

引用格式: 安凤平. 基于二维局域均值分解的自适应图像处理算法[J]. 微电子学与计算机, 2020, 37(2): 57-62. [AN F P. Adaptive image processing algorithm based on bi-dimensional local mean decomposition[J]. Microelectronics & Computer, 2020, 37(2): 57-62.]

## 基于二维局域均值分解的自适应图像处理算法

安凤平<sup>1,2</sup>

(1 淮阴师范学院 物理与电子电气工程学院, 江苏 淮安 223300; 2 北京理工大学 信息与电子学院, 北京 100081)

**摘 要:** 本文借鉴具有自适应特性的一维局域均值分解算法(Local Mean Decomposition, BLMD), 提出了二维局域均值分解算法(Bidimensional Local Mean Decomposition, BLMD). 二维局域均值分解算法可以将源图像分解成多个二维生产函数分量(Bidimensional Product Function, BPF). 思路为: 先通过可变邻域窗法来获得分解过程中的极值点, 而后利用分形理论对图像进行插值操作, 并得到相应的均值曲面的等信息, 再对筛分过程中相邻曲面之间在零值平面投影上不重合极值点数目进行统计和分析, 给出符合图像本身特性的停止条件, 保证分解得到的 BPF 分量能够真实反映图像的某类特征信息. 最后, 在此基础上形成本文提出的二维局域均值分解算法. 通过实证分析表明, 本方法可以自适应对图像进行分解.

**关键词:** 二维经验模式分解; 局域均值分解; 二维局域均值分解; 分形插值; 停止条件

**中图分类号:** TP319.4

**文献标识码:** A

**文章编号:** 1000-7180(2020)02-0057-06

## Adaptive image processing algorithm based on bi-dimensional local mean decomposition

AN Feng-ping<sup>1,2</sup>

(1 School of Physics and Electronic Electrical Engineering, Huaiyin Normal University, Huaian 223300, China;

2 School of Information and Electronics, Beijing Institute of Technology, Beijing 100081, China)

**Abstract:** In this paper, a Bi-dimensional Local Mean Decomposition (BLMD) algorithm with adaptive characteristics is proposed. The two-dimensional local mean decomposition algorithm can decompose the source image into multiple bi-dimensional production function components (BPF). The basic idea is to first obtain the extreme points in the decomposition process by the variable neighborhood window method, and then use the fractal theory to interpolate the image. And get the corresponding information of the mean surface. Then, the number of non-coincident extreme points on the zero-value plane projection between adjacent surfaces in the sieving process is statistically analyzed and analyzed, and the stopping condition corresponding to the characteristics of the image is given. It ensures that the BPF component obtained by the decomposition can truly reflect certain types of feature information of the image. Finally, it forms the two-dimensional local mean decomposition algorithm proposed in this paper. The empirical analysis shows that the method can adaptively decompose the image.

**Key words:** Bi-dimensional empirical mode decomposition; local Mean decomposition; Bi-dimensional local mean decomposition; fractal interpolation; stop condition

1 引言

数字图像处理技术主要应用包括:特征提取、图像分割、图像识别和图像重建等. 对于以上方面的应用,目前主要有<sup>[1,2]</sup>:传统的傅里叶理论上发展而来的相关理论,基于小波的处理方法等.

2005 年 Smith 在 EMD(Empirical made Decomposition)算法的基础上提出了局域均值分解(Local Mean Decomposition,LMD)算法<sup>[3]</sup>. 它将信号分解成一组生产函数(Product Function,PF),每一个 PF 均是一个包络信号和一个调频信号的乘积. LMD 算法是一种全新的分析非线性、非平稳信号的时频分析方法. 同时,根据其分解原理,它对信号具有更好的自适应性和局部性. 鉴于 LMD 算法的优势,本文在 LMD 算法的基础上,提出一种全新的图像分解算法-二维局域均值分解算法(Bidimensional Local Mean Decomposition, BLMD),针对图像信号相对于一维信号的差异,BLMD 在图像插值、分解停止条件和端部效应抑制上对算法进行了针对性的优化. 通过实例分析,证实本文提出的 BLMD 较传统小波及 BEMD 方法更具有优势,图像分解得到的二维生产函数分量(Bidimensional Product Function, BPF)更能反映图像的特征信息,保证图像的多尺度分解,实现图像特征信息的多尺度提取.

