

用于图像分割的多分类高斯混合模型和 基于邻域信息的高斯混合模型

柴五一 杨丰 袁绍锋 黄靖

(南方医科大学生物医学工程学院广东省医学图像处理重点实验室 广州 510515)

摘要 高斯混合模型是一种简单有效且被广泛使用的图像分割工具。然而,传统的高斯混合模型在混合成分个数确定时的拟合结果不够精确;此外,由于没有考虑像素间的空间关系,导致分割结果易受噪声干扰,且分割精度不高。为弥补传统高斯混合模型的缺陷,文中提出多分类高斯混合模型和基于邻域信息的高斯混合模型用于图像分割。多分类高斯混合模型对传统混合模型进行二重分解:传统混合模型由 M 个分布加权混合得到,多分类混合模型进一步将 M 个分布中的每一个分布分解成 R 个分布。即多分类高斯混合模型由 M 个高斯分布混合组成,而这 M 个分布分别由 R 个不同的分布混合得到,提高了模型的拟合精度。基于邻域信息的高斯混合模型通过对模型中的先验概率和后验概率添加空间信息约束,增强了像素间的信息关联和抗噪性。采用结构相似性、误分率和峰值信噪比等指标来评价分割结果。通过实验发现:与现有的混合模型分割方法相比,文中方法大幅提高了分割精度,且有效地抑制了噪声干扰。

关键词 高斯混合模型,邻域信息,多分类,图像分割

中图分类号 TP391 文献标识码 A DOI 10.11896/j.issn.1002-137X.2018.11.043

Multi-class Gaussian Mixture Model and Neighborhood Information Based Gaussian Mixture Model for Image Segmentation

CHAI Wu-yi YANG Feng YUAN Shao-feng HUANG Jing

(Guangdong Provincial Key Laboratory of Medical Image Processing, School of Biomedical Engineering,
Southern Medical University, Guangzhou 510515, China)

Abstract Gaussian mixture model is one of the simple, effective and widely used tools in image segmentation. However, the fitting result is not accurate enough when the number of mixture components in the traditional Gaussian mixture model is determined. In addition, because the spatial relationship between pixels is not considered, the segmentation results are easily affected by noise, and the segmentation accuracy is not high. To remedy the defects of the traditional Gaussian model, this paper proposed a multi-class Gaussian mixture model and a neighborhood information based Gaussian mixture model for image segmentation. The multi-class Gaussian mixture model decomposes the traditional mixture model. The traditional mixture model is composed of M different weighted distributions, and multi-class Gaussian mixture model decomposes each of the M components into R different distributions, that is, the multi-class Gaussian mixture model is composed of M different weighted distributions, and each of the M distributions is obtained by mixing R different distributions, thus improving the fitting accuracy of the model. The neighborhood information based Gaussian mixture model adds spatial information to the prior probability and posterior probability in the model, thus enhancing the information association and antinoise capability among pixels. The segmentation results were evaluated by the indexes of structural similarity, misclassification rate and peak signal-to-noise ratio. The experimental results show that compared with the existing segmentation method of mixture model, the segmentation accuracy of the proposed method in this paper is greatly improved, and the noise is effectively restrained.

Keywords Gaussian mixture model, Neighborhood information, Multi-class, Image segmentation

1 引言

图像分割作为图像处理中的一项关键技术和重要环节,在现实中已经得到了广泛的应用,如遥感图像分析^[1]、磁共振

成像^[2]、合成孔径雷达图像^[3]、目标检测^[4]等。在这些应用中,图像分割精度将会直接影响后续的各种处理。在各种图像应用中,对图像进行目标提取、目标检测等都与图像分割密切相关,但图像的重叠强度和低对比度,以及噪声的干扰,都

到稿日期:2017-11-13 返修日期:2018-02-21 本文受国家自然科学基金项目(61771233,61271155)资助。

柴五一(1992-),硕士生,主要研究方向为图像处理,E-mail:1741647498@qq.com;杨丰(1965-),教授,主要研究方向为生物医学信号处理、模式识别、机器学习,E-mail:yangf@smu.edu.cn(通信作者);袁绍锋(1991-),硕士生,主要研究方向为机器学习,E-mail:403568338@qq.com;黄靖(1981-),副教授,主要研究方向为生物信息识别,E-mail:brinker149@126.com。

使得图像的自动分割仍是一个具有挑战性的研究课题。目前已有许多关于图像分割的方法,这些方法主要可分为两大类:基于边界的图像分割方法和基于区域的图像分割方法^[5]。

