

联合 Sobolev 梯度的相场变分模型 应用于图像显著性检测

李梦^{1,2}, 刘星¹, 任泽民³

(1. 重庆大学经济与工商管理学院, 重庆 400030; 2. 重庆工商大学数学与统计学院, 重庆 400067;
3. 重庆科技学院数理学院, 重庆 401331)

摘要: 基于变分框架和相变换理论, 提出能量泛函应用于图像显著性检测, 采用 Sobolev 梯度法最小化该能量泛函, 由此导出基于时间的演化系统应用于计算机视觉选择, 其检测过程是图像显著和非显著分量的竞争变化. 比较传统的 L_2 梯度, Sobolev 度量具有更好的正则性. 论文阐述了演化系统的动态行为和视觉选择之一致性, 这对探索新的显著性检测机制非常重要. 实验显示, 本文模型在较好压制图像背景的同时, 获得较为精细的目标、纹理、绒毛等信息, 这些信息对于视觉感知是非常重要的.

关键词: 视觉注意; 显著性检测; 相场方法; 变分模型; Sobolev 梯度

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2018)07-1683-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2018.07.021

A Phase Field Variational Model Joint Sobolev Gradient for Saliency Detection

LI Meng^{1,2}, LIU Xing¹, REN Ze-min³

(1. College of Economics and Business Administration, Chongqing University, Chongqing 400030, China;
2. College of Mathematics and Statistics, Chongqing Technology and Business University, Chongqing 400067, China;
3. College of Mathematics and Physics, Chongqing University of Science and Technology, Chongqing 401331, China)

Abstract: An energy functional based on variational framework and the phase-transition theory is presented for saliency detection. We describe a Sobolev gradient to find minima of the proposed functional, and then a temporal evolution system for computer visual selection is produced. The process of saliency extraction is a dynamical competition between salient and non-salient component. Comparing the classical L_2 gradient, we find that the Sobolev metric induces favorable regularity properties in their gradient flow. We demonstrate the consistency between the dynamical behavior of the evolution system and visual selection, which is very important for human to exploit new mechanism of saliency detection. Experimental results on various images show that our model achieves better suppression of the information in background, while achieving higher detection precision of the object, texture, hair, etc, which is important in terms of human visual perception.

Key words: visual attention; saliency detection; phase field method; variational model; Sobolev gradient

1 引言

显著性是图像中能引起感官注意视觉刺激的特征区域、像素点或纹理等. 显著性检测是利用算法对图像数据加工, 使计算机具备人类视觉之选择能力, 获取图像显著性. 图像显著性建立了图像与高层语义之内在联系, 给后续图像处理, 如图像检索^[1]和目标追踪^[2]等

带来极大便利.

人的大脑易感知图像显著性, 这种感知源于低水平信号刺激或高水平任务驱使, 因此图像显著性检测可分为“下到上”^[3-9]和“上到下”^[10,11]两种模式. “下到上”是低水平数据驱动的显著性检测方法, 最具代表的是 Itti 等提出的生物模型^[3]. 之后, Hou 和 Zhang^[4]提出谱残差方法, Harel 等^[5]提出基于图的检测方法; Achan-

收稿日期: 2017-02-13; 修回日期: 2017-08-19; 责任编辑: 李勇锋

基金项目: 国家自然科学基金 (No. 61601068); 重庆市基础与前沿研究计划 (No. cstc2015jcyjA40029); 重庆市教委科学计划研究 (No. KJ1601317); 重庆工商大学校内科研 (No. 2016-56-08, No. 1752002)

ta 等^[6]提出频率调谐方法; Fang 等^[7]提出基于视觉敏感和振幅频谱方法; Cheng 等^[8]利用生物视觉系统对高对比信号敏感, 提出基于区域直方图对比模型, Sheth 和 Babu^[9]提出基于背景先验的方法等. 这些模型^[3-9]从生物视觉到计算, 建立了计算机对人脑的模拟, 极大丰富了计算机视觉理论, 但由此获得的显著映射图存在分辨率低^[3-5], 背景清晰^[6], 显著特征模糊^[3-5,7], 显著区域内关键数据丢失严重^[8,9]等问题.

与“下到上”不同, “上到下”是任务驱动显著性检测方法. Tsotsos 等^[10]利用胜者为王竞争机制建立反馈连接, 获取图像中注意被刺激位置; Deco 和 Zihl^[11]认为图像特征图与任务增强和干扰项的抑制相关, 提出了神经动力学模型. 联合上到下和下到上机制, Ma 和 Zhang^[12]提出基于三水平级注意分析的混合比较模型, Feng 等^[13]提出多尺度比较模型, Lou 等^[14]提出主色调对比模型, Li 等^[15]联合低水平图像特征和深度神经网络提出 LCNN 模型. 这些模型^[10-15]从不同角度阐释了图像显著性, 但是一些关键信息, 如花蕊、叶脉等信息仍然被忽略. 而且我们对视觉注意机制的理解还远远不够, 因此需要更多手段更多方法去分析、理解并获取图像关键信息.

