

基于分数阶与 NCTGV 的图像放大新模型

谢 斌^{1,2}, 刘 壮¹, 丁成军¹

(1 江西理工大学 信息工程学院, 江西 赣州 341000; 2 深圳大学 信息工程学院, 广东 深圳 518060)

摘 要: 针对传统全变分在图像放大时容易产生“阶梯效应”与边缘模糊等问题, 在此基础上考虑到非凸二阶总广义变分在抑制“阶梯效应”以及分数阶在保护图像细节信息的特性, 提出了基于纹理分解的分数阶非凸二阶总广义变分图像放大模型. 新模型将低分辨率图像分解为卡通与纹理两个部分, 卡通部分为原始图像的平坦区域, 使用传统全变分易产生“阶梯效应”, 因此对卡通部分采用非凸二阶总广义变分模型处理. 针对图像细节信息较多的纹理部分, 采用分数阶变分模型处理, 可更好的完善图像细节信息. 对所提出的新模型, 采用原始对偶与 Chambolle 投影算法进行数值求解. 数值实验结果表明文中所提的新模型在峰值信噪比与均方误差均等指标有明显的提升.

关键词: 全变分; 图像放大; 非凸总广义变分; 分数阶; 纹理分解

中图分类号: TN929.5

文献标识码: A

文章编号: 1000-7180(2018)01-0050-06

A New Image Zooming Model Based on Fractional Order and NCTGV

XIE Bin^{1,2}, LIU Zhuang¹, DING Cheng-jun¹

(1 College of information engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China;

2 College of information engineering, Shenzhen University, Shenzhen 518060, China)

Abstract: Prone to the staircase effect and the blurring of the traditional variational image magnification, on the basis of considering the non convex order two total generalized variation in the suppression of the staircase effect and the fractional order in preserving the image details the characteristics of non convex total two order generalized variational model of fractional texture image magnification based on decomposition is proposed. The new model decomposes the low resolution image into two parts: cartoon and texture, because for a flat area, easy to produce the staircase effect, so the cartoon part uses the two order non convex total generalized variational model. In this paper, the fractional variational model is used to deal with the texture of the image with more details. In this paper, the primal dual and Chambolle projection algorithm are used to solve the new fractional non convex model. The results of numerical experiments show that the new model has a significant improvement in peak signal to noise ratio and mean square error.

Key words: total variation; image zooming; non convex order generalized variational; fractional order; texture decomposition

1 引言

人们将一幅低分辨率的图像通过一系列的处理之后变成一幅高分辨率图像的过程称之为图像放大, 图像放大作为数字图像处理的基础之一, 在农业、医疗、军事等领域都有着广泛地应用, 因此在图

像处理中如何根据低分辨率的图像获取高质量的高分辨率图像是一个重要的环节. 传统的, 插值技术是经典的图像放大技术之一, 也是目前众多图像处理软件中最长用的图像放大技术, 插值放大技术包括最邻近插值、双线性插值和样条插值等技术, 插值图像放大简单易实现, 也取得一定的效果, 但是这些插

收稿日期: 2017-04-20; **修回日期:** 2017-05-17

基金项目: 国家自然科学基金(61363076); 江西省自然科学基金(20142BAB207020)

