatic cloud/shadow detection on high resolution optical images[J]. *ISPRS J Photogramm Remote Sens*, 2009, 64(4): 351-366.