我们认为要有效的捕获图像显著信息, 并压制图像的背景信息, 可以借助于变分框架下图像的非线性扩散来实现. 过去几十年, 非线性扩散已被广泛应用于图像恢复^[16]和图像去噪^[17], 它们以 Perona-Malik^[18]工作为基础, 对区域内和区域间采用不同的滤波策略, 从而平滑图像噪声, 恢复退化信号等. 与 Perona-Malik 方法不一样, 本文目的是构造新的变分模型, 通过能量泛函的极小使图像的显著和背景分量向不同方向急剧变化, 一方面显著信息被突出, 另一方面背景变暗变黑趋于消失. 这思想类似于热力学的相场变化, 即物质固相和液相在凝固过程中分别向 1 和 0 方向发展变化.

相场方法^[19,20]源于 20 世纪 50 年代, 被广泛应用于物理、流体力学、材料科学等领域. 其基本思想是在物质界面处引入急剧变化但连续的相场变量, 来描述系统中不稳定分量(相)结构状态, 通过变分模型能量泛函的极小或微分方程的反应扩散来区分物质的固相和液相, 从而刻画组织演化问题. 1950 年, Ginzburg 和 Landau^[19]提出描述物质超导和非超导特性相场模型, 随后 Cahn 和 Hilliard^[20]考虑二值流体系统不稳定分量演化问题, 提出固液分离相场模型. 近二十年相场方法被应用于图像处理, 如: 图像修补^[21]和二余维目标检测^[22]等. 考虑到图像显著性检测是让图像的显著分量与背景相分离, 本文在 Cahn-Hilliard 模型^[20]基础上, 设计基于图像信息的相场变分模型应用于图像显著性检测. 该模型包括正则项、相变换项和保真项三个能量泛函,

通过 Sobolev 梯度极小化该泛函, 获得与时间变量相关的偏微分方程组, 通过时间演化使图像信息向着亮和暗两方向运动, 获取图像显著特征. 实验结果阐述了基于时间的动态演化和大脑记忆选择之一致性, 这对探索新的显著性检测机制非常重要.

2 Cahn-Hilliard 模型

在非均匀流体系统中, 如何让两个不稳定分量自发分离并形成各自纯净的区域? 基于热力学方程, Cahn 和 Hilliard^[20]提出如下能量泛函:

$$E_{\varepsilon}^{CH}(u) = \varepsilon \int_{\Omega} |\nabla u|^2 dx + \frac{1}{\varepsilon} \int_{\Omega} W(u) dx \quad (1)$$

其中 $\varepsilon > 0$ 是参数, $|\nabla u|$ 是函数 u 的梯度模, $W(u) = u^2(u-1)^2$ 是双势阱函数. 第 1 项是正则项, 惩罚函数 u 的空间不均匀性; 第 2 项是相变换项, 最小化该能量泛函将迫使函数 u 的值逼近 0 和 1, 数学理论已证明, 在 $u=0$ 和 $u=1$ 两个相场之间存在 $0 < u < 1$ 相变换区域. 该模型在热动力学中描述物质局部状态: $u=1$ 表示固相, $u=0$ 液相, $0 < u < 1$ 表示固-液混合界面. 通过系统演化, 系统中不稳定分量逐渐达到平衡状态, 从而产生固相、液相及中间界面的分离.

3 本文方法

3.1 算法思想

类似于二值流体问题, 本文将图像的显著特征和背景理解为同一系统中两个不稳定分量(相). 为此, 本文构造基于图像信息的相场变分模型, 目的是通过非线性变化, 使图像显著分量和背景分别逼近于 1 和 0, 压制背景的同时突出图像显著特征. 具体作法是: 先将图像数据标准化, 再利用标准化数据构造复数 $u_0 = \omega_0 + iv_0$ 作为相变化的初始数据, 用 $u = \omega + iv$ 来描述图像结构状态变化, 设计基于复变函数 u 的相场变分模型, 最后用 Sobolev 梯度下降法把变分模型转化为与时间相关的偏微分方程组, 通过循环迭代求解获取图像显著性.

