系数多状态关联的图像 NSST-HMT 模型

王相海^{1,2}, 赵晓阳¹, 朱毅欢¹, 宋若曦^{1,2}, 宋传鸣^{1*}

1. 辽宁师范大学计算机与信息技术学院, 大连 116029

2. 辽宁师范大学自然地理与空间信息科学辽宁重点实验室, 大连 116029

* 通信作者. E-mail: chmsong@lnnu.edu.cn

收稿日期: 2018-05-14; 接受日期: 2018-09-05; 网络出版日期: 2019-06-06

国家自然科学基金 (批准号: 41671439, 61402214)、辽宁省高等学校创新团队支持计划 (批准号: LT2017013)、大连市青年科技之星项目支持计划项目 (批准号: 2015R069) 和南京大学计算机软件新技术国家重点实验室开放课题项目 (批准号: KFKT2018B07) 资助

摘要 近年来, 非下采样 Shearlet 变换 (non-subsampled shearlet transform, NSST) 因其具有各向异性, 多方向捕捉性的同时, 还兼具平移不变性, 从而在图像恢复过程中发挥着重要的稳定作用. 本文首先对图像 NSST 子带内系数关系、子带间系数的“父子关系”和“兄弟关系”3 方面进行分析, 获得子带内系数具有稀疏性、子带间“父子关系”和“兄弟关系”系数均具有聚集性和传递性的结论. 在此基础上提出一种基于系数多状态关联的隐 Markov 树模型 (multi-state non-subsampled shearlet transform hidden Markov tree, M-NSST-HMT), 该模型通过将 NSST 子带间系数的“父子关系”和“兄弟关系”作为共同指导子带间系数传递的状态来估计重构系数, 并利用两种状态关联的互信息来对重构系数进行整合. 最后将所提出的模型应用于图像去噪并取得良好的去噪效果, 结果表明所提出的模型较传统 HMT 模型能够更好地揭示图像 NSST 变换后子带内和子带间系数的关系, 并提高系数的预测准确性.

关键词 非下采样剪切波变换, 混合 Gauss 模型, 隐 Markov 树模型, 系数多状态关联, 图像去噪, 支持向量机

1 引言

多尺度几何分析工具之所以在图像处理领域获得成功, 很大程度上归结为人们对图像经多尺度变换后所形成的子带内和子带间系数关系的挖掘. 隐 Markov 树 (hidden Markov tree, HMT) 模型通过将子带间的系数以一种树状结构的形式相关联, 揭示了子带间系数所具有的 Markov 相关性. Wavelet 及后 Wavelet 时代多尺度分析工具的快速发展, 引起人们对其对应的 HMT 模型的关注. 目前主要的基于多尺度分析工具的 HMT 模型包括: 基于 Wavelet 变换的 HMT 模型^[1,2], 展示了图像 Wavelet 变换

引用格式: 王相海, 赵晓阳, 朱毅欢, 等. 系数多状态关联的图像 NSST-HMT 模型. 中国科学: 信息科学, 2019, 49: 708–725, doi: 10.1360/N112017-00293
Wang X H, Zhao X Y, Zhu Y H, et al. Image NSST-HMT model with associated multi-state coefficients (in Chinese). Sci Sin Inform, 2019, 49: 708–725, doi: 10.1360/N112017-00293

系数的非 Gauss 性和聚集性,并将其应用于图像去噪和分类领域;基于 Curvelet 变换的 HMT 模型^[3],挖掘图像 Curvelet 变换系数的特性,通过 HMT 模型捕捉了 Curvelet 系数之间的尺度从属性,并将其应用于 SAR 图像相干斑噪声去除中;基于二代 Bandlet 的 HMT 模型^[4],参考文献^[1]过程挖掘了图像 Bandlet 子带间系数的相关性,并通过多尺度参数训练和上下文的最大后验概率进行图像分割;基于 Contourlet 变换的 HMT 模型^[5],捕捉了尺度、方向和位置间系数的相关性,并将其应用于图像去噪和纹理检索中;基于 Contourlet 变换的带方向特性的 HMT 模型^[6],揭示了方向特征在 Contourlet 变换的父子子带间形成传递的特性,并将其应用于图像分割中;基于 NSCT (non-subsampled contourlet transform, NSCT) 的 HMT 模型^[7],在保持平移不变特性的同时,捕捉了不同方向、不同尺度系数之间的相关性,并将其应用于图像的去噪中;进一步,文献^[8]将其应用于遥感图像的去噪和变化探测中;双 Contoulet 域 HMT 模型^[9],将 HMT 模型与单边指数分布相结合挖掘了带符号系数之间的相关性,并将其应用于图像去噪中。

上述这些 HMT 从不同多尺度分析工具的特性出发,对子带间系数的传递特性进行了挖掘,这些特性包括幅值、方向和符号等等,但其一个共同的特点是所采用的预测树形结构均为单状态关联,即父子关系的预测结构.而经过大量统计分析发现,在图像的多尺度分析子带中,兄弟子带间的系数也会表现出一定的相关特性,充分挖掘该特性并将其应用于 HMT 模型的系数预测中势必会对系数的预测有所贡献.基于此,本文对非下采样 Shearlet 变换 (non-subsampled shearlet transform, NSST)^[10]的系数分布、各子带系数的相关性等进行研究,提出一种新的系数多状态关联的图像 NSST-HMT 模型,采用混合 Gauss 模型对 NSST 子带内的系数进行建模,将父子子带之间的传递性与兄弟子带间的关联性作为 HMT 模型状态转移的两个关联状态,通过互信息来分别衡量当前系数与其父系数、兄弟系数的相关强弱程度,并据此对两个预测系数进行整合,提高了模型对系数的预测准确性.最后将所提出的模型应用于图像的去噪中,取得了较传统 HMT 模型以及目前流行的图像去噪算法更好的去噪效果.

2 图像 NSST 子带内系数统计特性及混合 Gauss 拟合

2.1 NSST

Shearlet 变换是后小波时代一种具有良好的方向敏感性和各向异性的多尺度几何变换工具^[11~13],该变换将膨胀算子、剪切算子和平移算子进行组合,以增强基函数的方向敏感度,从而实现对图像任意方向的信息提取.其中膨胀算子用来实现信号的多尺度分解,剪切算子用来实现信号的多方向分解,而通过平移算子实现元素在二维平面上转移.为了生成具有各向异性支持的波形,Shearlet 采用了抛物线膨胀矩阵的膨胀算子,并通过旋转变换来改变波形的方向;进一步,为了克服一般旋转变换所带来的对整数格结构的破坏,Shearlet 在剪切算子中通过参数化的方式实现了方向的斜率表示,从而实现对图像任意方向信息的提取.这种接近最优的多维函数稀疏表示方式在图像处理,特别是复杂纹理图像的处理方面受到重视^[14~16].