近年来,基于模型的图像分割方法逐渐引起了人们的重视。对混合模型的研究最早可追溯到 19 世纪末。1894 年, Pearson 采用了具有两个混合成分的高斯混合模型对数据进行拟合,并用矩估计法对模型进行参数估计,这是关于混合模型最早的研究。随着人们对混合模型研究的不断深入,基于混合模型的图像分割方法也得到了更广泛的发展,国内外学者提出了许多基于混合模型的分割方法。传统的高斯混合模型(Gaussian Mixture Model, GMM)是其中一种,但由于该模型在图像分割中仅对像素灰度进行分析,没有考虑像素之间的空间信息,导致分割结果受噪声影响较大,且分割精度也有待提高。为解决传统高斯混合模型易受噪声影响的问题,文献[6]提出了一种图像重塑(Remodeling Gaussian Mixture Model, R_GMM)的方法,即对图像进行预处理。文献[6]中引入相似性度量因子 $S_{i,j}$ 来表征中心像素 i 与邻域像素 j 之间的空间关系,然后以 $S_{i,j}$ 为权重,将邻域像素值加权的结果作为中心像素重塑后的像素值,然后再对重塑后的图像用高斯混合模型进行分析,可以较好地抑制噪声。文献[7]提出了一种噪声平滑因子(Noise Smoothing Gaussian Mixture Model, NS_GMM)的方法,该方法是基于马尔科夫随机场模型^[8-9]的一种变形。文献[7]在随机场能量函数中引入噪声平滑因子 $G_{i,j}$,并将其作为加权因子,用先验分布对数加权和替换传统的先验分布对数和,以定义随机场能量函数;将 $G_{i,j}$ 定义为像素 i 的邻域像素属于混合模型中第 j 个分量的先验概率与后验概率的平均值的负指数,这样能够起到线性平滑噪声的作用,但同时易丢失图像细节。文献[10-12]提出了空间平滑的高斯混合模型的方法(Gaussian Mixture Model with Spatial Smoothing, SS_GMM),即在高斯混合模型的先验概率和条件概率中添加自适应的均值滤波来增加模型的抗噪性,滤波窗口中的权值由邻域像素与中心像素的空间距离确定,距离越近,权值越大,反之亦然。该方法对图像分割的精度较高,且很好地抑制了噪声,但当噪声较大、图像纹理较复杂时,该方法的处理效果不太理想。为提高图像的分割精度和抗噪性,本文借鉴文献[13-14]中对混合模型多重分解的思想,提出了多分类混合模型的方法(Gaussian Mixture Model of Multi-Class, MC_GMM);针对噪声图像,本文将多分类混合模型的方法与文献[6]中图像重塑的方法结合,提高了图像的分割精度和抗噪性;同时本文提出基于邻域信息的高斯混合模型的方法(Gaussian Mixture Model with Neighborhood Information, NI_GMM),在文献[10]方法的基础上,重新定义滤波窗口中各像素的权值,该方法在有效抑制噪声的同时能更好地保留图像细节。

2 实验方法

实验包含两个部分:首先对本文提出的两种模型方法(多分类高斯混合模型、基于邻域信息的高斯混合模型)进行说明;然后介绍评价模型分割效果的几种指标。

2.1 多分类高斯混合模型

高斯混合模型是指随机变量 x 的概率密度表示为:

$$p(x|\Theta) = \sum_{k=1}^M \pi_k \frac{1}{\sqrt{(2\pi\sigma_k^2)}} \exp\left(-\frac{(x-\mu_k)^2}{2\sigma_k^2}\right) \quad (1)$$

其中, $\sum_k \pi_k = 1$, $\Theta = (\pi_1, \dots, \pi_M, \theta_1, \dots, \theta_M)$, θ_M 表示混合模型的参数集合 $\theta_M = (\mu_M, \sigma_M)$, 即混合模型由 M 个分量组成,分量 k 的权重系数为 π_k 。


传统的混合模型由 M 个不同的概率分布加权得到。本文首先将混合模型分为 M 个概率分布,即混合模型由 M 个不同的类别产生;然后将 M 个概率分布中的每一个分布再分为 R 个概率成分,即每一个类别由 R 个不同的概率成分拟合其分布。具体表示如下:

$$p(x_i|\Theta) = \sum_{j=1}^J V_j \sum_{r=1}^R \pi_{j,r} f_x(x_i|\Theta_{j,r}) \quad (2)$$

对高斯混合模型而言:

$$f_x(x_i|\Theta_{j,r}) = \frac{1}{\sqrt{2\pi\sigma_{j,r}^2}} \exp\left(-\frac{4(x-\mu_{j,r})^2}{2\sigma_{j,r}^2}\right) \quad (3)$$

其中, $\theta_{j,r} = (\mu_{j,r}, \sigma_{j,r})$, 参数集 $\Theta = (\pi_{1,1}, \dots, \pi_{j,r}, \theta_{1,1}, \dots, \theta_{j,r})$, V_j 表示属于第 j 个类别成分的权重, $\pi_{j,r}$ 表示属于第 j 个类别成分中第 r 个分布成分的权重。图 1 是对多分类的图解说明。



注: 每一个像素 x_i 属于类别 C_j 的概率为 $p(V_j|\Theta)$, 属于类别 C_j 中的第 r 个成分, 即 $x_i \in B_{j,r}$ 的概率为 $p(\pi_{j,r}|V_j, \Theta)p(V_j|\Theta)$