3.2 图像显著性检测的相场变分模型

首先将图像数据标准化. 设 Ω 是图像域, $I: \Omega \subset \mathbb{R}^2 \rightarrow \mathbb{R}$ 是灰度图像, $I(\Omega) \subset [0, 255]$, $f: I \rightarrow \omega_0$ 是 I 到 ω_0 的映射,

$$\omega_0(x_{ik}) = \frac{I_{ik} - \min\{I_{ik}\}}{\max\{I_{ik}\} - \min\{I_{ik}\}} \\ (i = 1, 2, \dots, n; k = 1, 2, \dots, m)$$

以 ω_0 为实部, $v_0 = \sqrt{1 - \omega_0}$ 为虚部, 构造复变函数 $u_0 = \omega_0 + iv_0$, 显然 $\omega_0 \in [0, 1]$ 是图像数据的标准化, $v_0 \in [0, 1]$, 图像上每一点有 $|u_0| = 1$.

下面提出变分模型应用于图像显著性检测:

$$E(u) = \frac{1}{2} \int_{\Omega} (g(|\nabla u|) \cdot |\nabla u|^2) dx + \frac{1}{2\varepsilon^2} \int_{\Omega} W(|u|) dx + \frac{\lambda}{2} \int_{\Omega} |u - u_0|^2 dx \quad (2)$$

其中 $\varepsilon > 0, \lambda > 0$ 是参数, $u = \omega + iv$ 是复变函数, $g(s) = 1/(1+s^2)$, $W(s) = s^2(s-1)^2$ 是双势阱函数, $|u|$ 是 u 的模. 与式(1)用实数描述流体问题不同, 式(2)用复变函数描述图像状态变化, 增加权系数 g 和保真项 $\int_{\Omega} |u - u_0|^2 dx$ 约束图像变化. 下面阐述式(2)各项作用.

第 1 项是正则项, 它的最小化将惩罚图像噪声并保持边缘和纹理等特征. 具体说: 在图像同质区域, $|\nabla u| \rightarrow 0, g \rightarrow 1$, $\int_{\Omega} g \cdot |\nabla u|^2 dx \rightarrow \int_{\Omega} |\nabla u|^2 dx$, 极小化该能量泛函将惩罚 u 的空间不均匀性, 平滑图像噪声; 在图像边缘和纹理等区域, $|\nabla u| \rightarrow \infty, g \rightarrow 0$, $\int_{\Omega} g \cdot |\nabla u|^2 dx \rightarrow 0$, 泛函已达到极小, 意味图像不再非线性扩散, 图像特征被保持.

第 2 项是相变换项, 极小化该能量泛函将迫使 $|u|$ 逼近 0 和 1. 在图像中, $|u| = 1$ 描述图像显著区域, $|u| = 0$ 描述背景区域, $0 < |u| < 1$ 刻画图像轮廓、纹理等混合区域. 能量泛函的极小将使得这些区域逐渐分离并达到平衡状态, 从而实现图像的显著性检测.

第 3 项为数据保真相, 其作用是使函数 u 在变化过程中始终逼近于初始状态 u_0 , 即图像特征不发生根本性改变.

3.3 Sobolev 梯度和模型的极小

接下来是能量泛函极小化问题. 目前常用方法是由 Gâteaux 导数推出的 L_2 梯度流方法, 本文用 Sobolev 梯度法极小化式(2). Renka^[23] 已阐明 Sobolev 梯度具有良好的正则性, 能加快能量泛函的收敛速度.

设 $\Omega \subset \mathbb{R}^2, C$ 为复数域, $H^{1,2}(\Omega, C)$ 是定义在 Ω 上的复变函数构成的 Sobolev 空间, 其范数定义为:

$$\|f\|_{H^{1,2}(\Omega, C)}^2 = \int_{\Omega} (\|\nabla f\|^2 + \|f\|^2), f \in H^{1,2}(\Omega, C)$$

式(2)中, $u = \omega + iv \in H^{1,2}(\Omega, C)$, 记:

$$G \begin{pmatrix} \omega \\ v \end{pmatrix} = E(u), G: H = H^{1,2}(\Omega, C) \rightarrow \mathbb{R}$$

定义微分算子:

$$D(r) = D \begin{pmatrix} \omega \\ v \end{pmatrix} = \begin{pmatrix} (\omega, \nabla \omega) \\ (v, \nabla v) \end{pmatrix}, r = \begin{pmatrix} \omega \\ v \end{pmatrix} \in H^{1,2}(\Omega, C)$$

记: $G(u) = \int_{\Omega} F(D(u))$, 其中, $F: \mathbb{R}^2 \times \mathbb{R}^2 \rightarrow \mathbb{R}$. 对 $\forall g, h \in H^{1,2}(\Omega, C)$, 定义其在 $H^{1,2}(\Omega, C)$ 空间内积:

$$\langle g, h \rangle_{H^{1,2}(\Omega, C)} = \int_{\Omega} gh + \langle \nabla g, \nabla h \rangle = \langle Dg, Dh \rangle_{L^2(\Omega)^*} \quad (3)$$