2 二维局域均值分解算法

BLMD 是 LMD 算法由一维信号处理推广到二维信号处理,BLMD 算法本质是通过提取二维图像信号的局部极值点去筛选获得具有一定物理意义的多个二维生产函数(BPF)和一个趋势图像的过程,此筛选过程完全根据图像信号本身特征来获得,该分解算法具有高度的自适应多尺度特性.

2.1 极值谱的提取

提取二维极值指的是从给定二维信号找到所有极值点. 所有极大值点构成的阵列,称为“极大值谱”;所有极小值点构成的阵列,称为“极小值谱”. 在 LMD 算法中较容易提取得到极值点,但是对于 BLMD 算法来说,它的极值谱提取就较为复杂,这是因为较难给出二维空间中数据极值点的定义.

鉴于此,本文利用已经得到较好应用的邻域窗法提取图像信号的极值谱. 像素中若某个像素点比一定邻域范围的其它点都大或小,它称之为极大或极小值. 假定  $m \times n$  像素二维图像  $f(x, y)$  可以用下式

矩阵表示:

$$f(x,y)=\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \cdots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{bmatrix} \tag{1}$$

式中, $a_{mn}$  表示矩阵中第  $m$  行、第  $n$  列数据. 先假定邻域窗口尺寸为  $w_n \times w_n$ ,则极值点可以通过下式进行描述:

$$a_{mn} \overset{\Delta}{=} \begin{cases} a_{mn} \text{ 为极大值,当 } a_{mn} > a_{kl} \text{ 时} \\ a_{mn} \text{ 为极小值,当 } a_{mn} < a_{kl} \text{ 时} \end{cases} \tag{2}$$

式中:

$$\begin{aligned} k &= (m - (w_n - 1)/2):(m + (w_n + 1)/2) \\ l &= (n - (w_n - 1)/2):(n + (w_n + 1)/2) \end{aligned} \tag{3}$$

对于图像信号来说,一般使用  $3 \times 3$  窗口来寻找极值是一个比较理想的方法. 如图 1 所示的  $8 \times 8$  矩阵,利用邻域窗法来说明其寻找步骤. 使用  $3 \times 3$  窗口来寻找极值点,图中的黑色粗线所围成的窗口为滑动窗口,可对行列分别进行逐一扫描,得到的极大值谱和极小值谱分别如图 2 及图 3 所示.

|   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|
| 8 | 8 | 4 | 1 | 5 | 2 | 6 | 3 |
| 6 | 3 | 2 | 3 | 7 | 3 | 9 | 3 |
| 7 | 8 | 3 | 2 | 1 | 4 | 3 | 7 |
| 4 | 1 | 2 | 4 | 3 | 5 | 7 | 8 |
| 6 | 4 | 2 | 1 | 2 | 5 | 3 | 4 |
| 1 | 3 | 7 | 9 | 9 | 8 | 7 | 8 |
| 9 | 2 | 6 | 7 | 6 | 8 | 7 | 7 |
| 8 | 2 | 1 | 9 | 7 | 9 | 1 | 1 |

图 1  $8 \times 8$  矩阵

|   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 7 | 0 | 9 | 0 |
| 0 | 8 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 1 | 0 | 4 | 0 | 0 | 0 | 8 |
| 6 | 0 | 0 | 1 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 8 | 0 |
| 9 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 1 | 9 | 0 | 9 | 0 | 0 |

|   |   |   |   |   |   |   |   |
|---|---|---|---|---|---|---|---|
| 0 | 0 | 0 | 1 | 0 | 2 | 0 | 0 |
| 0 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 1 | 0 | 0 | 0 |
| 0 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 1 | 0 | 0 | 3 | 0 |
| 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 0 | 0 | 0 | 0 | 6 | 0 | 0 | 0 |
| 0 | 0 | 1 | 1 | 0 | 0 | 0 | 0 |

