

文章编号:1001-9081(2013)02-0468-04

doi:10.3724/SP.J.1087.2013.00468

结合熵主成分变换与优化方法的遥感图像融合

罗晓清*, 吴小俊

(江南大学 物联网工程学院, 江苏 无锡 214122)

(*通信作者电子邮箱 qingqingchong@126.com)

摘要:在遥感图像融合中,融合图像光谱失真是主要存在的问题,为此提出一种结合熵主成分变换与优化方法的图像融合方法。通过熵主成分变换将庞杂的多波段数据用尽可能少的波段表示出来,减少光谱维数,且从熵的角度出发完成投影变换保留更多的源波段信息。取第一熵主分量,与直方图匹配后的全色图像进行小波变换,分别获取低频和高频子图。对低频子图采用量子粒子群优化方法搜索线性加权的最优融合权值,对高频子图采用统计特征与统计模型相结合的方式完成融合,小波融合结果作为第一熵主分量。最后,熵主成分逆变换得到融合后的遥感图像。选用熵、交叉熵、标准差、梯度、相关系数和光谱扭曲度作为客观评价指标。实验结果表明,所提方法能够提升空间细节且避免融合图像光谱失真。

关键词:遥感图像融合; 主成分分析; 量子粒子群优化算法; 统计模型; 小波变换

中图分类号: TP751 文献标志码:A

Remote sensing image fusion combining entropy principal component transform and optimization methods

LUO Xiaoqing*, WU Xiaojun

(School of IoT Engineering, Jiangnan University, Wuxi Jiangsu 214122, China)

Abstract: In the process of remote sensing images fusion, the spectral distortion of fusion image is the main problem. To reduce distortion, an optimization image fusion method in combination with entropy component analysis transform was proposed. First, multi-band image was transformed to a small amount of bands by the entropy component analysis to reduce the spectral dimension. Projection transformation was finished from the perspective of entropy contribution so as to keep more information of source bands. Wavelet decomposition was done between the first entropy component and the high resolution image after histogram matching to get low frequency and high frequency subbands. For the fusion of low frequency subbands, Quantum-behaved Particle Swarm Optimization (QPSO) algorithm was applied to select the optimal weight coefficients. For the high frequency subbands, statistical feature and statistical model were used to perform fusion. The result of wavelet fusion was regarded as the first entropy principal component. The fusion image was obtained by wavelet and entropy component inverse transform. Entropy, cross entropy, standard deviation, grad, correlation coefficient and spectral distortion were selected as objective evaluation indexes. The experimental results show that the proposed method can enhance the spatial information and avoid spectral distortion.

Key words: remote sensing image fusion; Principal Component Analysis (PCA); Quantum-behaved Particle Swarm Optimization (QPSO) algorithm; statistical model; wavelet transform

0 引言

随着遥感技术的发展,涌现了光学、热红外和微波等大量不同卫星传感器对地观测的应用,如何有效地利用这些数据成为遥感领域的一个重要研究课题。多源图像融合技术是采用一定的算法将各影像数据中所含的信息优势或互补性有机地结合起来产生新影像数据的技术^[1],是解决这一问题的有效手段。本文主要探讨了高空间分辨率图像与低分辨率的多光谱图像的融合问题。多光谱图像含有丰富的光谱信息,全色图像具有较高的空间分辨率^[2]。将多光谱图像与全色图像进行融合,使融合后的图像在保留多光谱信息的同时尽量提高空间分辨率是我们追求的目标。

依据融合处理中信息抽象的程度,图像融合一般可以分为三个层次:像素级、特征级和决策级^[3]。许多遥感图像融合的研究都集中在像素级上。目前常用的像素级遥感图像融合方法包括色调、饱和度、亮度(Hue-Saturation-Intensity, HIS)变换^[4-5],Brovey 变换(Brovey Transform, BT)^[6],主成分分析(Principal Component Analysis, PCA)变换^[7-8]和离散小波变换(Discrete Wavelet Transform, DWT)^[9-10]等方法。Brovey 变换存在一定的光谱扭曲,且没有解决光谱范围不一致的影像融合问题;HIS 方法扭曲了原始的光谱特征,融合结果存在光谱退化现象,且仅局限于3波段融合;利用PCA 变换无波段数限制,且数据信息量几乎没有损失,但融合结果易失去原有物理特性;DWT 融合具有多分辨率的特性,由于它

收稿日期:2012-08-02;修回日期:2012-08-25。

基金项目:国家自然科学基金资助项目(60973094, 61103128);教育部科技研究重大项目(311024);江南大学创新团队研究计划项目(JNIRT0702);新进科研人员启动经费资助项目(1255210232110940);111 高等学校学科创新引智计划项目(B12018)。

作者简介:罗晓清(1980-),女,江西南昌人,讲师,博士,主要研究方向:模式识别、图像处理;吴小俊(1967-),男,江苏丹阳人,教授,博士,主要研究方向:模式识别、图像处理、计算机视觉。

舍弃了高分辨率图像的低频分量,故很容易出现分块效应。为了克服以上缺点,同时满足人眼视觉特性和参数统计性能这两个方面的应用要求,本文提出了一种结合熵主成分分析与优化方法的遥感图像融合方法(Entropy Component Analysis Optimization Method,ECAOM)。