下面用 Gâteaux 导数推导 $E(u)$ 的 Sobolev 梯度. 取 $h \in H^{1,2}(\Omega, C)$, 先计算 $E(u)$ 的 Gâteaux 导数,

$$\begin{aligned} E'(u)h &= \lim_{\alpha \rightarrow 0} \frac{1}{\alpha} [E(u + \alpha h) - E(u)] \\ &= \int_{\Omega} \frac{\nabla u}{(1 + |\nabla u|^2)^2} \cdot \nabla h dx \\ &+ \int_{\Omega} \left(\frac{1}{\varepsilon^2} u (|u| - 1) (2|u| - 1) + \lambda (u - u_0) \right) h dx \end{aligned} \quad (4)$$

应用格林公式有:

$$\begin{aligned} \int_{\Omega} \frac{\nabla u}{(1 + |\nabla u|^2)^2} \cdot \nabla h dx &= \int_{\partial\Omega} \frac{1}{(1 + |\nabla u|^2)^2} \frac{\partial u}{\partial \mathbf{n}} \cdot h dS \\ &- \int_{\Omega} \nabla \cdot \left(\frac{\nabla u}{(1 + |\nabla u|^2)^2} \right) h dx \end{aligned} \quad (5)$$

其中 \mathbf{n} 为单位外法向量, $\partial\Omega$ 为 Ω 边界. 在零 Neumann 边界条件下, 式(5)第 1 项为 0, 联合式(4)和式(5), 有:

$$E'(u)h = \langle \nabla_{L_2} E(u), h \rangle_{L_2(\Omega)} \quad (6)$$

其中:

$$\begin{aligned} \nabla_{L_2} E(u) &= -\operatorname{div} \left(\frac{\nabla u}{(1 + |\nabla u|^2)^2} \right) \\ &+ \frac{1}{\varepsilon^2} u (|u| - 1) (2|u| - 1) + \lambda (u - u_0) \end{aligned} \quad (7)$$

称 $\nabla_{L_2} E(u)$ 为 $E(u)$ 在 $L_2(\Omega)$ 空间的 L_2 梯度.

由式(6)知 $E'(u)$ 存在, $u \in H^{1,2}(\Omega, C)$, 且对所有 $h \in H^{1,2}(\Omega, C)$, $E'(u)$ 是 $H^{1,2}(\Omega, C)$ 空间的有界线性泛函, 由 Riesz 表示定理知, $E'(u)h$ 在 $H^{1,2}(\Omega, C)$ 空间唯一表示成有界线性泛函 $E'(u)$, 形式如下:

$$E'(u)h = \langle \nabla_s E(u), h \rangle_{H^{1,2}(\Omega, C)} \quad (8)$$

称 $\nabla_s E(u)$ 为 $E(u)$ 在 $H^{1,2}(\Omega, C)$ 空间的 Sobolev 梯度. 联合式(3)和式(8), 有:

$$\begin{aligned} E'(u)h &= \langle \nabla_s E(u), h \rangle_{H^{1,2}(\Omega, C)} \\ &= \langle D \nabla_s E(u), Dh \rangle_{L^2(\Omega)^*} \\ &= \langle D * D \nabla_s E(u), h \rangle_{L^2(\Omega)} \end{aligned} \quad (9)$$

D^* 是 D 的伴随算子. 对比式(6)和式(9), 得到:

$$\nabla_s E(u) = (D * D)^{-1} \nabla_{L_2} E(u) \quad (10)$$

其中 $D^* D = (I - \nabla) \begin{pmatrix} I \\ \nabla \end{pmatrix} = I - \Delta$, I 为单位矩阵.

根据变分法基本原理, 用 Sobolev 梯度替换 L_2 梯度, 式(2)极小化等价于寻找梯度流 $u_t = -\nabla_s E(u)$ 稳态解, 即:

$$\frac{\partial u}{\partial t} = -\nabla_s E(u) = -(I - \Delta)^{-1} \nabla_{L_2} E(u) \quad (11)$$

其中, $\nabla_{L_2} E(u)$ 如式(7)所示, 初值条件 $u(0) = u_0$.