图 2 图 1 的极大值谱      图 3 图 1 的极小值谱

2.2 基于分形理论的二维局域均值分解插值算法

2.2.1 一维布朗运动

一维布朗运动可以通过如下随机过程进行描述:对于任一  $t_1$  和  $t_2$  均有<sup>[4,5]</sup>

$$L_H(t_1) - L_H(t_2) \quad \text{符合高斯分布} \tag{4}$$

$$E(|L_H(t_2) - L_H(t_1)|^2) \propto |t_2 - t_1| \tag{5}$$

式中, $E$  代表数学期望; $L_H(t)$  为一维分形布朗函数; $t$  代表  $R^n$  空间的某个点.

对于任一的  $t_0$  和  $\gamma > 0, L(t_0 + t) - L(t_0)$  和  $\frac{1}{\sqrt{\gamma}}(L(t_0 + \gamma t) - L(t_0))$  具有相同的联合分布函数.

也就是说,  $L$  的增量在统计规律上具有自相似特性.

### 2.2.2 分形布朗函数

若把公式(5) 调整为下式

$$\text{Var}(L(t_2) - L(t_1)) \propto |\Delta t|^{2H} \quad (6)$$

式中,  $\text{Var}$  为方差;  $L(t)$  为一维分形布朗函数.  $H$  从原来的  $H = 1/2$  变为  $0 < H < 1$ , 它表示  $L(t)$  的不规则程度.

分形布朗运动是连续函数, 设  $t \in R^n$ ,  $L(t)$  是关于  $t$  的实值随机函数, 如果存在常数  $H(0 < H < 1)$ , 使得函数

$$\Pr\left\{\frac{L_H(t + \Delta t) - L_H(t)}{\|\Delta t\|^H} < x\right\} = F(x) \quad (7)$$

如果  $F(x)$  与  $\Delta t$ 、 $t$  无关, 则  $L(t)$  为分形布朗运动.  $t$  代表  $R^n$  空间的某个点;  $\Delta t$  代表该点的偏移量;  $\|\Delta t\|$  表示欧式距离;  $F(x)$  表示高斯随机分布函数.  $L_H(t)$  定义的分形维数如下表示

$$D = E + 1 - H \quad (8)$$

式(8) 中,  $D$  代表拓扑维数.

$L_H(t)$  具有如下性质<sup>[4,5]</sup>:

$$\begin{aligned} E[L_H(t + \Delta t) - L_H(t)]^2 &= \\ E|L_H(t + 1) - L_H(t)|^2 \|\Delta t\|^{2H} \end{aligned} \quad (9)$$

一般情况下, 普通平面图形的分形维数可以通过下面公式求得:

$$D = 3 - H \quad (10)$$

如果零均值高斯随机分布函数用  $L(t)$  代表, 那么具体形式可用下式表示

$$F(x) = 2 \int_{-\infty}^0 \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{s^2}{2\sigma^2}\right) ds \quad (11)$$

根据公式(7) 可以知道

$$\begin{aligned} E\left|\frac{L(t + \Delta t) - L(t)}{\|\Delta t\|^H}\right| &= E|x| = \\ 2 \int_0^{+\infty} x \frac{1}{\sqrt{2\pi\sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right) dx &= \frac{2\sigma}{\sqrt{2\pi}} = C \end{aligned} \quad (12)$$

于是, 公式(7) 可以用下式表示

$$\log E|L(t + \Delta t) - L(t)| - H \log \|\Delta t\| = \log C \quad (13)$$

因为  $H$  和  $C$  都是常数, 通过公式(13), 可以知道  $\log E|L(t + \Delta t) - L(t)|$  和  $\log \|\Delta t\|$  具有线性关系, 在直角坐标系中 ( $\log \|\Delta t\|$ ,  $\log E|L(t + \Delta t) - L(t)|$ ) 代表直线斜率, 用  $H$  代表. 这样可以通过相关信息拟合一条直线, 从而得到  $H$  的值.

### 2.2.3 图像的分形特征

#### (1) 分布函数

图像表面形状的特征描述之一的是其分布函数

$F(x)$ . 在本章中,  $F(x)$  为零均值高斯分布函数  $N(0, \sigma^2)$ , 它的特性由  $\sigma^2$  决定.