与传统的 Wavelet 变换相似,上述 Shearlet 变换也采用了下采样的操作模式,因而在图像处理过程中同样存在着空间支撑丢失和 Gibbs 现象.文献^[10]在 Shearlet 理论上,用非下采样金字塔 (non-subsampled pyramid, NSP) 算法替代传统 Shearlet 变换中的下采样金字塔算法,提出了一种非下采样 Shearlet 变换,避免了方向滤波中的失真.NSST 变换主要包含两个过程:一是基于非下采样金字塔滤波器组的图像多尺度分解,其中一次 NSP 分解将产生一个低频子带和一个高频子带.该过程可

图 1 (网络版彩图) NSST 第一层第一方向子带的分布直方图

Figure 1 (Color online) The distribution histogram of the 1st direction subband in the 1st layer of the NSST from test images

按分解层数对所产生的低频子带重复进行; 二是利用剪切滤波器 (shearing filter, SF) 对高频子带进行多方向分解, 对 l 级方向分解产生 2^l 个方向子带. 标准 Shearlet 变换中用到的 SF 是通过窗函数进行平移操作实现的, 其间需要进行下采样, 因而不具有平移不变性. NSST 除了保持传统 Shearlet 变换所具有的各向异性和多方向捕捉特性外, 还具有了平移不变特性, 该特性对于图像去噪和恢复等图像处理的稳定性发挥着重要作用, 特别对具有复杂纹理信息的图像处理^[17~19].

2.2 图像 NSST 子带内系数统计特性分析

为了分析图像 NSST 子带内系数的统计特性, 我们选取 3 幅测试图像 (记为 Test-image1, Test-image2 和 Bridge) 并对其进行 3 层 NSST 分解, 依次为 2, 4, 8 个方向子带. 对每一层子带的系数进行了直方图统计, 图 1 给出了对第 1 层第 1 方向子带的统计结果. 从统计结果可以看出: NSST 系数具有“高峰重尾”的分布特性, 即绝大多数系数值均在零点附近, 并且峰度 (kurtosis) 均大于 Gauss 分布的峰度, 而只有少量系数值较大. 这些特性在其他方向子带中也同样出现.

2.3 图像 NSST 子带系数的 Gauss 混合建模

图像 NSST 方向子带所表现出的大量系数值较小, 少量系数值较大所造成的“高峰重尾”特性, 这很难用单 Gauss 模型进行逼近, 但可以通过混合两个 Gauss 分布函数来对其进行建模, 即用方差大的 Gauss 分布来描述“大状态” (即少量对应图像边缘区域的幅值较大的系数), 用方差小的 Gauss 分布来描述“小状态” (即大量对应图像平滑区域的幅值较小的系数), 然后将两个 Gauss 函数混合, 得到 Gauss 混合模型, 实现对 NSST 方向子带系数的建模.

对于 NSST 方向子带系数集 $X = \{c_1, c_2, \dots, c_N\}$, 其边缘概率密度函数定义为

$$f(c_i) = \sum_{s_i=1,2} P_{s_i} f(c_i|s_i), \quad (1)$$

图 2 (网络版彩图) 对图 1 中测试图像 NSST 第 1 层第 1 方向子带系数的 GMM 拟合

Figure 2 (Color online) The GMM fitting results to the 1st direction in the 1st layer of the NSST subband from the test images in Figure 1

表 1 图 2 中测试图像 GMM 拟合程度 KS 值

Table 1 The Kolmogorv-Smirnov of GMM fitting for test images in Figure 2

Test image	The 1st direction subband in the 1st layer	The 1st direction subband in the 2nd layer	The 1st direction subband in the 3rd layer
Test-image1	0.0154	0.0211	0.0366
Test-image2	0.0126	0.0125	0.0399
Bridge	0.0173	0.0275	0.0497

其中 $c_i \in X$, s_i 表示系数对应的状态 (其取值 1 和 2 分别对应大、小状态), P_{s_i} 表示 c_i 对应状态 s_i 的概率, 且满足 $\sum_{s_i=1,2} P_{s_i} = 1$; $f(c_i|s_i = 1)$ 和 $f(c_i|s_i = 2)$ 分别为大、小两个状态下所对应的 Gauss 条件概率密度函数, 其表达式如下式所示:

$$f(c_i|s_i = m) = \frac{1}{\sqrt{2\pi\sigma_{i,m}^2}} \exp\left(-\frac{c_i^2}{2\sigma_{i,m}^2}\right) = g(c_i; 0; \sigma_{i,m}^2), \tag{2}$$

其中 $\sigma_{i,m}^2$ 为方差, 这样可以利用参数集 $GMM = \{P_{s_i}, 0, \sigma_{i,m}^2\}$ 来表示 NSST 方向子带系数的概率分布模型.

图 2 给出了利用 Gauss 混合模型 (GMM) 对图 1 中 3 幅测试图像第 1 层第 1 方向子带直方图进行的拟合曲线 (这里采用了 EM^[20] 算法对参数进行了估计), 其中蓝色线表示子带内系数直方图曲线, 红色线表示拟合曲线.

进一步, 选取 KS (Kolmogorov-Smirnov)^[21] 作为评价指标来对测试图像经 NSST 变换后第 1~3 层的第 1 方向子带系数的 GMM 拟合程度进行定量分析, 统计结果参见表 1. KS 的计算公式为

$$KS = \max_{\omega \in R} |F_h(\omega) - F_e(\omega)|, \tag{3}$$

其中 $F_h(\cdot)$ 和 $F_e(\cdot)$ 为先验概率分布函数和标准分布的累积分布函数. KS 值越小表明拟合度越高.

从图 2 和表 1 可以看出, 无论是主观视觉效果还是客观评价指标, GMM 均可对测试图像的方向子带系数进行很好地拟合.

3 图像 NSST 子带间系数多状态关联度分析

为了考察图像 NSST 子带间系数的关系, 我们采用联合概率分布统计与系数差分直方图方法对不同子带系数间的关联情况进行分析.