值方法都是利用光滑函数来逼近原始图像,这导致了放大后的图像中含有较多的无用信息,此外传统的线性插值图像放大还存在这许多不足之处.近年来,偏微分方程凭借其求解简单,效果良好的特点而在数字图像处理中受到了越来越多的关注. Rudin 等^[1]人提出的 TV 模型在图像处理中获得了巨大的成功.因此 Maltouyres 等人^[2]结合插值图像放大与 TV 提出了基于变分的插值图像放大模型,新的模型选用 TV 来估计图像的正则性,并取得了较好的放大效果. Chambolle 等^[3]人基于 TV 模型提出了一种新的图像放大模型,并获得了不错的图像放大效果,但是因 TV 的分段平滑特性而不能有效的保护图像的细节信息并且在图像的平滑区域容易造成“阶梯效应”,所以基于 TV 模型而提出的 Chambolle 图像放大模型存在一定的缺陷.为此,文献[4]基于 Chambolle 模型并结合了二阶总广义变分^[5]在抑制“阶梯效应”上的良好效果,提出了二阶总广义变分图像放大模型,并给出了相应的数值求解算法.但是在图像的细节信息的保护上并不是很理想.针对在保护图像细节的这一问题的,刘亚男等人^[6]在 2016 年将分数阶微分运用到了图像放大中,使用分数阶来对图像的细节信息进行增强,新的分数阶图像放大模型很好的提升了图像的细节信息,但在抑制图像的平坦区域的“阶梯效应”效果有待进一步提高.

针对上述问题,本文结合最新的非凸二阶总广义变分^[7]与分数阶的图像处理中的优点,提出了一种新的图像放大模型.新的模型无论是在峰值信噪比还是在图像相似度上都有明显的提高.

2 相关模型分析

2.1 Chambolle 图像放大模型

Chambolle 等人基于 TV 模型,提出了相关的图像放大模型,模型具体如下

$$E(u) = \min_{u \in X, w \in P^\perp} \|u - (g + w)\| + \lambda \cdot \text{TV}(u) \quad (1)$$

式(1)中, u 表示放大后的图像, λ 表示正则化参数, g 表示一幅粗糙的原始放大图像,对于 $M \times N$ 大小的图像, X 表示空间 $C^{m \times n}$, P 是 X 的一个子空间,且当图像放大倍数为 2 时,Chambolle 等人提出的空间 P 表示为

$$P = \{g \in X \mid g_{2m, 2n} = g_{2m-1, 2n} = g_{2m, 2n-1} = g_{2m-1, 2n-1}, m \leq M/2, n \leq N/2\} \quad (2)$$

Chambolle 模型是基于 TV 模型提出的图像放大模型,并且 Chambolle 等人给出了相应的数值解法,也取得了不错的图像放大效果,但是模型的正则项是基于 TV 所提出的,因此在处理后的图像中存在明显的“阶梯效应”与边缘模糊的问题.

2.2 二阶总广义变分模型

文献[5]提出了能够衡量图像微分特性的总广义变分 (TGV, Total Generalized Variation) 函数.其中对于任意 $u \in L^1_{\text{loc}}(\Omega)$ 的 n 阶总广义变分定义如下:

$$\begin{aligned} \text{TGV}_a^n(u) = \\ \sup \left\{ \int_{\Omega} u \operatorname{div}^n p \, dx \mid p \in C_c^n(\Omega, \operatorname{Sym}^n(R^d)), \right. \\ \left. \|\operatorname{div}^k p\|_{\infty} \leq \alpha_k, k = 0, \dots, n-1 \right\} \end{aligned} \quad (3)$$

式(3)中, $\Omega \in R^d$ 是一个开区域, $n \geq 1$ 且 $(\alpha_0, \dots, \alpha_{n-1}) > 0$.

不难发现当 n 阶总广义变分的阶次 $n = 1$ 时,式(3)就是 TV 的对偶定义,可以说,总广义变分是 TV 对偶定义的推广.根据 Legendre-Fenchel 对偶^[8]定义,可得式(3)的原始形式

$$\begin{aligned} \text{TGV}_a^n(u) = \\ \inf_{u_l \in C^{n-l}(\bar{\Omega}, \operatorname{Sym}^l(R^d))} \sum_{l=1}^n \alpha_{k-1} \int_{\Omega} |\varepsilon(u_{l-1}) - u_l| \, dx \\ l=1, \dots, n-1, u_0 = u, u_k = 0 \end{aligned} \quad (4)$$

式(4)中, $\varepsilon(u_{l-1})$ 为对称梯度算子

$$\varepsilon(u_{l-1}) = \frac{\nabla u_{l-1} + (\nabla u_{l-1})^T}{2} \quad (5)$$