图 1 多分类框架

Fig. 1 Mmulti-class framework

在这里, 已知样本数据及其概率密度表达式, 利用 EM 算法^[15]可以估计出未知参数 Θ 的值, 从而得到感兴趣样本的混合分布模型, 然后计算出每一个像素的后验概率:

$$p(j|x_i, \Theta) = \frac{\sum_{r=1}^R v_j \pi_{j,r} f_x(x_i|\Theta_{j,r})}{\sum_{j=1}^J v_j \sum_{r=1}^R \pi_{j,r} f_x(x_i|\Theta_{j,r})} \quad (4)$$

最后, 根据最大后验准则^[16]即可确定像素 x_i 所属的类别, 进而完成图像分割。

2.2 基于邻域信息的高斯混合模型

相比于传统混合模型, 多分类混合模型提高了分割精度, 但多分类混合模型也没有考虑像素间的空间关系, 故对噪声比较敏感, 具体情况如图 2 所示。图 2(a)与图 2(b)的中心点均为噪声点, 传统的混合模型会将其与周围像素分为不同的类。为消除噪声点对图像分割结果的影响, 本文结合像素间

的空间关系对混合模型做以下改进。




图2 噪声图
Fig. 2 Noisy image

1)对像素先验概率 π_k 添加空间信息。例如如图2(a)中所有像素本应同属一类,但由于噪声点的影响,可能将其与周围像素分为两类。加入空间信息后,所有像素点都受周围像素影响,从而消除了噪声点的干扰,将所有像素分为一类。

2)对条件概率 $p(x_i|\theta_k)$ 添加空间信息。依据传统概率混合模型,具有相同灰度值的像素拥有相同的条件概率。图2(a)中的中心像素与图2(b)中周围像素的灰度值相同,但它们不属于同一类,传统混合模型不能正确区分两者。加入空间信息后,除灰度值外,所有像素还受周围像素的约束,从而能更好地对像素进行划分。具体实现方法如下:

$$p(x_i|\theta_k) = \sum_{m \in N_i} \frac{\omega_m}{Q_i} p(x_m|\theta_k) \quad (5)$$

$$\pi_{i,j} = \frac{\sum_{m \in \partial_i} \omega_m z_{m,j}}{\sum_{k=1}^M \sum_{m \in \partial_i} \omega_m z_{m,k}} \quad (6)$$

其中, $z_{i,j}$ 是EM算法中的中间变量,其计算如下:

$$z_{i,j}^{(k+1)} = \frac{\pi_{i,j}^{(k)} \sum_{m \in N_i} \frac{\omega_m}{Q_i} p(x_m|\theta_j^{(k)})}{\sum_{h=1}^M \pi_{i,h}^{(k)} \sum_{m \in N_i} \frac{\omega_m}{Q_i} p(x_m|\theta_h^{(k)})} \quad (7)$$

其中, N_i 表示第 i 个像素的邻域, ∂_i 表示第 i 个像素的邻域但不包含第 i 个像素,即 $\partial_i = N_i - \{i\}$ 。 ω_m 是邻域像素的权重, Q_i 是权重的归一化系数:

$$Q_i = \sum_{m \in N_i} \omega_m \quad (8)$$

本文采用 3×3 的均值模板对像素添加空间信息约束,同时考虑像素间空间距离与灰度值之间的关系。定义 ω_m 如下:

$$\omega_m = S_{s,ij} \times S_{g,ij} \quad (9)$$

其中, $S_{s,ij}$ 与中心像素 i 和邻域像素 j 之间的空间距离相关,距离越远, $S_{s,ij}$ 越小; $S_{g,ij}$ 表示中心像素 i 和邻域像素 j 之间灰度的关联,灰度值越接近, $S_{g,ij}$ 越大。 $S_{s,ij}$ 和 $S_{g,ij}$ 的定义如下:

$$S_{s,ij} = \exp\left(\frac{-d_{i,j}^2}{2\sigma_d^2}\right) \quad (10)$$

$$S_{g,ij} = \exp\left(\frac{-\|x_i - x_j\|^2}{2\sigma_r^2}\right)$$

其中, $d_{i,j}$ 表示像素 i 和像素 j 之间的欧氏距离, x_i 和 x_j 分别表示像素 i 和像素 j 的灰度值; σ_d 与邻域窗口的大小有关, σ_r 受图像中噪声标准差影响较大^[17],定义 $\sigma_d = \frac{M \times N - 1}{4}$, M 和 N 分别表示模板窗口的长和宽,本文窗口大小为 3×3 ,即 $M \times N = 9$,故 $\sigma_d = 2$ 。 σ_r 的取值分以下两种情况:

1)对于噪声图像,若已知噪声标准差 σ_{noise} ,则 $\sigma_r = \lambda_1 \sigma_{\text{noise}}$,

λ_1 是常系数,根据实际情况确定合适的值。

2)对于无噪声图像, $\sigma_r = \lambda_2 \sigma_{X_{N_i}}$, λ_2 是常系数,根据实际情况选取合适的值, $\sigma_{X_{N_i}}$ 是包含中心像素在内的邻域像素灰度值的标准差。