由于 $u = \omega + iv$, 则关于 ω 和 v 的演化方程是:

$$\frac{\partial \omega}{\partial t} = -\nabla_s E(\omega) = -(\mathbf{I} - \Delta_\omega)^{-1} \nabla_{L_2} E(\omega) \quad (12)$$

$$\frac{\partial v}{\partial t} = -\nabla_s E(v) = -(\mathbf{I} - \Delta_v)^{-1} \nabla_{L_2} E(v) \quad (13)$$

其中:

$$\begin{aligned} -\nabla_{L_2} E(\omega) &= \operatorname{div} \left(\frac{1}{(1 + |\nabla \omega|^2)^2} \cdot \nabla \omega \right) \\ &+ \frac{1}{\varepsilon^2} \omega (1 - \sqrt{\omega^2 + v^2}) (2\sqrt{\omega^2 + v^2} - 1) \\ &- \lambda(\omega - \omega_0) \end{aligned}$$

$$\begin{aligned} -\nabla_{L_2} E(v) &= \operatorname{div} \left(\frac{1}{(1 + |\nabla v|^2)^2} \cdot \nabla v \right) \\ &+ 2v(1 - \sqrt{\omega^2 + v^2}) (2\sqrt{\omega^2 + v^2} - 1) \\ &- \lambda(v - v_0) \end{aligned}$$

式(12)和式(13)初值条件分别为 $\omega(0) = \omega_0, v(0) = v_0$.

3.4 对彩色图像的处理

本文所有彩色图像都转化为灰度图像再检测其显著性. 彩色图像包含 RGB 三个分量, 由于红色分量对人眼刺激较强烈, 蓝色分量较低, 因此采用加权平均方法将其转化为灰度图像. 如果图像显著目标色彩比背景亮, 则:

$$I(i, j) = 0.69R(i, j) + 0.20G(i, j) + 0.11B(i, j)$$

反之:

$$I(i, j) = 255((0.69R(i, j) + 0.20G(i, j) + 0.11B(i, j)))$$

4 数值实现和实验结果

4.1 数值实现

记 h 和 Δt 是空间和时间步长, $(x_i, x_j) = (ih, jh)$ 是网格点, $u_{i,j}^n = \omega_{i,j}^n + iv_{i,j}^n$ 是函数 $u(n\Delta t; x_i, x_j)$ 状态描述, $n \geq 0, \omega^0 = \omega_0, v^0 = v_0$. 中心差分方案是:

$$\nabla^x u_{i,j} = \frac{u_{i+1,j} - u_{i-1,j}}{2h} \quad \nabla^y u_{i,j} = \frac{u_{i,j+1} - u_{i,j-1}}{2h}$$

通过式(12)、(13)循环迭代逼近式(11)解, 步骤如下:

①对 $n > 0$, 记 $G^n := -\nabla_{L_2} E(\omega)$, 则

$$\begin{aligned} G_{i,j}^n &= \nabla^x \left(\frac{\nabla^x \omega_{i,j}^n}{(1 + |\nabla \omega_{i,j}^n|^2)^2} \right) + \nabla^y \left(\frac{\nabla^y \omega_{i,j}^n}{(1 + |\nabla \omega_{i,j}^n|^2)^2} \right) \\ &+ \frac{1}{\varepsilon^2} \omega_{i,j}^n (1 - ((v_{i,j}^n)^2 + (\omega_{i,j}^n)^2)^{\frac{1}{2}}) \\ &\cdot (2((v_{i,j}^n)^2 + (\omega_{i,j}^n)^2)^{\frac{1}{2}} - 1) - \lambda(\omega_{i,j}^n - \omega_0^0) \end{aligned}$$

②记 $w = (\omega^{n+1} - \omega^n) / \Delta t$, 采用文献[23]方法, 在

$\frac{\partial \omega}{\partial n} \Big|_{\omega} = 0$ 条件下, 用半隐式方案解方程 $(\mathbf{I} - \Delta_\omega) w = G^n$. 具体说, 开始于 $w^0 = 0$, 迭代方程,

$$w_{i,j}^{l+1} - \left\{ \frac{w_{i+1,j}^l - 2w_{i,j}^l + w_{i-1,j}^l}{h^2} + \frac{w_{i,j+1}^l - 2w_{i,j}^l + w_{i,j-1}^l}{h^2} \right\}$$

$$= G_{i,j}^n, \quad l = 1, 2, \dots$$

直到 w 稳定结束该步骤;

③更新 $\omega^{n+1} = \omega^n + \Delta t \cdot w$;