根据 n 阶总广义变分的定义可知,当 $n = 2$ 时,可知 $\operatorname{Sym}^2(R^d) = S^{d \times d}$,其中 $S^{d \times d}$ 是对称矩阵空间.根据式(3)可得二阶总广义变分的定义为:

$$\begin{aligned} \text{TGV}_a^2(u) = \\ \sup \left\{ \int_{\Omega} u \operatorname{div}^2 p \, dx \mid p \in C_c^2(\Omega, \operatorname{Sym}^2(R^{d \times d})), \right. \\ \left. \|p\|_{\infty} \leq \alpha_0, \|\operatorname{div} p\|_{\infty} \leq \alpha_1 \right\} \end{aligned} \quad (6)$$

同理根据 Legendre-Fenchel 对偶定义可以得到二阶总广义变分的原始形式

$$\begin{aligned} \text{TGV}_a^2(u) = \min_{\vartheta \in \operatorname{BD}(\Omega)} \alpha_1 \int_{\Omega} (|\nabla u| - \vartheta) \, dx + \\ \alpha_0 \int_{\Omega} |\varepsilon(\vartheta)| \, dx \end{aligned} \quad (7)$$

式(7)中, $\operatorname{BD}(\Omega)$ 表示有界限的向量场空间,对于任意的 ω 都有 $\omega \in \operatorname{BD}(\Omega)$,且对称梯度算子 $\varepsilon(\vartheta)$ 是一个矩阵值的 Radon 度量^[9].

二阶总广义变分虽然在抑制“阶梯效应”有不错的效果,但是在边缘保护上还不是很好.

3 新模型的提出

对于上述式(7)的二阶总广义变分原始形式, Peter Ochs 等^[7]人提出将其中的一阶导数和二阶导数项都施加非凸约束得到

$$\begin{aligned} \text{NCTGV}_\alpha^2(u) = & \min_{\vartheta, u} \int_{\Omega} (|\nabla u - \vartheta| + \eta)^p dx \\ & + \alpha_0 \int_{\Omega} (|\varepsilon(\vartheta)| + \eta)^p dx \end{aligned} \quad (8)$$

式(8)中, p 为参数且 $0 < p < 1, \eta$ 为极小的正数. 非凸二阶总广义变分是在原二阶总广义变分上推导出来的, 因此继承了二阶总广义变分在图像处理中能很好的抑制“阶梯效应”的优点, 同时也结合了非凸正则函数能增强图像边缘的优点, 从而获得更好的图像处理效果.

结合 Chambolle 图像放大模型, 可以得到新的非凸总广义变分图像放大模型

$$E(u) = \min_{u \in X, w \in Z^\perp} \|u - (g + w)\| + \text{NCTGV}_\alpha^2(u) \quad (9)$$

式(9)中, λ 为正则参数.

与原始的 TGV 图像放大模型相比, 新模型中非凸 TGV 正则项在图像的平坦区域继承了 TGV 抑制“阶梯效应”的优点, 还引入了非凸在保边上的优势.

近年来, 分数阶已经成功的从数学理论运用到了图像处理领域^[10], 分数阶微分是全局算子, 其所具有的“弱导数”性质可以结合更多的局部信息, 能够更好的刻画图像的纹理信息. 文中选择图像处理领域应用较多的 Grünwald - letnikov(G-L)^[11]分数阶微分.

$$D_x^\alpha f(x) = \lim_{h \rightarrow 0} \frac{1}{h^\alpha} \sum_{j=0}^{\lfloor (x-x_0)/h \rfloor} (-1)^j \binom{\alpha}{j} f(x-jh) \quad (10)$$

式(10)中, $\binom{n}{j} = \frac{\Gamma(n+1)}{\Gamma(j+1)\Gamma(n-j+1)}$, 其中

$\Gamma(x) = \int_0^\infty e^{-t} t^{x-1} dt$ 表示 Gamma 函数. 从 G-L 分数阶微分的定义中可以看出, 相比于整数阶微分, 分数阶微分依据当前与前面无穷多的点来计算得到的, 因此分数阶微分具有记忆性.