图 3 图像 NSST 子带间父子关系示意图

Figure 3 Schematic diagram of parent-children relationship between NSST subbands

图 4 (网络版彩图) NSST 父子系数间联合概率分布统计及差分直方图

Figure 4 (Color online) The joint probability distribution and the differential histogram of parent-son coefficients

3.1 图像 NSST 域父子子带系数相关性分析

首先对图像 NSST 父子子带间的系数关系进行如下定义: 对于图像 NSST 当前尺度的子带系数 X , 定义同一子带的 X 周围的 8 个相邻系数为 X 的邻域系数, 记为 NX ; 定义上一尺度与 X 对应方向且相同位置的系数为父系数, 记为 PX , 即 X 是 PX 的子系数. X 与 NX 和 PX 的关系示意图参见图 3.

进一步, 我们对 3 幅测试图像的父子子带系数的联合概率分布与系数差分直方图进行分析. 图 4 给出了一对父子子带的联合概率分布统计结果及系数差分直方图.

通过上面的统计分析可以获得下列结论: (1) 从联合概率分布图来看, 绝大多数点位于零点, 并向该点聚集, 即图像 NSST 子带的父子系数具有较强的聚集性; (2) 从系数差分直方图来看, 图像 NSST 父子系数的差值都集中在“小”数值中, 并且绝大部分为零, 即当父系数为“大”系数时, 其子系数也为“大”系数的概率大, 反之亦然, 这说明图像 NSST 子带的父子系数具有一定的传递性. 综合上述两

图 5 NSST 子带间兄弟关系示意图

Figure 5 Schematic diagram of brother-hood relationship between NSST subbands

点特性, 本文将图像 NSST 子带系数间的“父子关系”作为构建 HMT 模型的第一种关联状态.

3.2 图像 NSST 域兄弟子带系数相关性分析

首先对图像 NSST 兄弟子带间的系数关系进行如下定义: 对于当前子带的 NSST 系数 X , 定义与同一尺度, 拥有相同父系数且与空间位置相同的系数为“亲兄弟系数”, 记为 C_1X ; 定义与 X 在同一尺度, 相隔一个子带且与 X 空间位置相同的系数为“堂兄弟系数”, 记为 C_2X . 兄弟系数间这种关系的示意图参见图 5.

进一步, 我们对 3 幅测试图像的兄弟子带系数的联合概率分布进行分析, 同时统计兄弟子带间的系数差分直方图. 图 6 为一对亲兄弟子带间与堂兄弟子带间的联合概率分布统计结果及系数差分直方图.

通过图 6 可以看出, 无论是亲兄弟系数还是堂兄弟系数, 其联合概率统计分布与系数差分直方图的分布都与父子子带的相似. 这说明图像 NSST 域兄弟子带系数之间同样具有与父子子带系数之间相似的聚集性与传递性. 因此, 本文将图像 NSST 子带系数间的兄弟关系作为构建 HMT 模型的第 2 种关联状态.

4 基于 NSST 子带间多状态系数关联的 HTM 的建立

4.1 图像 NSST 子带间多状态系数相关性的互信息度量

互信息 (mutual information, MI) 源于信息论, 用于测量两个随机变量的统计相关性, 90 年代开始被用于图像的配准和分割中^[22, 23]. 两个随机变量 X, Y 互信息的数学表达式为

$$\text{MI}(X; Y) = \sum_{y \in Y} \sum_{x \in X} P_{XY}(x, y) \log \left(\frac{P_{XY}(x, y)}{P_X(x)P_Y(y)} \right), \quad (4)$$

图 6 (网络版彩图) NSST 兄弟系数间联合概率分布统计及差分直方图

Figure 6 (Color online) The joint probability distribution and the differential histogram of brother-hood coefficients

其中 $P_X(x)$ 和 $P_Y(y)$ 分别表示随机变量 X, Y 的边缘概率分布, $P_{XY}(x, y)$ 为 X, Y 的联合概率分布. 互信息与熵的关系可以描述为

$$\text{MI}(X; Y) = H(X) + H(Y) - H(X, Y), \quad (5)$$

其中 $H(X), H(Y)$ 表示 X, Y 的熵, $H(X, Y)$ 为 X, Y 的联合熵.

进一步, 可归一化互信息为

$$\text{NMI}(X, Y) = \frac{H(X) + H(Y)}{H(X, Y)}. \quad (6)$$

对于前面所获得的图像 NSST 子带系数间的第 1 种关联状态和第 2 种关联状态, 我们可以通过如下互信息来度量其对当前系数的影响权重:

第 1 种关联状态对当前系数的影响权重:

$$\text{NMI}_p(y_{i,j}, y_{i,j-1}) = \frac{H(y_{i,j}) + H(y_{i,j-1})}{H(y_{i,j}, y_{i,j-1})},$$

第 2 种关联状态对当前系数的影响权重:

$$\text{NMI}_c(y_{i,j}, y_{i+t,j}) = \frac{H(y_{i,j}) + H(y_{i+t,j})}{H(y_{i,j}, y_{i+t,j})}.$$

这里 $y_{i,j}$ 表示当前子带位于第 j 尺度第 i 方向的系数, $y_{i,j-1}$ 表示其父亲子带对应系数, $y_{i+t,j}$ 表示其兄弟子带对应系数, 其中当 $t = 1$ 时, 表示其亲兄弟子带系数; 而当 $t = 2$ 时, 表示其堂兄弟子带系数.

4.2 基于图像 NSST 子带间多状态系数关联的 HMT

基于前面的分析, 我们提出基于两种关联状态的 HMT 模型 (M-NSST-HMT), 其架构见图 7 (以方向子带个数为 2, 4, 8 的 NSST 分解为例), 模型建立的具体过程如下:

首先对图像进行 q 层 NSST 分解, 并假设方向 k 的系数构成一个含有 p 个节点的树结构, 记其为 T_1^k , 其中 “1” 表示树根节点, T_1^k 上的所有系数及其所对应的隐状态变量分别记为 $N^k = \{N_1^k, N_2^k, \dots, N_p^k\}$ 和 $S^k = \{S_1^k, S_2^k, \dots, S_p^k\}$; 用 T_j^k 表示根节点和方向分别为 j, k 的子树, 其中每一个节点 i 记录的是 NSST 系数 (用 N_i 表示), 该节点对应的隐状态、父节点和兄弟节点分别用 $S_i, \rho(i)$ 和 $c(i)$ 表示, 其中 N_1 和 S_1 分别表示整个树根节点的系数及其对应的隐状态.