考虑到对无噪声图像应用均值模板时会使图像的部分细节丢失,本文在用均值模板时增加了一个噪声判断。当中心像素灰度值是邻域像素中的最大值或最小值时,认为它是噪声点,使用均值模板;否则不对中心像素做任何改变。这样既能很好地结合像素间的空间关系,有效抑制噪声,又能保持图像细节,提高图像分割精度。

针对噪声图像,为了更好地抑制噪声干扰,在运用本文两种混合模型之前,先进行图像重塑。通过引入相似性度量 $S_{i,j}$,重塑后的像素 i 的灰度值 ξ_i 的计算如下:

$$\xi_i = \frac{\sum_{j \in N_i} S_{i,j} x_j}{\sum_{j \in N_i} S_{i,j}} \quad (11)$$

其中, $S_{i,j}$ 的定义同时考虑了像素间的空间相似性 $S_{s,ij}$ 和灰度相似性 $S_{g,ij}$:

$$S_{i,j} = \begin{cases} S_{s,ij} \times S_{g,ij}, & j \neq i \\ 0, & j = i \end{cases} \quad (12)$$

其中, $S_{s,ij}$ 和 $S_{g,ij}$ 的定义同式(10)。

图像分割标准是最大后验准则。首先,用高斯混合模型对图像进行估计,得到每一个像素的后验概率,然后根据最大后验准则对每个像素进行分类,完成图像的初步分割。因初步分割图像中仍然会有一些未被正确分割的孤立点,故在此基础上采用K近邻法对分割图像做后处理,以改善图像的分割结果。

2.3 分割效果评价

本文采用3种指标来对实验结果进行评价:结构相似性(Structural Similarity Index, SSIM)、误分率(Misclassification Error, MCR)和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)。

结构相似性是一种全参考的图像质量评价指标,它分别从亮度 $l(X,Y)$ 、对比度 $c(X,Y)$ 、结构 $s(X,Y)$ 3方面来度量图像的相似性。SSIM值越大,表示分割图像与原图像结构越相似,分割效果越好。

$$SSIM(X,Y) = l(X,Y) \times c(X,Y) \times s(X,Y) \quad (13)$$

其中, $l(X,Y)$, $c(X,Y)$ 和 $s(X,Y)$ 的表示如下:

$$l(X,Y) = \frac{2\mu_X \mu_Y + C_1}{\mu_X^2 + \mu_Y^2 + C_1}$$

$$c(X,Y) = \frac{2\sigma_X \sigma_Y + C_2}{\sigma_X^2 + \sigma_Y^2 + C_2} \quad (14)$$

$$s(X,Y) = \frac{2\sigma_{XY} + C_3}{\sigma_X \sigma_Y + C_3}$$

其中, μ_X 和 μ_Y 分别表示图像 X 和图像 Y 的灰度均值; σ_X 和 σ_Y 分别表示图像 X 和图像 Y 的灰度方差; σ_{XY} 表示图像 X 和图像 Y 的灰度协方差; C_1, C_2, C_3 为常数,通常取 $C_1 = (K_1 \times L)^2, C_2 = (K_2 \times L)^2, C_3 = \frac{C_2}{2}$,其中, $K_1 = 0.01, K_2 = 0.03, L = 255$ 。

误分率表征图像错误分割部分所占的比例,定义如下:

$$MCR = \text{误分像素数} / \text{像素总数} \times 100 \quad (15)$$

从式(15)可以看出, MCR 的取值范围为 $[0, 1]$, 其值越小, 表示分割结果越好。

峰值信噪比用于评价图像分割结果抗噪能力的大小, 其值越大, 表示分割结果抗噪能力越强, 定义如下:

$$PSNR = 10 \log_{10} \left(\frac{(2^n - 1)^2}{MSE_{X,Y}} \right) \quad (16)$$

其中, $MSE_{X,Y}$ 表示图像 X 和图像 Y 的灰度均方误差; n 为像素的比特数, 一般取为 8, 即像素灰阶数为 256。

3 实验结果与分析

本文首先分别用上述几种方法对仿真图像和自然图像进行分割, 并比较本文方法与其他方法的分割效果; 然后对自然图像分别添加斑点噪声和高斯噪声, 再对加噪后的图像进行图像分割, 最后用上述 3 种评价指标评价本文方法与其他方法的分割结果。其他方法包括传统高斯混合模型法(GMM)、图像重塑法(R_GMM)^[6]、噪声因子法(NS_GMM)^[7]和空间平滑的高斯混合模型法(SS_GMM)^[10]。本文方法为多分类高斯混合模型(MC_GMM)和基于邻域信息的高斯混合模型(NI_GMM)法。实验证明, 本文方法可以取得更好的图像分割结果, 并且抗噪能力更强。实验在 Matlab 2014a 平台上实现, 其中仿真图像通过 Photoshop CS6 绘制, 自然图像取自 Berkeley 图像标准数据库^[18]。实验流程如图 3 所示。