④利用 v^n 和 ω^{n+1} 计算 $T^n := -\nabla_{L_2} E(v)$, 即

$$\begin{aligned} T_{i,j}^n &= \nabla^x \left(\frac{\nabla^x v_{i,j}^n}{(1 + |\nabla v_{i,j}^n|^2)^2} \right) + \nabla^y \left(\frac{\nabla^y v_{i,j}^n}{(1 + |\nabla v_{i,j}^n|^2)^2} \right) \\ &+ \frac{1}{\varepsilon^2} v_{i,j}^n (1 - ((\omega_{i,j}^{n+1})^2 + (v_{i,j}^n)^2)^{\frac{1}{2}}) \\ &\cdot (2((\omega_{i,j}^{n+1})^2 + (v_{i,j}^n)^2)^{\frac{1}{2}} - 1) - \lambda(v_{i,j}^n - v_{i,j}^0) \end{aligned}$$

⑤记 $v = (v^{n+1} - v^n) / \Delta t$, 在 $\frac{\partial v}{\partial n} \Big|_{\omega} = 0$ 条件下解方

程 $(\mathbf{I} - \Delta_v) v = T^n$. 取 $v^0 = 0$, 迭代方程,

$$\begin{aligned} v_{i,j}^{l+1} - \left\{ \frac{v_{i+1,j}^l - 2v_{i,j}^l + v_{i-1,j}^l}{h^2} + \frac{v_{i,j+1}^l - 2v_{i,j}^l + v_{i,j-1}^l}{h^2} \right\} \\ = T_{i,j}^n, \quad l = 1, 2, \dots \end{aligned}$$

直到 v 稳定结束该步骤;

⑥更新 $v^{n+1} = v^n + \Delta t \cdot v$;

⑦重复①~⑥, 直到 ω 和 v 稳定结束全部运算.

4.2 实验结果

本文对文献[6]数据库 1000 幅图像进行了实验. 模型参数选择如下: $\varepsilon = 0.5, \lambda = 0.1$, 时间步长 $\Delta t = 0.03$. 实验结果如下显示:

$$\bar{I} = \begin{cases} 255, & \omega \geq 1 \\ 255\omega, & 0 < \omega < 1 \\ 0, & \omega \leq 0 \end{cases}$$





图1 本文模型下图像显著性的检测过程

实验平台操作系统 win10, 程序 Matlab 2011a 编写.

图 1 展示了本文模型下图像显著性检测过程. 第 1 行为原始图像, 第 2 至 5 行分别是 1、6、8 和 11 次迭代结果. 实验显示: 绿叶、鹅卵石等背景慢慢变黑逐渐消失, 但花和球等视觉敏感物体随时间演化依然保留, 内部纹理、多层次信息依然清晰. 大脑记忆表明, 重要信息往往被长久保持, 不重要信息瞬间记忆后随时间逐渐消失, 因此我们认为在图像演化中, 随时间推移依然

保留的信息是图像显著特征, 如图 1 花和球等, 从而实现了图像显著性检测.

图 2 显示了不同模型实验结果比较, 第 1 行是原始图像, 第 2 至 8 行分别是文献 [4]、[5]、[6]、[7]、[14]、[8] 和 [9] 实验结果, 为了表示方便, 分别记为 SR、GB、FT、AS、RPC、RC 和 BP 模型, 最后 1 行是本文实验结果. 结果显示: SR、GB 模型所获得的显著图只有少量轮廓信息, FT 显著目标和背景都清晰; AS、RPC、




(从第1行到第9行, 分别是(a)原始图像, (b)SR[4]显著图, (c)GB[5]显著图, (d)FT[6]显著图, (e)AS[7]显著图, (f)RPC[14]显著图, (g) RC[8]显著图, (h) BP[9]显著图, (i)本文显著图)

图2 对细节丰富图像的实验结果比较

RC 和 BP 模型能较好压制图像背景,并获得显著区域,但 AS 显著目标模糊,RPC、RC 显著目标有块状效应,BP 显著目标内部信息丢失严重.本文模型不仅能压制背景信息,而且较好保留目标和目标内视觉特征,如:花儿的的多层结构信息、毛绒、花蕊、叶脉、水珠等都清晰可见.

图3展示了不同模型对不同场景图像的实验结

果.结果显示,SR、GB 只获得断断续续目标轮廓信息,FT 在获得目标同时背景还清晰,AS 显著目标较模糊,RPC、RC、BP 和本文模型都能标记显著物体,但 RPC 和 RC 结果图只有少量目标特征,BP 结果类似于分割,区域内特征信息更少,本文模型在压制背景的同时,获得了较为精细的目标特征,如动物毛发、人表情、标识牌字符等.