首先从频域来分析 G-L 分数阶微分在几个不同阶次下的频幅特性曲线, 图 1 中所示为分数阶微分的不同阶次的频幅特性曲线. 从图 1 中可以明显看到, 随着分数阶微分阶次的增大, 信号中的高频信息能够得到明显的加强, 信号中的低频信息得到抑

制. 众所周知在图像的平坦区域对应着图像的中低频信息, 而图像的细节则对应着图像的高频信息. 从图 1 中可以发现, 在处理图像的高频信息的时候, 分数阶微分有着明显的优势, 在处理图像的中低频信息的时候一阶微分要优于分数阶微分.




图 1 不同阶次的频幅特性曲线

综上所述, 文中根据分数阶微分与非凸二阶总广义变分的优点, 文中提出了基于纹理分解的一种新的图像放大模型. 新模型先将图像分解为卡通与纹理部分. 并对两个部分做分别的不同处理方式.

对于图像分解的预处理, 文中采用 AABC 分解模型^[12]将图像 u 分解为卡通 c 与纹理 v 两个部分, 对于卡通部分的 c , 文中采用非凸二阶总广义变分模型进行放大处理. 模型为

$$E(c) = \min_{c \in X, w \in Z^\perp} \lambda \cdot \|c - (g + w)\| + \text{NCTGV}_\alpha^2(c) \quad (11)$$

式(11)中, c 代表原始图像的卡通部分.

对于图像的纹理部分 v , 文中采用分数阶变分模型进行处理, 模型为

$$E(v) = \min_{v \in X, w \in P^\perp} \|v - (g_1 + w)\| + \lambda \cdot \|\nabla^\alpha v\|_1 \quad (12)$$

式(12)中, g_1 是对低分辨率纹理部分采用双线性插值放大得到的粗糙图像, v 代表原始图像的纹理部分. 且

$$\begin{cases} \|\nabla^\alpha u\|_1 = \sum_{\substack{1 \leq i \leq M \\ 1 \leq j \leq N}} |(\nabla^\alpha u)_{i,j}| \\ |(\nabla^\alpha u)_{i,j}| = \sqrt{((\Delta_x^\alpha)_{i,j})^2 + ((\Delta_y^\alpha)_{i,j})^2} \end{cases} \quad (13)$$

式(13)中, α 代表分数阶微分的阶次, $1 < \alpha < 2$, 且

$$\begin{cases} (\Delta_x^\alpha u)_{i,j} = (-1)^k \sum_{k=0}^{K-1} C_k^\alpha u_{i-k,j} \\ (\Delta_y^\alpha u)_{i,j} = (-1)^k \sum_{k=0}^{K-1} C_k^\alpha u_{i,j-k} \end{cases} \quad (14)$$

式(14)中, $K = \min(m, n)$, m, n 为图像的行列数, C_k^α 与式(10)中 $\binom{\alpha}{j}$ 相等.

图像的卡通部分代表着图像的中低频信息,对图像的卡通部分采用一阶微分的非凸二阶总广义变分模型进行放大,因此可以在图像的平坦区域能有效的抑制“阶梯效应”与边缘轮廓的保护. 图像的纹理部分代表着图像的高频信息,因此对图像的纹理部分采用分数阶微分模型进行处理,能使图像的纹理得到更好加强.

4 数值求解

文中采用文献[13]的 AABC 图像分解模型对原始待放大的图像进行卡通纹理分解. 得到待处理的卡通纹理两个部分,对于卡通部分,文中采用模型(11)进行放大. 而对于纹理部分文中则采用模型(12)进行放大.