进一步, 选取 GMM 对图像 NSST 分解后的不同方向子带系数进行建模, 并通过状态转移概率矩阵来表达不同尺度, 相同方向的 NSST 系数间的传递关系. 其中, $\Phi(\Phi = \rho(i), c(i))$ 表示当前关联状态, 当 $\Phi = \rho(i)$ 时, 为第 1 种关联状态, 即父子关联; 当 $\Phi = c(i)$ 时, 为第 2 种关联状态, 即兄弟关联. 由此, 我们可建立一个如下含有 4 个参数的四元组 $\theta_{\text{M-NSST-HMT}}$ 表示 NSST 域基于两种关联状态的 HMT 模型:

$$\theta_{\text{M-NSST-HMT}} = \{(P_{N_1, \Phi}(m), \varepsilon_{j,i,\Phi}^{m,n}, \sigma_{j,i,m,\Phi}^2, \omega_{j,i,\Phi}) | i = 1, 2, \dots, p; \\ j = 1, 2, \dots, q; m, n = 1, 2; \Phi = \rho(i), c(i)\}, \quad (7)$$

其中,

- (1) $P_{N_1, \Phi}(m)$ 为最粗尺度树根节点 N_1 的状态概率分布函数, m 为对应的隐状态;
- (2) $\varepsilon_{j,i,\Phi}^{m,n}$ 为各关联状态的状态转移概率矩阵: 当 $\Phi = \rho(i)$ 时, $\varepsilon_{j,i,\rho(i)}^{m,n} = f(S_i = m | S_{\rho(i)} = n)$ 表示第 1 种关联状态的状态转移概率, 其含义为当父节点 $\rho(i)$ 的隐状态变量 $S_{\rho(i)}$ 为 n 时, 子节点 i 的隐状态变量 S_i 为 m 的条件概率; 当 $\Phi = c(i)$ 时, $\varepsilon_{j,i,c(i)}^{m,n} = f(S_i = m | S_{c(i)} = n)$ 表示第 2 种关联状态的状态转移概率, 其含义为当兄弟节点 $c(i)$ 的隐状态变量 $S_{c(i)}$ 为 n 时, 子节点 i 的隐状态变量 S_i 为 m 的条件概率;
- (3) $\sigma_{j,i,m,\Phi}^2$ 为 j 尺度, i 方向子带上隐状态变量 $S_i = m$ 时混合 Gauss 分布的方差;
- (4) $\omega_{j,i,\Phi}$ 为以 $\varepsilon_{i,\rho(i)}^{m,n}$ 与 $\varepsilon_{i,c(i)}^{m,n}$ 作为状态转移概率对于最后预测系数的互信息权重: 当 $\Phi = \rho(i)$ 时, $\omega_{j,i,\rho(i)}$ 表示第 1 种关联状态对当前系数预测的互信息权重; 当 $\Phi = c(i)$ 时, $\omega_{j,i,c(i)}$ 表示第 2 种关联状态对当前系数预测的互信息权重. 其具体计算公式如下所示:

$$\begin{cases} \omega_{j,i,\rho(i)} = \frac{\text{NMI}_p(y_{i,j}, y_{i,j-1})}{\text{NMI}_p(y_{i,j}, y_{i,j-1}) + \text{NMI}_c(y_{i,j}, y_{i+t,j})}, \\ \omega_{j,i,c(i)} = \frac{\text{NMI}_c(y_{i,j}, y_{i+t,j})}{\text{NMI}_p(y_{i,j}, y_{i,j-1}) + \text{NMI}_c(y_{i,j}, y_{i+t,j})}. \end{cases} \quad (8)$$

图 7 M-NSST-HMT 模型结构示意图

Figure 7 The structure diagram of M-NSST-HMT model

对于式 (7) 中参数的估计, 除 $\omega_{j,i,\Phi}$ 外, 本文采用 EM 算法通过迭代方式获得, 具体过程可参考文献 [6].

5 所提出 HTM 模型在图像去噪中的应用

图像去噪和重构作为图像处理的经典问题一直受到关注, 目前去噪方法总体上可以分为非局部均值法, 各项异性扩散去噪, 双边滤波去噪和统计模型去噪方法等 [24, 25]. 尽管随着实际应用的需求, 去噪方法不断推陈出新, 比如在遥感图像去噪和重建领域出现了一些新的去噪方法 [26~29], 但目前对研究者而言如何在有效去除噪声的同时很好地保留图像的特征及纹理信息仍是一个具有挑战性的问题 [30]. 本文所提出的 M-NSST-HMT 模型很好的揭示了图像 NSST 子带系数间的关系, 并将该模型应用于图像去噪, 为后续的图像处理奠定了基础.

5.1 一致性临近分类器

一致性临近分类器 (proximal classifier with consistency, PCC) [31] 提供了一种具有一致性强化特性的分类方案, 即在决策和训练过程中通过比较一个点与两个超平面之间的距离来强化一致性, 取得了较广义特征值临近支持向量机更好的分类精度和效率.

考虑 $\mathbb{R}^n$ 空间的二元分类问题, 对于训练集 $\{(x_i, x_j) | i, j \in \{1, 2, \dots, p+q\}\}$ 和正、负输入集 X_+ 和 X_- , 其中 $X_+ = (x_1, x_2, \dots, x_p)^T \in \mathbb{R}^{p \times n}$, $X_- = [x_{p+1}, x_{p+2}, \dots, x_{p+q}]^T \in \mathbb{R}^{q \times n}$, 以及

$$y_j = \begin{cases} 1, & \text{if } j \in \{1, 2, \dots, p\}, \\ -1, & \text{if } j \in \{p+1, p+2, \dots, p+q\}. \end{cases} \quad (9)$$

PCC 的目标是确定一对形式为 $\omega_+^T + b_+ = 0$ 和 $\omega_-^T + b_- = 0$ 的正、负超平面, 使其各自逼近一类数据而同时能远离另一类数据.

记 $u_+ = [\omega_+, b_+]^T$, $G_+ = [X_+, e_+]$, $H_+ = G_+^T G_+$; $u_- = [\omega_-, b_-]^T$, $G_- = [X_-, e_-]$, $H_- = G_-^T G_-$, 其

中 e_+ 和 e_- 是两个适当维数的向量, 这样 PCC 的目标转换为下列优化问题:

$$\min_{u_+, u_- \neq 0} \frac{u_+^T (H_+ - vH_-) u_+ + \delta \|u_+\|_2^2}{\|u_+\|_2^2} + \frac{u_-^T (H_- - vH_+) u_- + \delta \|u_-\|_2^2}{\|u_-\|_2^2}, \quad (10)$$

其中 $v > 0, \delta > 0$ 分别为折衷参数和权重因子.