(从第1行到第9行,分别是(a)原始图像,(b)SR[4]显著图,(c)GB[5]显著图,(d)FT[6]显著图,(e)AS[7]显著图,(f)RPC[14]显著图,(g)RC[8]显著图,(h)BP[9]显著图,(i)本文显著图)

图3 对不同场景图像的实验结果比较

接下来用灰度剖面图比较 SR、GB、FT、AS、RPC、RC、BP 和本文模型实验效果.图4是图3第6列图像横截线(高度200像素处的水平线)之灰度剖面图.由原始图像知,该横截线从左至右90~210像素间属于显著

区域,其它属于背景区域.好的实验效果是在显著区域内灰度剖面图与原始图像一致,在背景值为零.结果显示所有模型中,只有 FT 和本文结果在显著区域内与原始图像灰度剖面图较接近,但 FT 模型在背景灰度值偏

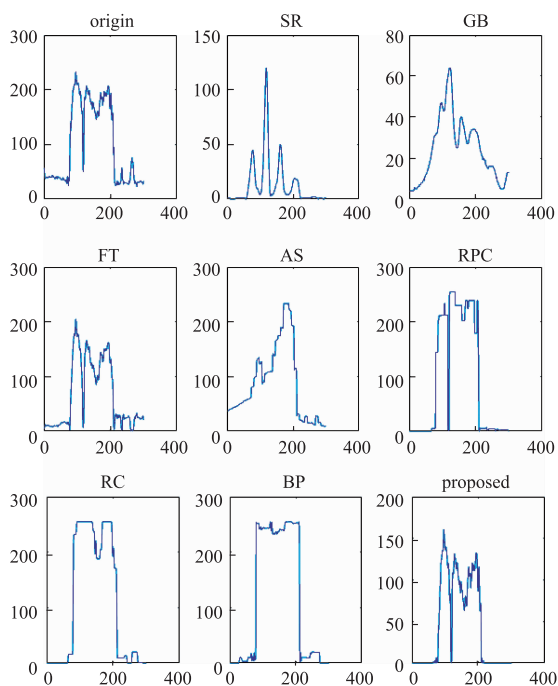


图4 对图3最右列图像的灰度剖面图比较

高,本文模型在背景值接近于零,说明本文模型在压制图像背景的同时获得了更加精细的显著特征.


最后用 *precision*、*recall* 和 *F* 度量^[6]评价模型实验效果.实验对象是文献[6]数据库 1000 幅图像,图 5 是八个模型对 1000 幅图像的 *precision*、*recall* 和 *F* 度量平均值.具体做法是:将数据库中真实显著区域图(二值图)记为 G ,不同模型获得的显著图记为 S ,用自适应阈值 $T^{[6]}$ 将 S 二值化为 s ,度量定义如下:

$$precision = \frac{\sum_x G_x s_x}{\sum_x s_x}, \quad recall = \frac{\sum_x G_x s_x}{\sum_x G_x}$$

$$F = \frac{(1 + \alpha) * precision * recall}{\alpha * precision + recall}$$

三个度量值在 0 和 1 之间,它们从不同角度反应 s 和 G 重复度,值越接近于 1, s 和 G 重复度越高,效果越好,反之效果越差.由图 5 知:本文结果高于 SR、GB、FT 和 AS 模型,低于 RPC、RC 和 BP 模型.由于 SR、GB、FT 和 AS 的显著图比较模糊,因此度量值偏低.本文模型和 RPC、RC 和 BP 模型都获得了与人工标记显著图比较接近的显著区域,因此有较高的度量值.下面分析本文模型度量值略低于后三个模型的原因:事实上 G 是人工标记二值图,1 标记显著区域,0 标记背景.由于 RPC、RC 和 BP 显著区域内特征信息丢失严重(如图 3(f)、(g)、(h)),其显著图二值化结果就会出现较纯净的显著和背景区域,因此 s 更拟合 G ;而本文模型在获得显著区域的同时还获得了较为精细的区域内特征(如图 3(i)),通过阈值获得的二值图必有 0 和 1 两个数来刻画显著区域内特征,这在一定程度上降低了度量值.我

们认为显著区域内的特征信息对人的视觉也是非常重要的,也即是不能完全通过 *precision*、*recall* 和 *F* 度量值来反映显著性检测的精确性.

图5 1000幅图像的*precision*、*recall*和*F*度量平均值

5 结束语

基于 Cahn-Hilliard 模型,提出了应用于图像显著性检测的相场变分模型.该方法以图像为先验信息,在复数域上定义能量泛函,其局部极值组成了可供高层视觉选择的图像非线性变化方案.实验显示了该模型的有效性.后续工作将研究分数阶变分模型应用于图像特征检测,并研究更合理的标准去度量显著性检测.