对于模型(11)与(12)的数值求解,文中采用原始对偶交替迭代算法进行求解. 首先对卡通模型(11)的数值求解,

根据文献[7],文中先将非凸模型(11)中的非凸正则项转换成如下的等价加权凸优化问题:

$$\begin{aligned} \text{NCTGV}_\alpha^2(c) = \min_{\vartheta, c} & \alpha_1 \cdot m \int_{\Omega} |(\nabla c - \vartheta)| dx \\ & + \alpha_0 \cdot \tilde{m} \int_{\Omega} |\varepsilon(\vartheta)| dx \end{aligned} \quad (15)$$

式(15)中

$$m = \frac{p}{(|\nabla c| + \varepsilon)^{1-p}} \quad \tilde{m} = \frac{p}{(|\varepsilon(\vartheta)| + \varepsilon)^{1-p}} \quad (16)$$

式(16)中, ε 为不为 0 的极小正数.

经过变换文中非凸模型(11)变成了等价的如下的凸优化模型:

$$\begin{aligned} \min_{u, v} E(c) = \min_{c \in X, w \in Z^\perp} & \lambda \cdot \|c - (g + w)\| \\ & + \alpha_1 \cdot m \int_{\Omega} |(\nabla c - \vartheta)| dx + \alpha_0 \cdot \tilde{m} \int_{\Omega} |\varepsilon(\vartheta)| dx \end{aligned} \quad (17)$$

对于式(17),文中采用原始对偶与交替迭代进行求解,先将模型(17)转换为如下两个模型

$$(c^n, \vartheta^n) = \min_{c \in X, w \in Z^\perp} \lambda \cdot \|c - (g + w^{n-1})\|$$

$$+ \alpha_1 \cdot m \int_{\Omega} |(\nabla c - \vartheta)| dx + \alpha_0 \cdot \tilde{m} \int_{\Omega} |\varepsilon(\vartheta)| dx \quad (18)$$

$$w^n = \min_{w \in Z^\perp} \|c^n - (g + w)\| \quad (19)$$

对于式(19)的求解,文中采用 Chambolle 投影算法进行求解,根据文献[3]很容易可以得到

$$w^{n+1} = \text{proj}_{P^\perp}(c^n - g) \quad (20)$$

式中集合 P 定义见 1.1 节定义. 根据 Chambolle 投影算法可以得到

$$\mu \text{div}(s^l) \rightarrow \text{proj}_{P^\perp}(c^n - g), l \rightarrow \infty \quad (21)$$

式(21)中 μ 为参数, s 满足 $s^0 = 0$, 且

$$s_{ij}^{l+1} = \frac{s_{ij}^l + \delta(\nabla(\text{div}(s^l) - (c - g^{l+1})/\mu))_{ij}}{1 + \delta|(\nabla(\text{div}(s^l) - (c - g^{l+1})/\mu))_{ij}|} \quad (22)$$

式(22)中参数 $\delta \leq 0.125$.

对于式(18)采用原始对偶求解,根据 Legendre-Fenchel 对偶原理,模型(18)的对偶模型为

$$\begin{aligned} \min_{c, \vartheta} \max_{P, Q} & \lambda \cdot \|c - (g + w^{n-1})\| + \langle \nabla c - \vartheta, y \rangle \\ & + \langle \varepsilon(\vartheta), q \rangle \end{aligned} \quad (23)$$

式(23)中变量 y, q 分别为

$$\begin{aligned} Y &= \{y = (y_1, y_2) \mid \|y\|_\infty \leq \alpha_1 \cdot m\} \\ Q &= \left\{q = \begin{bmatrix} q_{11}, q_{12} \\ q_{21}, q_{22} \end{bmatrix} \mid \|q\|_\infty \leq \alpha_0 \cdot \tilde{m}\right\} \end{aligned} \quad (24)$$

根据文献[8]一阶原始对偶算法,式(18)模型的数值解法具体如下

算法 1:

1. 初始化: $c^0 = c^-0 = g, \vartheta^0 = \bar{\vartheta}^0 = 0, w^0 = 0, \tau > 0, n = 0, y^0 = 0, q^0 = 0, \lambda > 0, \sigma > 0$.