基于式 (10) 所确定的 u_+ 和 u_- , 即确定了 $[\omega_+, b_+]^T$ 和 $[\omega_-, b_-]^T$, 则对于新的样本 $x \in \mathbb{R}^n$, 可通过判断其更加接近于 $\omega_+^T + b_+ = 0$ 还是 $\omega_-^T + b_- = 0$ 来判断其属于 “+” 和 “-” 的哪个类, 即确定下式的 j :

$$\text{Class } j = \arg \min_{j=+,-} \frac{|\omega_j^T x + b_j|}{\|u_j\|_2}. \quad (11)$$

5.2 算法的实现

对于含噪图像的 NSST 系数 y , 我们可将其视为由原始图像 NSST 系数 x 和噪声系数 n 组合而成. 该算法将去噪的实现归结为应用所提出的 M-NSST-HMT 模型通过 y 估计 x 的过程. 其具体去噪过程如下.

Step 1. 对含噪图像进行 NSST 分解, 得到尺度从粗到细依次为 2, 4, 8 个方向的高频子带.

Step 2. 对含噪图像的 NSST 系数 y 用 PCC 方法进行分类, 筛选出有意义系数 y' , 即 “二元图” (参考文献 [31]) 中连续非零点所对应的 NSST 系数, 过程如下:

Step 2.1. 通过式 (12) 构造 $y(i, j)$ 系数所对应的 “二值图” $I(i, j)$, 其中 $j \in \{1, 2, 3\}$ 为系数所在的层数, i 为系数在该层的序号:

$$I(i, j) = \begin{cases} 1, & \text{if } |y(i, j)| > t_j, \\ 0, & \text{else.} \end{cases} \quad (12)$$

其中 t_j 为基于分解层子带的阈值, 其表达式为 $t_j = \frac{\sigma \times \sqrt{2 \ln N}}{e^{(j-1)/(j+1)}}$, $\sigma = \frac{\text{median}(|y(i, j)|)}{0.6745}$, N 为第 j 层子带系数个数.

Step 2.2. 对二值图 I , 按照有意义数据的 “非零联通” 原则 (参见文献 [32]), 在非零联通路径上选取具有一定长度的非零点, 并将与之对应位置上的 NSST 系数组成特征向量 F_k^1 ; 将标记为 0 的系数中与之相同数量点所对应的 NSST 系数组成特征向量 F_k^2 , 从而形成训练样本集 $\Omega_k = \{F_k^1, F_k^2\}$, ($k = 1, 2, \dots, M$).

Step 2.3. 对 $\Omega_k = \{F_k^1, F_k^2\}$ 进行 PCC 分类, 即从 y 中分离出有意义的系数 y' .

Step 3. 对系数 y' 建立 M-NSST-HMT 模型, 获得如式 (7) 所示的模型参数.

Step 4. 估算系数 y' 中噪声的方差 $(\sigma_{(j,k,i)}^{(\text{noise})})^2$, 这里采用 Monte-Carlo 方法 [33], 其中 j, k, i 依次表示各子带的尺度、方向及系数序号.

Step 5. 将 M-NSST-HMT 模型的方差 $(\sigma_{(j,k,i),m,\Phi}^{(y')})^2$ 与用 Monte-Carlo 方法估计得到的方差 $(\sigma_{(j,k,i)}^{(\text{noise})})^2$ 的差值作为原始图像 x 的系数方差模型, 即

$$(\sigma_{(j,k,i),m,\Phi}^{(x)})^2 = \begin{cases} (\sigma_{(j,k,i),m,\Phi}^{(y')})^2 - (\sigma_{(j,k,i)}^{(\text{noise})})^2, & \text{if } ((\sigma_{(j,k,i),m,\Phi}^{(y')})^2 - (\sigma_{(j,k,i)}^{(\text{noise})})^2) \geq 0, \\ 0, & \text{else.} \end{cases} \quad (13)$$

Step 6. 基于式 (13) 可获得去噪后图像的 HMT 模型:

$$\theta_{\text{M-NSST-HMT-}x} = \{(P_{N_1, \Phi}(m), \varepsilon_{j,i,\Phi}^{m,n}, (\sigma_{j,i,m,\Phi}^{(x)})^2, \omega_{j,i,\Phi})\}. \quad (14)$$

图 8 测试图像
Figure 8 Test images

当状态 $S_{j,k,i}$ 一定时, 假设噪声均值为 0 且与系数独立并符合 GMM, 这样可将 $\theta_{\text{M-NSST-HMT-}x}$ 的参数作为去噪后图像的先验模型来估计去噪后的高频 NSST 子带, 即利用 Bayes 估计可得

$$E[x_{j,k,i,\Phi}|y'_{j,k,i}, \theta_{\text{M-NSST-HMT-}x}, S_{j,k,i,\Phi}] = \frac{(\sigma_{(j,k,i),m,\Phi}^{(x)})^2}{(\sigma_{(j,k,i),m,\Phi}^{(x)})^2 + (\sigma_{(j,k,i)}^{(\text{noise})})^2} \times y'_{j,k,i}. \quad (15)$$

Step 7. 利用 EM 算法获得在样本为有意义系数 y' , $\theta_{\text{M-NSST-HMT-}x}$ 参数已知状况下隐状态为 m 的条件概率 $p(S_{j,k,i,\Phi} = m|y'_{j,k,i}, \theta_{\text{M-NSST-HMT-}x})$, 进而获得去噪图像 x 的估计如下:

$$E[x_{j,k,i,\Phi}|y'_{j,k,i}, \theta_{\text{M-NSST-HMT-}x}] = \sum \left(p(S_{j,k,i,\Phi} = m|y'_{j,k,i}, \theta_{\text{M-NSST-HMT-}x}) \times \frac{(\sigma_{(j,k,i),m,\Phi}^{(x)})^2}{(\sigma_{(j,k,i),m,\Phi}^{(x)})^2 + (\sigma_{(j,k,i)}^{(\text{noise})})^2} \times y'_{j,k,i} \right). \quad (16)$$

Step 8. 通过式 (8) 计算 $\omega_{i,j,\rho(i)}$ 和 $\omega_{i,j,c(i)}$, 并利用由式 (16) 获得的 $E[x_{j,k,i,\rho(i)}|y'_{j,k,i}, P_{N_1,\rho(i)}(m), \varepsilon_{j,i,\rho(i)}^{m,n}, \sigma_{j,i,m,\rho(i)}^2]$ 父子系数间相关性和 $E[x_{j,k,i,c(i)}|y'_{j,k,i}, P_{N_1,c(i)}(m), \varepsilon_{j,i,c(i)}^{m,n}, \sigma_{j,i,m,c(i)}^2]$ 兄弟系数间相关性, 分别获得对去噪图像 x 的估计 x_ρ 和 x_c , 通过式 (17) 加权计算最终去噪图像 x 的 NSST 系数估计:

$$x = x_\rho \times \omega_{i,j,\rho(i)} + x_c \times \omega_{i,j,c(i)}. \quad (17)$$

Step 9. 对 x 做 NSST 逆变换获得最终去噪结果.