#### (2) 分形维数

分形维数是图像特征参数的分形描述, 其分形维数利用上述公式(10) 得到. 在同一个分布函数  $F(x)$  下, 图像分形维数  $D$  越大, 被测物体就更粗糙, 反之亦然.

### 2.2.4 随机中点位移法

利用分形理论可以得到具体的随机中点位移法, 它通过下面公式进行内差点  $(x_{mi}, y_{mi})$  值表达, 具体为<sup>[4,5]</sup>

$$x_{mi} = (x_i + x_{i+1})/2 + s \cdot \omega \cdot \text{rand}() \quad (14)$$

$$y_{mi} = (y_i + y_{i+1})/2 + s \cdot \omega \cdot \text{rand}() \quad (15)$$

式中,  $x$  为水平轴;  $y$  为垂直轴;  $s$ ,  $\omega$  为控制参数,  $s$  控制着  $x$  左右方向移动和  $y$  上下方向移动,  $\omega$  是对  $s$  在  $x$  及  $y$  方向的实际移动距离进行控制;  $\text{rand}()$  表示对移动的随机变量进行控制.

通过正态随机函数  $\text{stdev} * N(0, 1)$  对随机变量  $s \cdot \omega \cdot \text{rand}()$  进行表示, 使得  $s \cdot \text{rand}()$  符合正态分布. 新区间的标准差演化规律可以通过参数  $H$  进行记录, 根据 Mandelbrot 理论, 可以知道其相应维数为  $1 + H$ .

### 2.2.5 基于分形理论的二维局域均值分解插值算法

#### (1) 图像特征量提取

1) 通过计算图像中值为  $\Delta t$  的空间距离的像素亮度差期望值, 记作  $E|L_H(t + \Delta t) - L_H(t)|^2$ .

2) 确定尺度极限参数  $|\Delta t|_{\min}$  及  $|\Delta t|_{\max}$ .

如果图像是理想分形特征, 那么分形维数为常数. 但是, 实际图像并不一定是完全理想分形, 故需要确定一个尺度范围, 以保证在该范围内的分形维数是一个常数. 具体方法为: 画出分形维数图, 就是  $\log E|L_H(t + \Delta t) - L_H(t)|^2$  相对于  $\log |\Delta t|$  的曲线, 其中直线段的上下限分别为  $|\Delta t|_{\min}$  及  $|\Delta t|_{\max}$ .

3) 对参数  $H$  和像素灰度正态分布标准差  $\delta$  进行计算, 根据公式(8) 得到如下关系

$$\log E|L_H(t + \Delta t) - L_H(t)|^2 - 2H \log |\Delta t| = \log \sigma^2 \quad (16)$$

式中,  $\sigma^2 = E|L_H(t + 1) - L_H(t)|^2$ .  $H$  和  $\sigma$  可以通过求解上述方程得到.

#### (2) 二维局域均值分解分形插值

二维局域均值分解分形插值算法本质上是随机中点位移法递归实现的过程, 它通过下式实现, 对于图像中的像素点  $(i, j)$ , 假设  $i, j$  均为奇数时, 它的灰度值  $L_H$  已经确定, 则对  $i, j$  均为偶数时, 可以

得到

$$L_H(i, j) = \frac{1}{4} \{L_H(i-1, j-1) + L_H(i+1, j-1) + L_H(i+1, j+1) + L_H(i-1, j+1)\} + \sqrt{1-2^{2H-2}} \|\Delta t\| \cdot H \cdot \sigma \cdot G \quad (17)$$

当  $i, j$  有且仅有一个偶数时有

$$L_H(i, j) = \frac{1}{4} \{L_H(i, j-1) + L_H(i-1, j) + L_H(i+1, j) + L_H(i, j+1)\} + 2^{-H/2} \sqrt{1-2^{2H-2}} \|\Delta t\| \cdot H \cdot \sigma \cdot G \quad (18)$$