2. 迭代:

$$\begin{aligned} y^{n+1} &= \text{proj}_Y(y^n + \sigma(\nabla c^n - \bar{\vartheta}^n)) \\ q^{n+1} &= \text{proj}_Q(q^n + \sigma(\varepsilon(\bar{\vartheta}^n))) \\ c^{n+1} &= \frac{c^n + \tau \text{div}(y^{n+1}) + \tau \lambda (g + w^n)}{1 + \tau \lambda} \\ \vartheta^{n+1} &= \vartheta^n + \tau(y^{n+1} + \text{div}^*(q^{n+1})) \\ \bar{\vartheta}^{n+1} &= 2\vartheta^{n+1} - \vartheta^n \\ \bar{c}^{n+1} &= 2c^{n+1} - c^n \\ n &= n + 1 \end{aligned}$$

其中每循环一次, w^n 都要根据式(20)来求得.

3. 当 $\|c^{n+1} - c^n\|_2 / \|c^n\|_2 \leq 1e^{-5}$ 时, 停止迭代.

在算法 1 当中, 算子 $\text{proj}_Y(\tilde{y}) = \tilde{y} / \max(1, \frac{|\tilde{y}|}{\alpha_1 \cdot m})$, 算子

$\text{proj}_Q(\tilde{q}) = \tilde{q} / \max(1, \frac{|\tilde{q}|}{\alpha_0 \cdot \tilde{m}})$, 且 div^* 是 ∇ 的负共轭.

文中对于纹理部分的模型(12) 的数值求解同样采用原始对偶与交替迭代方法来求解,参考模型(11) 的数值解法,可以很容易的到模型(12) 的数值求解算法. 这里给出模型(12) 的具体迭代

算法 2:

- 1. 初始化: $v^0 = v^{-0} = g_1, w^0 = 0, \lambda > 0, \sigma > 0, \tau > 0, y^0 = 0, n = 0.$
- 2. 迭代:

$$\begin{aligned} y^{n+1} &= \text{proj}_Y(y^n + \sigma \nabla v^n) \\ v^{n+1} &= \frac{v^n + \tau \text{div}(y^{n+1}) + \tau \lambda (g_1 + w^n)}{1 + \tau \lambda} \\ \bar{v}^{n+1} &= 2v^{n+1} - v^n \\ n &= n + 1 \end{aligned}$$

其中每循环一次, w^n 都要根据式(20) 来求得.

- 3. 当 $\|v^{n+1} - v^n\|_2 / \|v^n\|_2 \leq 1e^{-5}$ 时, 停止迭代.
- 至此模型(11) 与(12) 的数值求解已经完成, 结合算法 1 与算法 2 文中给出新模型的完整数值求解算法, 具体算法如下

算法 3:

- 1. 初始化:
 $c^0 = c^{-0} = g, \mathcal{J}^0 = \mathcal{J}^{-0} = 0, w^0 = 0, \tau > 0, n = 0, y^0 = 0, q^0 = 0, \lambda > 0, \sigma > 0, v^0 = \bar{v}^0 = g_1$
 - 2. 应用算法 1 求解模型(11).
 - 3. 应用算法 2 求解模型(12).
- $u = v^n + c^n.$

5 数值实验

为了验证文中所提出的新模型及数值算法的有效性, 对相关模型与新模型进行相关测试, 所有程序均在 MATLAB R2012b 上编程实现, CPU 为 i5-3210M 2.5 GHz. 如图 2 所示, 文中选取 Lena、Plane 与 Lake 作为测试图像, 图像的大小均为 512×512 .