5.3 实验结果分析

本文分别选取 “maxflat” 和 “dmaxflat7” 作为非下采样多尺度滤波器和方向滤波器, 对测试图像进行 3 层 NSST 分解, 各层方向子带个数分别为 2, 4, 8, 方向滤波器的方向分解个数分别为 16, 32, 64, 采用了 Matlab R2009a 的实验环境. 测试图像选取了大小为 512×512 的 6 幅图像, 分别为 3 幅遥感图像 Test-image1, Test-image2 和 Test-image3, 以及 3 幅自然图像 Bridge, Boat 和 Hill (参见图 8).

表 2 Test-image1 图像的 M-NSST-HMT 模型参数
Table 2 The parameters of Test-image1's M-NSST-HMT model

		$K = 1$		$K = 2$				$K = 1$		$K = 2$	
		State1	State2	State1	State2			State1	State2	State1	State2
$P_{1,k,\rho}$		0.35	0.65	0.30	0.70	$P_{1,k,c}$		0.70	0.30	0.28	0.72
$A_{2,2k-1,\rho}$	State1	0.38	0.94	0.71	0.01	$A_{2,2k-1,c}$	State1	0.97	0.02	0.20	0.85
	State2	0.62	0.06	0.29	0.99		State2	0.03	0.98	0.80	0.15
$A_{2,2k,\rho}$	State1	0.63	0.04	0.24	0.99	$A_{2,2k,c}$	State1	0.89	0.13	0.01	0.93
	State2	0.37	0.96	0.76	0.01		State2	0.11	0.87	0.99	0.07
$A_{3,2k-1,\rho}$	State1	1.00	0.01	0.22	0.90	$A_{3,2k-1,c}$	State1	0.96	0.01	0.00	1.00
	State2	0.00	0.99	0.78	0.10		State2	0.04	0.99	1.00	0.00
$A_{3,2k,\rho}$	State1	1.00	0.01	0.25	0.91	$A_{3,2k,c}$	State1	0.08	0.66	0.00	0.99
	State2	0.00	0.99	0.75	0.09		State2	0.92	0.34	1.00	0.01
$A_{3,2k+3,\rho}$	State1	0.99	0.00	0.01	0.39	$A_{3,2k+3,c}$	State1	0.01	0.95	0.07	0.80
	State2	0.01	1.00	0.99	0.61		State2	0.99	0.05	0.93	0.20
$A_{3,2k+4,\rho}$	State1	0.99	0.00	0.01	0.34	$A_{3,2k+4,c}$	State1	0.00	0.99	0.02	1.00
	State2	0.01	1.00	0.99	0.66		State2	1.00	0.01	0.98	0.00
$\sigma_{1,k,\rho}$		12.69	6.14	12.06	5.95	$\sigma_{1,k,c}$		4.23	1.81	4.28	1.67
$\sigma_{2,2k-1,\rho}$		9.08	4.82	9.56	4.21	$\sigma_{2,2k-1,c}$		4.63	2.55	3.70	2.92
$\sigma_{2,k,\rho}$		9.10	4.90	8.90	4.09	$\sigma_{2,k,c}$		4.49	2.57	3.87	2.90
$\sigma_{3,2k-1,\rho}$		5.74	2.30	4.86	2.22	$\sigma_{3,2k-1,c}$		4.53	2.03	5.44	1.92
$\sigma_{3,2k,\rho}$		5.74	2.30	4.92	2.23	$\sigma_{3,2k,c}$		4.75	2.24	5.33	2.06
$\sigma_{3,2k+3,\rho}$		5.63	2.26	6.48	2.53	$\sigma_{3,2k+3,c}$		5.29	2.23	4.56	2.10
$\sigma_{3,2k+4,\rho}$		5.63	2.23	6.93	2.62	$\sigma_{3,2k+4,c}$		5.32	2.06	4.57	1.88

表 2 给出了 Test-image1 图像通过 EM 算法训练所获得的 M-NSST-HMT 模型参数, 其中参数下标依左至右顺序分别表示尺度、方向和关联方式。

实验中通过对测试图像叠加不同等级的 Gauss 白噪声来获得噪声图像, 采用峰值信噪比 (PSNR) 作为去噪效果的客观评价指标, 同时与当前一些主流的去噪算法进行了对比实验, 这些算法包括 BM3D [34], MSDCT [35], BLS-GSM [2], NSCT-HMT [7], 以及不考虑“兄弟关系”的 NSST 相关算法的对比实验, 即 NSST-HMT. 表 3 给出了本文算法与对比算法对包含不同噪声的测试图像去噪后的 PSNR 值统计情况; 图 9 给出了这些算法对噪声方差为 25 的 Gauss 白噪声的测试图像去噪后的图像结果, 图 10 和 11 是对 Test-image1 和 Bridge 图像去噪后纹理局部区放大后的细节展示。

从表 3 的统计结果可以看出, 基于本文提出的系数多关联状态 NSST-HMT 模型去噪方法较其他方法在 PSNR 值的表现上有一定程度的提高. 同时由图 9~11 也可以观察到: 本文所提出的去噪方法在对具有纹理信息丰富的图像进行去噪时, 不仅能够有效地去除噪声, 同时还很好地保留了原图像中的边缘和纹理等特征。