图 3 实验流程图

Fig. 3 Flowchart of experiment

首先对仿真图像分别添加斑点噪声和高斯噪声, 然后分别用本文方法和其他方法对噪声图像进行分割处理, 并比较分割效果。实验结果如图 4 和图 5 所示。




图 4 斑点噪声图分割结果

Fig. 4 Segmentation results of simulation image with speckle noise

观察图 4, 对比传统高斯混合模型, 图像重塑法^[6](R_GMM)的抗噪能力提升很多, 但仍残留较多噪声; 噪声因子法^[7](NS_GMM)对噪声的抑制能力稍弱; 而空间平滑的高斯混合模型法^[10](SS_GMM)相比前 3 种方法, 抗噪能力大幅增强, 但一些边角和中间圆环处仍有噪声点。图 4(g)是本文基于多分类高斯混合模型(MC_GMM)的图像分割结果, 相比于前几种分割模型, 其分割效果提升明显, 在较好地保持图像轮廓的基础上有效地抑制了大部分噪声干扰。图 4(h)是本文基于邻域信息的高斯混合模型(NI_GMM)的图像分割结果, 可以看到, 该方法的分割精度高, 且几乎不受噪声干扰。

表 1 给出了各方法的定量评估结果。

表 1 各方法的定量评估结果 1

Table 1 Quantitative evaluation results 1 of each method

方法	结构相似性	误分率	信噪比/dB	用时/s
GMM	0.8483	0.2724	13.6685	59.9115
R_GMM ^[6]	0.9304	0.1313	17.9349	54.4095
NS_GMM ^[7]	0.8867	0.2857	15.1685	396.4583
SS_GMM ^[10]	0.9857	0.0235	24.1064	1064.5271
MC_GMM	0.9869	0.0145	24.4328	130.1324
NI_GMM	0.9927	0.0036	26.5838	948.1625

分析表 1 可知: 本文 NI_GMM 和 MC_GMM 的 3 种指标都优于其他方法, 前者耗时较长, 但分割效果最好; 后者分割效果不如 NI_GMM 法, 但处理速度极快。综合而言: MC_GMM 能够取得很好的图像分割结果, 且处理速度快; NI_GMM 虽耗时较长, 但能够取得更好的图像分割结果。

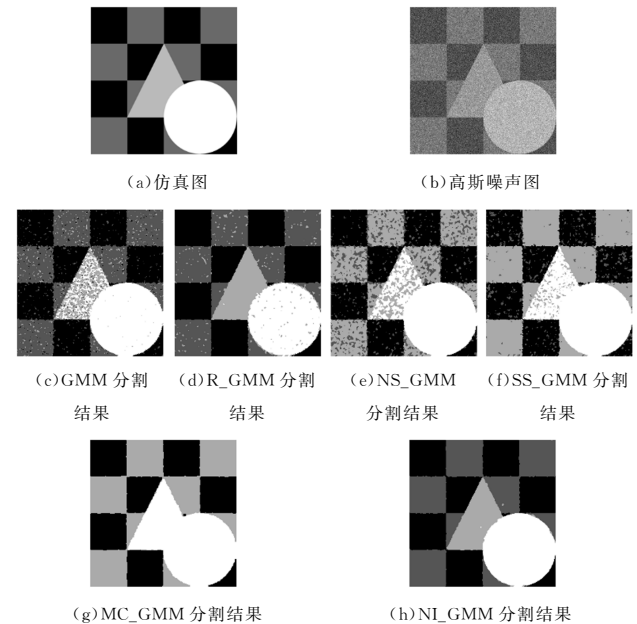


图 5 高斯噪声图分割结果

Fig. 5 Segmentation results of simulation image with Gaussian noise

观察图 5 可知, 相比于传统高斯混合模型的结果, 图像重塑法(R_GMM)和空间平滑的高斯混合模型法(SS_GMM)的分割结果提升较大, 但受噪声干扰依然较明显; 本文多分类高斯混合模型(MC_GMM)和基于邻域信息的高斯混合模型(NI_GMM)的分割结果受噪声影响非常小, 前者将图中三角形和圆形区域标记为同一区域, 而后者则很好地区分这两区域。

各方法的定量评估结果如表2所列。

表2 各方法的定量评估结果2

Table 2 Quantitative evaluation results 2 of each method

方法	结构相似性	误分率	信噪比/dB	用时/s
GMM	0.9609	0.0903	19.4833	54.1470
R_GMM ^[6]	0.9808	0.0267	22.6938	50.5881
NS_GMM ^[7]	0.9203	0.1438	15.8770	199.6496
SS_GMM ^[10]	0.9044	0.0667	14.7479	579.9389
MC_GMM	0.9132	0.0079	15.0677	103.5021
NI_GMM	0.9875	0.0079	24.5144	1213.8205

分析表2可知:MC_GMM法和NI_GMM法的误分率远小于其他几种方法,前者分割结果的结构相似性和信噪比不如后者高,但其耗时短,后者3种指标的数据都最好,但用时较长。