式中,  $G$  是服从  $N(0, 1)$  分布的 Gauss 随机变量;  $\|\Delta t\|$  为样本间距离, 故可以利用原图像特征描述信息的  $H$  和  $\sigma$  共同作用得到插值点亮度。

在达到设定空间分辨率之前, 不断重新上述步骤。其中每一次迭代过程中, 需要插入的中点均为高斯随机变量, 期望值为四个相邻点的均值。点的偏移量可以通过能够描述图像特性信息的  $H$  和  $\sigma$  共同决定。当  $H=0$  时, 此点相对与其相邻四个点均值的偏移量需通过  $\sigma$  决定; 而  $H=1$ , 方差为 0, 得到的相邻四个点均值相当于线性插值。如果  $\sigma$  取值一定的情况下, 则  $H$  越小, 插值点随机性就会更大。具体插值原理如图 2 所示。




图 2 分形插值基本示意图

### 2.3 二维生产函数分量曲面的获取

根据一维局域均值分解的原理, 可以得到二维局域均值分解的筛分过程。对于一幅二维图像信号  $f(x, y)$ , 它的上下包络曲面分别用  $f_{\max}(x, y)$  和  $f_{\min}(x, y)$  表示, 那么其均值曲面  $m_1(x, y)$  可用下式表示:

$$m_1(x, y) = \frac{f_{\max}(x, y) + f_{\min}(x, y)}{2} \quad (19)$$

根据二维生产函数分量的基本特性, 在理想状况下, 第一次筛分得到的均值曲面可用作作为第一个分量  $h_1(x, y)$ , 具体用下式表示:

$$h_1(x, y) = f(x, y) - m_1(x, y) \quad (20)$$

由于曲面  $h_1(x, y)$  中可能存在非对称波, 所以必须继续进行筛分, 但第二次筛分需要以  $h_1(x, y)$  作为分解对象, 那么:

$$h_{11}(x, y) = h_1(x, y) - m_{11}(x, y) \quad (21)$$

式中,  $m_{11}(x, y)$  是  $h_1(x, y)$  的局部均值。重复筛分  $k$  次后, 有:

$$h_{1k}(x, y) = h_{1(k-1)}(x, y) - m_{1k}(x, y) \quad (22)$$

在此, 我们将  $BPF_1(x, y) = h_{1k}(x, y)$ 。

$BPF_1(x, y)$  是从原始图像信号分解得到的第一个二维生产函数。把原始图像信号  $f(x, y)$  分离出来的剩余图像信号  $R_1(x, y)$  作为新的图像进行继续筛分, 那么:

$$R_1(x, y) = f(x, y) - BPF_1(x, y) \quad (23)$$

很明显,  $R_1(x, y)$  包含图像信号中较大尺度部分。

所以, 最终的筛分结果可以用下式表示:

$$f(x, y) = \sum_{i=1}^n BPF_i(x, y) + R_n(x, y) \quad (24)$$

也就是说原始图像被分解为  $n$  个二维生产函数分量和一个趋势项  $R_n(x, y)$ 。

### 2.4 停止条件

筛分过程是为了删除骑行波的本底和波形剖面更加对称。该处理过程能平滑不规则的振幅和削弱数据的奇异性, 但它会影响图像的物理意义, 故不能无限地处理下去。同时, 由于实际计算过程中存在均值曲面的过分解和欠分解。而过分解和欠分解将会影响均值和分解过程的结果。因此, 必须根据图像信号本身特点来终止分解过程。

本文提出了根据每次剔除均值曲面后所得到剩余曲面  $h_{k,l}(m, n)$  极值点数目演化规律, 将其与上一次得到的剩余曲面  $h_{k,l-1}(m, n)$  对比, 分别计算这两个曲面在零值平面投影位置上极值点不重合数, 再将这两个具体数目进行求得到总极值点数, 用  $T_k$  表示, 类似地, 下一次筛分也会得到相应的总极值点数, 用  $T_{k+1}$  表示。而用  $\Delta_{k+1}$  来表示这两次筛分得到的总的极值点数目之差, 具体如下