6 结束语

本文提出了一种系数多状态关联的 NSST-HMT 模型 (M-NSST-HMT), 第 1 次在对隐 Markov 树

表 3 不同去噪方法的 PSNR 对比
Table 3 The PSNR value of different denoising models

Image	Noise level	PSNR (dB)					
		BM3D	MSDCT	BLS-GSM	NSCT-HMT	NSST-HMT	Proposed
Test-image1	25	26.49	25.94	26.38	25.64	25.59	27.07
	30	25.77	25.20	25.63	25.30	25.24	26.63
	35	25.19	24.61	25.03	24.94	24.89	26.32
	40	24.65	24.13	24.53	24.56	24.58	25.71
	45	24.22	23.72	24.11	24.17	24.21	25.16
	50	23.89	23.38	23.74	23.78	23.82	24.54
Test-image2	25	25.59	24.93	25.48	24.72	24.70	26.15
	30	24.95	24.29	24.81	24.49	24.50	25.75
	35	24.47	23.83	24.31	24.24	24.26	25.30
	40	24.06	23.48	23.92	23.94	24.00	24.72
	45	23.68	23.20	23.61	23.61	23.65	24.41
	50	23.44	22.97	23.34	23.39	23.46	24.07
Test-image3	25	24.77	24.12	24.37	23.21	23.25	24.92
	30	23.84	23.13	23.45	22.89	22.86	24.39
	35	23.08	22.35	22.74	22.54	22.43	23.83
	40	22.37	21.74	22.17	22.18	21.97	22.78
	45	21.95	21.25	21.70	21.81	21.72	22.47
	50	21.57	20.86	21.31	21.44	21.35	22.04
Bridge	25	26.23	25.69	26.03	24.53	24.67	26.50
	30	25.46	24.92	25.25	24.24	24.38	26.07
	35	24.86	24.33	24.64	23.91	24.03	25.48
	40	24.30	23.86	24.15	23.56	23.68	25.97
	45	23.90	23.48	23.93	23.20	23.29	24.53
	50	23.59	23.15	23.38	22.83	22.94	24.08
Boat	25	29.91	29.15	29.27	26.97	27.31	29.96
	30	29.12	28.29	28.43	26.52	26.81	29.42
	35	28.43	27.58	27.72	26.03	26.23	28.75
	40	27.74	26.99	27.12	25.53	25.60	28.32
	45	27.24	26.49	26.60	25.03	25.24	27.72
	50	26.78	26.05	26.15	24.53	24.60	26.94
Hill	25	29.85	29.20	29.27	27.60	27.43	29.71
	30	29.16	28.51	28.55	27.33	27.18	29.34
	35	28.56	27.94	27.96	27.02	26.91	28.88
	40	27.98	27.46	27.47	26.68	26.62	28.22
	45	27.57	27.05	27.05	26.31	26.26	27.89
	50	27.18	26.69	25.92	25.92	25.94	27.48

图 9 不同去噪方法去噪后结果图对比

Figure 9 The comparison of the denoising results of different methods

图 10 对图 9 中 Test-image1 去噪结果图的局部区域放大
Figure 10 The local region magnification of the Test-image1’s denoising results in Figure 9

图 11 对图 9 中 Bridge 去噪结果图的局部区域放大
Figure 11 The local region magnification of the Bridge’s denoising results in Figure 9

模型的预测结构上同时考虑利用“父子关系”和“兄弟关系”这两种状态关联指导 HMT 模型的系数预测,较传统的基于单状态关联的 HMT 模型取得了更高的系数预测精度,为进一步更加准确地挖掘图像经多尺度分解后的系数间关系提供了一种新的思路;进一步提出了一种基于所提出模型的图像去噪算法,与当前一些经典的去噪算法相比,在有效去除图像噪声的同时,更加有效地保留了图像中的边缘纹理信息.由于所提出的模型采用了“父子关系”和“兄弟关系”两种状态联合关联指导模型的系数预测,这样在对参数进行估计时会增量一定的计算量,这也是需要进一步优化的地方.

参考文献

1 Crouse M S, Nowak R D, Baraniuk R G. Wavelet-based statistical signal processing using hidden Markov models.

- IEEE Trans Signal Process, 1998, 46: 886–902
- 2 Portilla J, Strela V, Wainwright M J, et al. Image denoising using scale mixtures of Gaussians in the wavelet domain. IEEE Trans Image Process, 2003, 12: 1338–1351
- 3 Jin H Y, Jiao L C, Liu F. SAR image de-noising based on curvelet domain hidden Markov tree models. Chin J Comput, 2007, 30: 491–497 [金海燕, 焦李成, 刘芳. 基于 Curvelet 域隐马尔可夫树模型的 SAR 图像去噪. 计算机学报, 2007, 30: 491–497]
- 4 Hou B, Xu J, Liu F, et al. Image segmentation using second generation bandelet-domain hidden Markov tree models. Acta Autom Sin, 2009, 35: 498–504 [侯彪, 徐婧, 刘凤, 等. 基于第二代 Bandelet 域隐马尔可夫树模型的图像分割. 自动化学报, 2009, 35: 498–504]
- 5 Po D Y, Do M N. Directional multiscale modeling of images using the contourlet transform. IEEE Trans Image Process, 2006, 15: 1610–1620
- 6 Wang X H, Chen M Y, Song C M, et al. Contourlet HMT model with directional feature. Sci China Inf Sci, 2012, 55: 1563–1578 [王相海, 陈明莹, 宋传鸣, 等. 带方向特征的 Contourlet HMT 模型. 中国科学: 信息科学, 2013, 43: 626–643]
- 7 Wang X H, Ni P G, Su X, et al. The nonsubsampled Contourlet HMT model. Sci Sin Inform, 2013, 43: 1431–1444 [王相海, 倪培根, 苏欣, 等. 非下采样 Contourlet HMT 模型. 中国科学: 信息科学, 2013, 43: 1431–1444]
- 8 Chen P, Zhang Y, Jia Z, et al. Remote sensing image change detection based on NSCT-HMT model and its application. Sensors, 2017, 17: 1295–1310
- 9 Shahdoosti H R, Hazavei S M. Image denoising in dual contourlet domain using hidden Markov tree models. Digit Signal Process, 2017, 67: 17–29
- 10 Easley G, Labate D, Lim W Q. Sparse directional image representations using the discrete shearlet transform. Appl Comput Harmonic Anal, 2008, 25: 25–46
- 11 Guo K, Labate D. Optimally sparse multidimensional representation using shearlets. SIAM J Math Anal, 2007, 39: 298–318
- 12 Kutyniok G, Labate D. Resolution of the wavefront set using continuous shearlets. Trans American Math Soc, 2009, 361: 2719–2754
- 13 Kutyniok G, Labate D. Shearlets: Multiscale Analysis for Multivariate Data. Basel: Birkhauser, 2012
- 14 Easley G R, Labate D. Image Processing Using Shearlets. Boston: Birkhauser, 2012. 283–325
- 15 Bosse S, Chen Q, Siekmann M, et al. Shearlet-based reduced reference image quality assessment. In: Proceedings of IEEE International Conference on Image Processing, 2016. 2052–2056
- 16 Duval-Poo M A, Noceti N, Odone F, et al. Scale invariant and noise robust interest points with shearlets. IEEE Trans Image Process, 2017, 26: 2853–2867
- 17 Hou B, Zhang X, Bu X, et al. SAR image despeckling based on nonsubsampled shearlet transform. IEEE J Sel Top Appl Earth Observ Remote Sens, 2012, 5: 809–823
- 18 Jafari S, Ghofrani S. Using two coefficients modeling of nonsubsampled Shearlet transform for despeckling. J Appl Remote Sens, 2016, 10: 015002
- 19 Liu X, Mei W, Du H. Structure tensor and nonsubsampled shearlet transform based algorithm for CT and MRI image fusion. Neurocomputing, 2017, 235: 131–139
- 20 Dempster A P, Laird N M, Rubin D B. Maximum likelihood from incomplete data via the EM algorithm (with discussion). J Royal Stat Soc, 1977, 39: 1–38
- 21 Olea R A, Pawlowsky-Glahn V. Kolmogorov-Smirnov test for spatially correlated data. Stoch Environ Res Risk Assess, 2009, 23: 749–757
- 22 Maes F, Collignon A, Vandermeulen D, et al. Multimodality image registration by maximization of mutual information. IEEE Trans Med Imag, 1997, 16: 187–198
- 23 Lu Q W, Chen W F. Image segmentation based on mutual information. Chin J Comput, 2006, 29: 296–301 [吕庆文, 陈武凡. 基于互信息量的图像分割. 计算机学报, 2006, 29: 296–301]
- 24 Irum I, Shahid M A, Sharif M, et al. A review of image denoising methods. J Eng Sci Tech Rev, 2015, 8: 41–48
- 25 Gupta K, Gupta S K. Image denoising techniques - a review paper. Int J Innov Tech Exploring Eng, 2013, 2: 2278–3075
- 26 Shen H, Li X, Cheng Q, et al. Missing information reconstruction of remote sensing data: a technical review. IEEE Geosci Remote Sens Mag, 2015, 3: 61–85