参考文献

- [1] Genma S, Ogawa T, Haseyama M. Image retrieval for identification of insects based on saliency map and distance metric learning [A]. 2016 IEEE 5th Global Conference on Consumer Electronics [C]. IEEE, 2016. 1 - 2.
- [2] T Gane, Ferryman J. Saliency-based detection for maritime object tracking [A]. 2016 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW) [C]. IEEE, 2016. 1257 - 1264.
- [3] Itti L, Koch C, Niebur E. A model of saliency-based visual attention for rapid scene analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(11): 1254 - 1259.
- [4] Hou X, Zhang L. Saliency detection, A spectral residual approach [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. IEEE, 2007. 1 - 8.
- [5] Harel J, Koch C, Perona P. Graph-based visual saliency [J]. Advances in Neural Information Processing Systems, 2007, 19: 545 - 552.
- [6] Achanta R, Hemami S, Estrada F, susstrunk S. Frequency-tuned salient region detection [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. IEEE,

2009. 1597 – 1604.
- [7] Fang Y, Lin W, Lee B, et al. Bottom-up saliency detection model based on human visual sensitivity and amplitude spectrum [J]. *IEEE Transactions on Multimedia*, 2012, 14 (1): 187 – 198.
- [8] Cheng M, Mitra N J, Huang X, et al. Global contrast based salient region detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37 (3): 569 – 582.
- [9] Sheth C, Babu R. V. Object saliency using a background prior [A]. *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* [C]. IEEE, 2016. 1931 – 1935.
- [10] Tsotsos J, Culhane S, Wai W, et al. Modeling visual attention via selective tuning [J]. *Artificial Intelligence*, 1995, 78: 507 – 545.
- [11] Deco G, Zihl J. A neurodynamical model of visual attention: feedback enhancement of spatial resolution in a hierarchical system [J]. *Journal of Computational Neuroscience*, 2001, 10(3): 231 – 253.
- [12] Ma Y, Zhang H. Contrast-based image attention analysis by using fuzzy growing [A]. *ACM International Conference on Multimedia*, 2003. 374 – 381.
- [13] Feng S, Xu D, Yang X. Attention-driven salient edge (s) and region (s) extraction with application to CBIR [J]. *Signal Processing*, 2010, 90(1): 1 – 15.
- [14] Lou J, Ren M, Wang H. Regional principal color based saliency detection [J]. *Plos One*, 2014, 9 (11): e112475, 1 – 13.
- [15] Li H, Chen J, Lu H, et al. CNN for saliency detection with low-level feature integration [J]. *Neurocomputing*, 2017, 226: 212 – 220.
- [16] Prasath V, Vorotnikov D, Pelapur R, et al. Multiscale Tikhonov-total variation image restoration using spatially varying edge coherence exponent [J]. *IEEE Transactions on Image Processing*, 2015, 24(12): 5220 – 5235.
- [17] Rafsanjani H K, Sedaaghi M H, Saryazdi S. An adaptive diffusion coefficient selection for image denoising [J]. *Digital Signal Processing*, 2017, 64: 71 – 82.
- [18] Perona P, Malik J. Scale space and edge detection using anisotropic diffusion [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1990, 12(7): 629 – 639.
- [19] Landau L D, Ginzburg V L. On the theory of superconductivity [J]. *Zhurnal Eksperimentalnoi i Teoreticheskoi Fiziki*, 1950, 20: 1064 – 1082.
- [20] Cahn J W, Hilliard J E. Free energy of a non-uniform system I. Interfacial free energy [J]. *The Journal of Chemical Physics*, 1958, 28(2): 258 – 267.
- [21] Grossauer H, Scherzer O. Using the complex Ginzburg-Landau equation for digital inpainting in 2D and 3D [A]. *International Conference on Scale-Space Theories in Computer Vision* [C]. Springer Berlin Heidelberg, 2003. 225 – 236.
- [22] Aubert G, Aujol J F, Feraud L B. Detecting codimension two objects in an image with Ginzburg-Landau models [J]. *International Journal of Computer Vision*, 2005, 65: 29 – 42.
- [23] Renka R J. Image segmentation with a Sobolev gradient method [J]. *Nonlinear Analysis: Theory, Methods and Applications A*, 2009, 71(12): 774 – 780.

作者简介



李 梦 女, 1973 年出生, 四川开江人, 理学博士, 现重庆工商大学副教授, 研究方向: 偏微分方程及其在图像处理中的应用.

E-mail: limeng7319@email.ctbu.edu.cn



刘 星 (通信作者) 男, 1956 年出生, 河南镇平人, 管理学博士, 现重庆大学经济与工商管理学院教授, 博士生导师, 院长, 研究方向: 优化与风险控制.

E-mail: liuxing@cqu.edu.cn



任泽民 男, 1985 年出生, 山东枣庄人, 理学博士, 现重庆科技学院副教授, 研究方向: 偏微分方程及其在图像处理中的应用.

E-mail: zeminren@cqu.edu.cn