然后对自然图像、添加斑点噪声和高斯噪声的自然图像进行处理。实验结果如图6和图7所示。




图6 自然图像分割结果1

Fig. 6 Segmentation results 1 of natural image

观察图6可知,子图(c),(d),(e),(j),(k)是对实验原图的分割结果,其中子图(j)和(k)分别为本文MC_GMM和NI_GMM的分割结果,子图(e),(j),(k)的分割效果都较好,但子图(j)和(k)中的噪声点比(e)中的少。因实验原图中右上角天空颜色较其他区域深,所以分割图的右上角会有一块灰色区域。子图(f),(g),(h),(i)是其他方法对含噪图像进行分割的结果,可以看到,子图(f)和(g)虽噪声减少很多,但丢失了大部分图像细节,比如天空和地面混为一体,图像分割精度不高,人物主体仍残留噪声等。子图(i)的人物轮廓的分割效果较好,但相机部分细节丢失,图像整体受噪声影响较

大。子图(l)和(m)是本文方法对含噪图像进行分割的结果,两者都很好地保持了图像的轮廓和细节,且有效地抑制了大部分噪声干扰,而相对于前者,后者对噪声的抑制能力更强。

表3列出对实验原图的分割效果评价结果。

表3 各方法的定量评估结果3

Table 3 Quantitative evaluation results 3 of each method

方法	结构相似性	用时/s
GMM	0.7853	70.7731
NS_GMM ^[7]	0.7782	134.8953
SS_GMM ^[10]	0.7886	1400.0012
MC_GMM	0.8091	177.7779
NI_GMM	0.8150	1097.5767

从表3中可以看到,本文NI_GMM的效果是最好的。

表4是对加噪图像的分割效果的评价结果,以表3中分割效果最好的图作为对比图,对表4中各方法的处理图像与该对比图进行比较,计算得到表4中的各指标值,以此评判各方法的分割效果和抗噪性。

表4 各方法的定量评估结果4

Table 4 Quantitative evaluation results 4 of each method

方法	结构相似性	误分率	信噪比/dB	用时/s
GMM	0.7704	0.0788	10.0097	65.1437
R_GMM ^[6]	0.7823	0.0732	10.2350	87.6025
NS_GMM ^[7]	0.8754	0.1532	14.0257	236.1526
SS_GMM ^[10]	0.8918	0.1576	13.8610	1688.3724
MC_GMM	0.9449	0.0764	17.2167	195.2138
NI_GMM	0.9619	0.0517	18.9106	1721.4532

综合而言:本文MC_GMM和NI_GMM都优于其他方法,前者处理速度快且分割效果良好;后者虽耗时较长,但能够取得更好的图像分割结果。



图7 自然图像分割结果2

Fig. 7 Segmentation results 2 of natural image

观察图7可知,子图(c),(d),(e),(j),(k)是对实验原图的分割结果。可以看到,子图(j)和(k)的结果比前几种方法

的结果更好。子图(f),(g),(h),(i)是其他方法对含噪图像进行分割的结果,可以看出,子图(g)和(i)的结果较好,但图像中噪声点仍然较多。子图(l)和(m)是本文方法对含噪图像进行分割的结果,结果最好的是子图(m),该图受噪声干扰最小,且较好地保留了图像细节。

表 5 列出对实验原图分割效果的分析结果。

表 5 各方法的定量评估结果 5

Table 5 Quantitative evaluation results 5 of each method

方法	结构相似性	用时/s
GMM	0.8961	156.8750
NS_GMM ^[7]	0.8971	582.2451
SS_GMM ^[10]	0.9028	1681.5132
MC_GMM	0.8994	555.6781
NI_GMM	0.9253	1502.2904

从表 5 中可以看到:本文 NI_GMM 方法优于其他方法。

表 6 是对加噪图像的分割效果的评价结果,同样以表 5 中分割效果最好的图作为对比图,计算该对比图与表 6 中各方法分割图像的各指标值,以此分析各方法的分割效果和抗噪性。

表 6 各方法的定量评估结果 6

Table 6 Quantitative evaluation results 6 of each method

方法	结构相似性	误分率	信噪比/dB	用时/s
GMM	0.9504	0.2387	18.1945	176.5049
R_GMM ^[6]	0.9429	0.1737	18.3658	231.9187
NS_GMM ^[7]	0.9407	0.2014	17.8407	237.2209
SS_GMM ^[10]	0.9574	0.1549	18.9729	1430.9704
MC_GMM	0.9633	0.1548	19.7024	608.2422
NI_GMM	0.9690	0.1427	20.4956	1567.1765