- 27 Meng X, Li J, Shen H, et al. Pansharpening with a guided filter based on three-layer decomposition. *Sensors*, 2016, 16: 1068–1082
- 28 Shen H, Meng X, Zhang L. An integrated framework for the spatio-temporal-spectral fusion of remote sensing images. *IEEE Trans Geosci Remote Sens*, 2016, 54: 7135–7148
- 29 Li J, Yuan Q, Shen H, et al. Noise removal from hyperspectral image with joint spectral-spatial distributed sparse representation. *IEEE Trans Geosci Remote Sens*, 2016, 54: 5425–5439
- 30 Kumar G A, Kusagur A. Evaluation of image denoising techniques a performance perspective. In: *Proceedings of International Conference on Signal Processing*, 2016. 1836–1839
- 31 Shao Y H, Deng N Y, Chen W J. A proximal classifier with consistency. *Knowledge-Based Syst*, 2013, 49: 171–178
- 32 Huang Y F. Based on support vector machines image denoising and image quality assessment research. Dissertation for Master Degree. Shanxi: North University of China, 2013 [黄玉飞. 基于支持向量机的图像去噪和图像质量评价的研究. 硕士学位论文. 山西: 中北大学, 2013]
- 33 Gasparini M. Markov chain Monte Carlo in practice. *Technometrics*, 1999, 39: 338–338
- 34 Dabov K, Foi A, Egiazarian K. Image denoising with block-matching and 3D filtering. *Proc SPIE-IS&T Electronic Imaging*, 2006, 6064: 354–365
- 35 Pierazzo N, Morel J M, Facciolo G. Multi-scale DCT denoising. *Image Process On Line*, 2017, 7: 288–308

Image NSST-HMT model with associated multi-state coefficients

Xianghai WANG^{1,2}, Xiaoyang ZHAO¹, Yihuan ZHU¹, Ruoxi SONG^{1,2} & Chuanming SONG^{1*}

1. *School of Computer and Information Technology, Liaoning Normal University, Dalian 116029, China;*

2. *Liaoning Key Laboratory of Physical Geography and Geomatics, Liaoning Normal University, Dalian 116029, China*

* Corresponding author. E-mail: chmsong@lnnu.edu.cn

Abstract In recent years, due to its anisotropy, multi-directional capture characteristics, and translation invariance, the non-subsampled shearlet transform (NSST) has played an important stabilizing role in the process of image restoration. In this study, we analyze an image's NSST coefficients, including the relationship between coefficients in the same subband, the relationship between “father-son” coefficients, and the relationship between “brotherhood” coefficients in different subbands. The results reveal that the coefficients in the NSST subbands are sparse, and both “father-son relationship” and “brotherhood relationship” coefficients exhibit aggregation and transitivity. On this basis, a hidden Markov tree (HMT) model with associated multi-state coefficients (M-NSST-HMT) is proposed. This model estimates the reconstructed coefficients using “father-son relationship” and “brotherhood relationship” of the NSST subband coefficients as joint states of guiding the coefficients' transfer between subbands. In addition, the model integrates the reconstructed coefficients using the mutual information between these two associated states. Finally, the proposed model is applied to image denoising with favorable results. The results indicate that the proposed model can reveal the relationship of coefficients in NSST subbands and improve the prediction accuracy of coefficients more effectively than the traditional HMT model.

Keywords non-subsampled shearlet transform, Gaussian mixture model, hidden Markov tree model, multi-state coefficients association, image denoising, support vector machine

Xianghai WANG was born in 1965. He received a Ph.D. degree from Jilin University, Jilin, in 1999. Currently, he is a professor in the School of Computer and Information Technology at Liaoning Normal University, Dalian. He is a senior member of the China Computer Federation. His research interests include computer graphics and multimedia information processing.

Xiaoyang ZHAO was born in 1994. She received a B.E. degree in from the School of Computer and Information Technology at Liaoning Normal University, Dalian, in 2016. Currently, she is studying for an M.E. degree at Liaoning Normal University, Dalian. Her research interests include remote sensing image processing and deep learning.

Yihuan ZHU was born in 1992. He received an M.S. degree from the School of Computer and Information Technology at Liaoning Normal University, Dalian. He is currently a teacher at the Information College of Dalian Jiaotong University. His research interests include image denoising and image segmentation.

Chuanming SONG was born in 1980. He received a Ph.D. degree from the Computer and Information Technology College at Nanjing University. He is an associate professor at the School of Computer and Information Technology, Liaoning Normal University, Dalian, and is a member of the China Computer Federation. His research interests include image and video coding, and digital watermarking of multimedia.