$$\Delta_{k+1} = T_{k+1} - T_k \quad (25)$$

式中,  $k \geq 2$  于是, 筛分  $n$  次之后不重合极值点变化平均速度, 记为  $\bar{V}$ , 也即

$$\bar{V} = \frac{\sum_{i=2}^{n-1} \Delta_{k+1}}{n-2} \quad (26)$$

式中,  $n \geq 3$  比较  $\bar{V}$  和  $\Delta_n$ , 也即

$$\Delta_n \leq \bar{bV} \quad (27)$$

式(27)是设定的分解停止条件, $b$ 为常数,根据多次相关试验结果分析,可以得到, $b$ 取值在0.09—0.32之间比较合理,同时可以达到较好地分解效果.通过本停止条件筛分得到的二维固有模态函数较其它条件得到的二维生产函数更能反映待分析图像的特征信息、边缘信息和细节信息.与此同时,为了进一步证明本文提出停止条件的合理性、自适应性,将在后续部分进行实证分析和说明.

## 2.5 二维局域均值分解算法计算过程

(1) 待分解图像进行初始化,  $r_0(m, n) = f(m, n)$ ,  $k = 1$ ,  $(m, n) \in [0, m-1] \times [0, n-1]$ , 其中  $M$  和  $N$  分别代表图像离散到平面上行列数.

(2) 初始化  $h_{k,0}(m, n) = r_{k-1}(m, n)$ ,  $l = 1$ .

(3) 采用2.1节原理提取得到  $h_{k,l-1}(m, n)$  的极值点.

(4) 利用2.2节提出的分形插值算法分别进行插值, 计算得到  $h_{k,l-1}(m, n)$  的上、下包络曲面  $e_{\max,l-1}(m, n)$  及  $e_{\min,l-1}(m, n)$ .

(5) 利用上、下包络曲面, 求取均值包络曲面, 计算公式为

$$e_{\text{mean},l-1}(m, n) = \frac{e_{\max,l-1}(m, n) + e_{\min,l-1}(m, n)}{2} \quad (28)$$

(6) 对于原始图像信号进行更新, 获得需继续迭代的新信号.

$$h_{k,l}(m, n) = h_{k,l-1}(m, n) - e_{\text{mean},l-1}(m, n), l = l + 1 \quad (29)$$

(7) 停止条件选取: 首先分别计算得到  $h_{k,l}(m+i, n+i)$  和  $h_{k,l-1}(m+i, n+i)$  在零值平面投影位置的极值点不重合个数, 并累加, 记为  $T_i$ , 下一次筛分时, 记作  $T_{i+1}$ . 这两次极值点不重合个数之差记为  $\Delta_{k+1}$ , 筛分  $n$  次后其平均变化速度, 记为  $\bar{V}$ , 比较  $\bar{V}$  和  $\Delta_n$

$$\Delta_n \leq \bar{bV} \quad (30)$$

式中, 式(30)即为本算法停止条件, 根据多次试验,  $b$ 取0.13最优.

(8) 重复步骤(2)到步骤(7), 直到满足公式(30)的分解停止条件, 则迭代终止. 此时  $h_{k,l}(m, n)$  为筛分得到的二维固有模态函数, 即  $BPF_k(m, n) = h_{k,l}(m, n)$ .

(9) 更新信号, 获得剩余信号.

$$R_k(m, n) = r_{k-1}(m, n) - BPF_k(m, n) \quad (31)$$


(10) 重复步骤(1)到步骤(9), 直到使得  $k = k+1$  的剩余信号  $r_k(m, n)$  为单调信号, 得到所有  $BPF$  分量后,  $BLMD$  分解过程结束.