图 2 测试图像

文中用峰值信噪比(PSNR)与图像结构相似度(SSIM)^[13]作为客观评价指标, 其定义如下

$$\begin{aligned} \text{PSNR} &= 10 \lg \left(\frac{n^2}{\|u - u_0\|_2^2} \right) \\ \text{SSIM} &= \frac{(2\sigma_{u_0} + c_1)(2\mu_u \mu_{u_0} + c_2)}{(\sigma_u^2 + \sigma_{u_0}^2 + c_1)(\mu_u^2 + \mu_{u_0}^2 + c_2)} \end{aligned}$$

上述评价指标中, u, u_0 分别代表原始图像和处理后的图像, $\sigma_u, \sigma_{u_0}, \mu_u, \mu_{u_0}$ 分别为 u, u_0 的标准差和均值, σ_{u_0} 为 u, u_0 的协方差. 参考文献[13], 文中将图像结构相似度中的维持稳定的系数 c_1, c_2 设定为 $1e^{-6}$ 与 $9e^{-6}$. 实验中的 Chambolle 与 TGV 模型的数值实验结果均是其最优的结果. 对于新模型的数值实验的参数设定为两个部分, 其中卡通部分的参数设置为: $\beta = 200, \tau = 0.03, \sigma = 3, p = 0.7, \alpha_1 = 0.01, \alpha_0 = 0.1$, 纹理部分的参数设置为: $\beta = 8, \tau = 0.03, \sigma = 3, \alpha = 1.6$. 先对原图进行缩小一定倍数的采样来获取低分辨率图像, 然后再对低分辨率图像进行放大.

表 1 给出了三种不同模型对 6 幅低分辨率图像进行放大的峰值信噪比, 从表 1 中可以看出文中新模型的峰值信噪比都明显要优于 Chambolle 图像放大与二阶总广义变分图像放大模型. 同样的表 2 给出了三种不同放大模型实验结果的结构相似度数, 从表 2 中可知新模型的结构相似度数也明显高于传统的 TGV 与 Chambolle 两种放大模型.

表 1 三种不同放大模型的 PSNR 比较

低分辨图	放大倍数	Chambolle	TGV	新模型
Lena256	2	30.942 9	31.622 1	33.185 2
Lena128	4	25.917 9	26.245 8	27.2514
Plane256	2	26.741 8	27.616 0	28.716 6
Plane128	4	22.345 2	22.606 7	24.225 0
Lake256	2	26.062 0	27.007 1	28.175 1
Lake128	4	20.048 3	21.155 8	23.134 0

表 2 三种不同放大模型的 SSIM 比较

低分辨图	放大倍数	Chambolle	TGV	新模型
Lena256	2	0.865 5	0.865 1	0.911 8
Lena128	4	0.623 1	0.675 9	0.745 7
Plane256	2	0.807 0	0.807 9	0.828 1
Plane128	4	0.550 1	0.599 5	0.655 6
Lake256	2	0.858 1	0.866 7	0.881 5
Lake128	4	0.576 4	0.643 9	0.716 0

从三种模型对 lena 放大四倍的结果, 可以清楚的看到, 在 Chambolle 放大模型中, 帽子顶端出现了明显的“阶梯效应”, 虽然 TGV 图像放大模型较有效的抑制了“阶梯效应”, 但是帽子上在细节纹理信息比较模糊. 实验结果表明了新的放大模型不仅能很好的抑制“阶梯效应”, 并且能很有效的增强图像

的细节信息.

6 结束语

提出了一种基于图像纹理分解的图像放大新模型. 并对图像分解成的卡通与纹理两个部分分别采用不同的放大模型, 对卡通部分采用非凸二阶总广义变分模型, 可以有效的在图像的平坦区域抑制“阶梯效应”. 对纹理部分采用分数阶变分, 结合分数阶的特性, 从而能有效的增强图像的细节信息. 实验结果表明, 新的模型无论在峰值信噪比还是图像相似程度上都有明显的提高.