分析可知:本文多分类混合模型(MC_GMM)能够快速取得较好的图像分割结果;本文基于邻域信息的混合模型(NI_GMM)虽耗时较长,但图像分割效果更好。

结束语 基于传统混合模型的图像分割方法由于缺少对像素间空间关系的分析,因此对噪声较敏感,且分割精度不高。为此,本文在分析研究各种改进混合模型的基础上,提出了多分类混合模型和基于邻域信息的混合模型方法,前者进一步细化了混合模型的混合成分,提高了图像的分割精度和抗噪性;后者通过在像素先验概率和后验概率的计算中考虑邻域像素的相互作用,进一步提升了图像的分割效果,同时有效地抑制了噪声干扰。基于邻域信息的混合模型方法的分割效果最好,但耗时较长,且模型参数求解时受初值影响较其他模型大,初值选取不当易使迭代求解结果不收敛。因此后续工作中将对该算法进行优化,以在加快处理速度的同时优化参数求解过程。改进模型参数初值的选取方法,从而提高模型的稳健性和处理速度,是需要考虑的首要问题。

参 考 文 献

[1] WANG L X, XIE W X, PEI J H. Ocean borne image segmentation using muti Gaussian mixture model covering feature space learning[J]. Transactions of Electronics, 2014, 42(10): 2117-2122. (in Chinese)
王荔霞, 谢维信, 裴继红. 多高斯模型特征空间覆盖学习的海洋航摄图像分割[J]. 电子学报, 2014, 42(10): 2117-2122.

[2] SUN Q S, JI Z X. Overview of brain magnetic resonance image segmentation algorithms based on fuzzy clustering [J]. Data Acquisition and Processing, 2016, 31(1): 28-42. (in Chinese)
孙权森, 纪则轩. 基于模糊聚类的脑磁共振图像分割算法综述[J]. 数据采集与处理, 2016, 31(1): 28-42.

[3] ZHANG M H, GUO Z W, LIU Y. Segmentation algorithm based on mixture model for SAR images of land and sea [J]. Photoelectron. Laser, 2017, 28(3): 326-333. (in Chinese)
张苗辉, 郭拯危, 刘扬. 基于混合模型的 SAR 影像海陆分割算法[J]. 光电子. 激光, 2017, 28(3): 326-333.

[4] ZHANG L, GAN C S, HU Y. Research on ship detection algorithms for high resolution optical remote sensing images [J]. Computer Engineering and Applications, 2017, 53(9): 184-189. (in Chinese)
张雷, 甘春生, 胡宇. 高分辨率光学遥感影像舰船检测算法研究[J]. 计算机工程与应用, 2017, 53(9): 184-189.

[5] 章毓晋. 图像分割[M]. 北京: 科学出版社, 2001.

[6] CAI W L. Research on image segmentation and classifier design based on clustering [D]. Nanjing: Nanjing University of Aeronautics & Astronautics, 2008. (in Chinese)
蔡维玲. 基于聚类的图像分割和分类器设计的研究[D]. 南京: 南京航空航天大学, 2008.

[7] ZHAO Q H, SHI X, WANG Y, et al. Remote sensing image segmentation by Gaussian mixture model with variable spatial constraint [J]. Journal of Communications, 2017, 38(2): 34-43. (in Chinese)
赵泉华, 石雪, 王玉, 等. 可变类空间约束高斯混合模型遥感图像分割[J]. 通信学报, 2017, 38(2): 34-43.

[8] SANJAY-GOPAL S, HEBERT T J. Bayesian pixel classification using spatially variant finite mixtures and the generalized EM algorithm [J]. IEEE Transactions on Image Processing, 1998, 7(7): 1014-1028.

[9] NIKOU C, GALATSANOS N P, LIKAS A C. A class-adaptive spatially variant mixture model for image segmentation [J]. IEEE Transactions on Image Processing, 2007, 16(4): 1121-1130.

[10] YANG Y F. Research on application of medical image segmentation algorithms based on finite mixture model [D]. Nanjing: Southeast University, 2015. (in Chinese)
杨云飞. 基于有限混合模型的医学图像分割算法应用研究[D]. 南京: 东南大学, 2015.

[11] ZHANG H, WU Q M J, NGUYEN T M. Incorporating mean template into finite mixture model for image segmentation [J]. IEEE Transactions on Neural Networks and Learning Systems, 2013, 24(2): 328-335.

[12] PRAKASH R M, KUMARI R S S. Gaussian Mixture Model with the Inclusion of Spatial Factor and Pixel Re-labelling: Application to MR Brain Image Segmentation [J]. Arabian Journal for Science & Engineering, 2017, 42(2): 595-605.

[13] VEGAS-SANCHEZ-FERRERO G, SEABRA J, RODRIGUEZ-LEOR O, et al. Gamma mixture classifier for plaque detection in intravascular ultrasonic images [J]. IEEE Transactions on Ultrasonics Ferroelectrics and Frequency Control, 2014, 61(1): 44-61.