原始图像最终可以表示为  $BPF$  分量和最后剩余信号之和, 公式为

$$f(m, n) = \sum_{k=1}^K BPF_k(m, n) + r_K(m, n), k \in N^* \quad (32)$$


## 3 算法性能分析

为了说明本算法在性能方面的优势, 本文利用径向基-二维经验模式分解方法、FABEMD方法及本算法分别对合成纹理图像进行分解, 所使用的合成纹理图像是由以下三种不同幅度、频率的正弦单分量之和组成, 第一个分量如图3(a)所示, 它的空间频率最高, 其水平频率为  $h_1 = 30$ , 垂直频率  $v_1 = 50$ , 振幅为  $A_{h1} = 30$  和  $A_{v1} = 30$ , 第二个分量如图3b所示, 处于中频段, 其水平频率为  $h_2 = 15$ , 垂直频率为  $v_2 = 19$ , 振幅为  $A_{h2} = 40$  和  $A_{v2} = 60$ , 第三个分量如图3(c)所示, 它的频率最低, 变化也最为平稳, 其水平频率为  $h_3 = 0.3$ , 垂直频率为  $v_3 = 0.5$ , 振幅为  $A_{h3} = 200$  和  $A_{v3} = 200$ , 由这三个分量累加得到的合成纹理图像如图3(d)所示.




(a) 高频分量 (b) 中频分量 (c) 低频分量 (d) 合成纹理图像

图3 原始图像及合成纹理图像



(a) BIMF1 (b) BIMF2 (c) BIMF3 (d) 残差


图4 小波分解结果示意图



(a) BIMF1 (b) BIMF2 (c) BIMF3 (d) 残差


图5 二维经验模式分解结果示意图

利用小波方法对合成的图3(d)的纹理图像进行分解, 分解结果如图4所示. 通过二维经验模式分解算法对合成的图3(d)的纹理图像进行分解, 停止



(a) BPF1 (b) BPF2 (c) BPF3

图 6 本文方法分解结果示意图



(a)小波 (b) 二维经验模式分解 (c) 本文提出的方法

图 7 三种不同方法分解得到的分量累加效果图

条件 SD 取值为 0.3,得到的分解结果如图 5 所示.最后利用本文提出的二维局域均值分解算法对合成的纹理图像进行分解,得到的分解结果如图 6 所示.这三种方法分解得到的分量分别进行合成累加得到的重构图如图 7 所示.通过图 4—图 7 可知,小波得到的分解结果与合成纹理图像的所需分量差异较大,多分出了一个分量无法解释其来源.分解得到的分量合成累加后的图像与人工合成的纹理图像存在较大差异.二维经验模式分解算法分解得到的四个分量与原始构分量存在一定的差异,而且出现了两个趋势项,可能是由于停止条件选取不合理造成,分解得到的分量合成累加后的图像与人工合成的纹理图像存在一定差异.小波、二维经验模式分解算法得到的分量合成累加后的图像与人工合成的纹理图像都具有一定的差异.然而,本文提出的方法分解得到了三个分量,与原始构分量基本一致.分解得到的三个分量合成累加得到的图像,也与人工合成的纹理图像最接近.

4 结束语

本文在局域均值分解算法的基础上,提出了可以对图像信号进行自适应处理的二维局域均值分解算法,该算法较好地继承了一维局域均值分解算法的数据驱动性、多尺度性和自适应等特性.实例证明本文提出的分解算法较小波、BEMD 具有分解效果更准确、更可靠、更有效等优势.

参考文献:

[1] SEMMLOW J L, GRIFFEL B. Biosignal and medical image processing [M]. Florida: CRC press, 2014: 50-78.

[2] SCHINDELIN J, ARGANDA-CARRERAS I, FRISE E, et al. Fiji: an open-source platform for biological-image analysis[J]. Nature methods, 2012, 9(7): 676-682.

[3] SMITH, JONATHAN S. The local mean decomposition and its application to EEG perception data[J]. Journal of the Royal Society Interface, 2005, 2(5): 443-454.

[4] FRACTALS. Theory and Applications in Engineering: Theory and Applications in Engineering [M]. Berlin: Springer Science & Business Media, 2012: 120-137.

[5] TORRES I C, RUBIO J M A, IPSEN R. Using fractal image analysis to characterize microstructure of low-fat stirred yoghurt manufactured with microparticulated whey protein[J]. Journal of Food Engineering, 2012, 109(4): 721-729.

作者简介:

安凤平 男,(1983-),博士,讲师.研究方向为图像处理、模式识别及深度学习方面的科研和教学工作.  
E-mail: anfengping@bit.edu.cn, anfengping@163.com。