参考文献:

- [1] Rudin LI, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms[J]. Physica D: Nonlinear Phenomena, 1992, 60(1): 259-268.
- [2] Malgouyres F. Total variation based oversampling of noisy images [C] // Scale-Space and Morphology in Computer Vision, Lecture Notes in Computer Science, Vancouver, Canada, 2006(2106): 111-122.
- [3] Chambolle A. An algorithm for total variation minimization and applications[J]. Journal of Mathematical Imaging and Vision, 2004, 20(1/2): 89-97.
- [4] 吴玉莲, 冯象初, 姜东焕. 二阶总广义变分图像放大[J]. 光子学报, 2013, 41(6): 732-736.
- [5] Bredies K, Kunisch K, Pock T. Total generalized variation[J]. SIAM Journal on Imaging Sciences, 2010, 3(3): 492-526.
- [6] 刘亚男, 杨晓梅, 陈超楠. 基于全变分正则化的超分辨率图像重建[J]. 计算机科学, 2016, 43(5): 274-278.
- [7] Peter Ochs, Alexey Dosovitskiy, Thomas Brox, et al.

An iterated l1 algorithm for non-smooth non-convex optimization in computer vision[J]. Computer Vision & Pattern Recognition, CVPR 2013. 2013, 86 (11) : 1759-1766.

- [8] Chambolle A, Pock T. A first-order primal-dual algorithm for convex problems with applications to imaging [J]. Journal of Mathematical Imaging and Vision, 2011, 40(1) : 120-145.
- [9] Bredies K, Valkonen T. Inverse problems with second-order total generalized variation constraints[C] // Proceedings of Samp TA 2011-9th international conference on sampling theory and applications. Singapore, 2011.
- [10] Bai J, Feng X C. Fractional—order anisotropic diffusion for image denoising[J]. IEEE Transactions on Image Processing, 2007, 16(10) : 2492-2502.
- [11] Odlubny I. Fractional differential equations[M]. New York: Academic Press, 1999.
- [12] Aujol J, Aubert G, Blanc-Feraud L, et al. Image decomposition into a bounded variation component and an oscillating component [J]. Math Imaging and Vision, 2005, 22(1): 71-88.
- [13] Wang Z, Bovik A, Sheikh H. et al. Image quality visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 1-14.

作者简介:

谢斌 男, (1977-), 博士研究生, 副教授. 研究方向为图像处理与现代通信技术.

刘壮(通讯作者) 男, (1992-), 硕士研究生. 研究方向为图像处理. E-mail: 18115163704@163.com.

丁成军 男, (1992-), 硕士研究生. 研究方向为图像处理.

(上接第 49 页)

- [2] He Z Y, Xu X F, Deng S C. Discovering cluster-based local outliers[J]. Pattern Recognition Lett, 2003, 24(9/10): 1641-1650.
- [3] Wei X S, Wu J, Zhou Z H. Scalable multi-instance learning[C] // 14th IEEE International Conference on Data Mining (ICDM14). Piscataway, NJ, USA: IEEE, 2014: 1037-1042.
- [4] Wang Z G, Zhao Z S, Weng S F, et al. Incremental multiple instance outlier detection[J]. Neural Computing & Applications, 2015, 26(4): 957-968.
- [5] Zhang W J, Zhou Z H. Multi-instance learning with distribution change [C] // 28th AAAI Conference on Artificial Intelligence (AAAI14). San Francisco, CA, USA: AAAI, 2014: 2184-2190.

- [6] Wang J, Zucker J D. Solving the multiple-instance problem: a lazy learning approach[C] // 17th International Conference on Machine Learning. San Francisco, CA, USA: Morgan Kaufmann, 2000: 1119-1125.
- [7] Ruffo G. Learning single and multiple instance decision trees for computer security applications[D]. Torino: University of Turin, 2000.
- [8] Zhou Z H, Zhang M L. Neural networks for multi-instance learning[R]. Nanjing: Nanjing University, 2002.

作者简介:

钱景辉 男, (1978-), 硕士, 讲师. 研究方向为计算机控制自动化.

卢屹伟(通讯作者) 男, (1992-), 硕士研究生. 研究方向为数据挖掘、人工智能. E-mail: 362781537@qq.com.