结束语 本文提出了一种新型的基于深度学习的单幅图像雨滴去除方法。该方法首先将有雨滴的源图像映射到 YUV 空间;然后在基于图像修复的极深网络框架下学习雨滴图像和无雨滴图像的深层残差特征图;最后将源图像的亮度分量与残差特征图进行叠加,得到重构的去雨图像,并将结果逆映射到 RGB 空间,更好地保留了图像的色度信息。文中还对不同环境中的雨滴图像进行了测试,并给出了主客观评价指标。实验结果表明,该方法能够更好地去除图像中的雨滴,极大地改善了图像的视觉效果。

参 考 文 献

- [1] JOACHIMS T. Making Large-scale SVM Learning Practical [J]. *Advanced in Kernel Methods-Support Vector Learning*, 1999, 8(3): 499-526.
 - [2] ZAKZESKI J, BRUIJNINX P C, JONGERIUS A L, et al. The Catalytic Valorization of Lignin for The Production of Renewable Chemicals[J]. *Chemical Reviews*, 2010, 110(6): 3552.
 - [3] HUANG D A, KANG L W, WANG Y C F, et al. Self-Learning Based Image Decomposition with Applications to Single Image Denoising[J]. *IEEE Transactions on Multimedia*, 2013, 16(1): 83-93.
 - [4] KANG L W, LIN C W, FU Y H. Automatic Single-image-based Rain Streaks Removal via Image Decomposition [J]. *IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society*, 2011, 21(4): 1742-1755.
 - [5] LUO Y, XU Y, JI H. Removing Rain from a Single Image via Discriminative Sparse Coding[C]//*Proceedings of IEEE Conference on Computer Vision*. Santiago: IEEE Press, 2015: 3397-3405.
 - [6] YIN B C, WANG W T, WANG L C. Review of Deep Learning [J]. *Journal of Beijing University of Technology*, 2015, 41(1): 48-59. (in Chinese)
尹宝才,王文通,王立春. 深度学习研究综述[J]. *北京工业大学学报*, 2015, 41(1): 48-59.
 - [7] HE K, ZHANG X, REN S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(9): 1904-1916.
 - [8] EIGEN D, KRISHNAN D, FERGUS R. Restoring an Image Taken through a Window Covered with Dirt or Rain[C]//*Proceedings of IEEE International Conference on Computer Vision*. Sydney: IEEE Press, 2013: 633-640.
 - [9] FU X, HUANG J, DING X, et al. Clearing the Skies: A Deep Network Architecture for Single-image Rain Streaks Removal [J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2944-2956.
 - [10] FU X, HUANG J, ZENG D, et al. Removing Rain from Single Images via a Deep Detail Network [C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Hawaii: IEEE Press, 2017: 1715-1723.
 - [11] ZHANG K, CHEN Y, CHEN Y, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising[J]. *IEEE Transactions on Image Processing*, 2016, 26(7): 3142-3155.
 - [12] KIM J, LEE J K, LEE K M. Accurate Image Super-Resolution Using Very Deep Convolutional Networks [C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Sichuan: IEEE Press, 2016: 1646-1654.
 - [13] HINTON G E, OSINDERO S, AND TEH Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. *Neural Computation*, 2014, 18(7): 1527-1554.
 - [14] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Nevada: IEEE Press, 2016: 770-778.
 - [15] DONG C, CHEN C L, HE K, et al. Image Super-Resolution Using Deep Convolutional Networks[J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2016, 38(2): 295-307.
 - [16] LI Y, TAN R T, GUO X, et al. Rain Streak Removal using Layer Priors[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. Chengdu: IEEE Press, 2016: 2736-2744.
 - [17] JIA Y Q, SHELHAMER, et al. Caffe: Convolutional Architecture for Fast Feature Embedding[C]//*Proceedings of the 22nd ACM International Conference on Multimedia*. Florida: IEEE Press, 2014: 675-678.
 - [18] VEDALDI A, LENC K. MatConvNet: Convolutional Neural Networks for MATLAB[C]//*Proceedings of the 23rd ACM International Conference on Multimedia*. Brisbane: IEEE Press, 2015: 689-692.
 - [19] SCHAEFER G. UCID: An Uncompressed Color Image Database [C]//*Proceedings of Storage & Retrieval Methods & Applications for Multimedia*. CA: IEEE Press, 2003: 472-480.
 - [20] BARNUM P C, NARASIMHAN S, KANADE T. Analysis of Rain and Snow in Frequency Space[J]. *International Journal of Computer Vision*, 2010, 86(2): 256-274.
- (上接第 277 页)
- [14] COPSEY K, WEBB A. Bayesian gamma mixture model approach to radar target recognition [J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2003, 39(4): 1201-1217.
 - [15] QIN Y, PRIEBE C E. Maximum L_q-Likelihood Estimation via the Expectation-Maximization Algorithm: A Robust Estimation of Mixture Models [J]. *Journal of the American Statistical Association*, 2013, 108(503): 914-928.
 - [16] COMER M, BOUMAN C A, DE GRAEF M, et al. Bayesian methods for image segmentation [J]. *JOM Journal of the Minerals, Metals and Materials Society*, 2011, 63(7): 55-57.
 - [17] ZHANG M. Bilateral filter in image processing [J]. *Applied Surface Science*, 2006, 253(2): 468-475.
 - [18] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics[C]//*Proceeding of International Conference on Computer Vision*. 2001: 416-423.