ECAOM 将主成分变换与小波变换相结合,在降低光谱维数的基础上进行小波变换融合更有利于空间分辨率的提升和光谱信息的保持。主成分变换的目的是在数据降维的同时,尽可能多地包含多光谱图像的信息。Jenssen^[11]的研究发现,核主成分分析的特征值和特征向量与原始图像的 Renyi 熵有着直接的关联,以对 Renyi 熵的贡献为判决标准选取第一主成分,能够更好地实现原始图像信息熵的保留。受此启发,线性条件下的基于熵的主成分分析(Entropy Component Analysis, ECA)被提出。光谱图像经变换得到第一熵主成分,在降低光谱维数的同时可以更好地保留原始波段的熵信息。使用小波变换对第一熵主成分与全色图像进行分解,获取高频和低频子图。对于低频部分,采用权重系数法。有别于传统的加权平均或人工选择融合权值,通过量子粒子群优化(Quantum-behaved Particle Swarm Optimization, QPSO)算法^[12]自适应地搜索最优融合权值。为了使低频部分尽可能多地包含光谱信息与空间信息,偏差指数与信息熵^[13]被选为目标函数。高频部分采用区域与像素相结合融合策略,可有效约束错误高频信息的引入。差异大的区域采用基于统计特征的融合方式,差异小的区域针对区域内的每个像素点建立统计模型寻找最优融合权重。最后经小波逆变换与 ECA 逆变换得到最终融合结果。

1 ECA 变换

设训练样本分别为 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N$ ($\mathbf{x}_i \in \mathbb{R}^{d \times 1}$), 记为: $X = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]$, X 为 $d \times N$ 的矩阵。

在核空间中采用 Parzen 窗密度估计方法样本的密度函数为: $\hat{p}(\mathbf{x}) = \frac{1}{N} \sum_{\mathbf{x}_t \in B} k(\mathbf{x}, \mathbf{x}_t)$ 。其中, $k(\mathbf{x}, \mathbf{x}_t)$ 的物理意义是用核函数 $k(\mathbf{x}, \mathbf{x}_t)$ 的值代替 \mathbf{x} 和 \mathbf{x}_t 的内积。因此,为了在原样本空间中估计样本的密度函数,则有: $\hat{p}(\mathbf{x}) = \frac{1}{N} \sum_{\mathbf{x}_t \in B} \mathbf{x}^T \mathbf{x}_t$; Renyi 二次熵为: $H(P) = -\ln \int p^2(\mathbf{x}) d\mathbf{x}$, 令 $V(p) = \int p^2(\mathbf{x}) d\mathbf{x}$ 。

为了估计 $H(p)$ 与 $V(p)$, 可采用 Parzen 窗密度估计方法:

$$\hat{V}(p) = \frac{1}{N} \sum_{\mathbf{x}_t \in B} \hat{p}(\mathbf{x}_t) = \frac{1}{N} \sum_{\mathbf{x}_t \in B} \frac{1}{N} \sum_{\mathbf{x}_{t'} \in B} \mathbf{x}_t^T \mathbf{x}_{t'} = \frac{1}{N^2} \mathbf{1}^T \mathbf{G} \mathbf{1} \quad (1)$$

其中: $\mathbf{1}$ 代表 $N \times 1$ 的单位列向量, $\mathbf{G} = \mathbf{X}^T \mathbf{X}$ 。

对 \mathbf{G} 进行特征分解: $\mathbf{G} = \mathbf{U} \boldsymbol{\Sigma} \mathbf{U}^T$ 。

$$\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_N], \boldsymbol{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_N) \quad (2)$$

$$\hat{V}(p) = \frac{1}{N^2} \sum_{i=1}^N (\sqrt{\sigma_i} \mathbf{u}_i^T \mathbf{1})^2 \quad (3)$$

ECA 的投影变换公式为: $\Phi_{ECA} = \boldsymbol{\Sigma}_k^{\frac{1}{2}} \mathbf{U}_k^T$ 。

由上述分析可知, σ_i 与 \mathbf{u}_i 决定了 Renyi 熵的大小。以对熵贡献大的特征分量作为投影变换轴,能够在降维的同时尽可能地保留原始数据信息。ECA 变换实现了线性条件下的基于熵最大的主成分变换,我们简称为熵主成分分析(ECA)。

下面讨论 ECA 和 PCA 的关系: $\mathbf{G} \mathbf{u}_i = \sigma_i \mathbf{u}_i$, 即

$$\begin{cases} \mathbf{X}^T \mathbf{X} \mathbf{u}_i = \sigma_i \mathbf{u}_i \\ \mathbf{X} \mathbf{X}^T \mathbf{X} \mathbf{u}_i = \sigma_i \mathbf{X} \mathbf{u}_i \end{cases} \quad (4)$$

如果 $d < N$, 那么 $r = \text{rank}\left(\frac{1}{N} \mathbf{X} \mathbf{X}^T\right) = \text{rank}(\mathbf{X}^T \mathbf{X}) \leq d$ 。

令 $\mathbf{v}_i = \mathbf{X} \mathbf{u}_i$, 则 \mathbf{v}_i 即为 PCA 的特征向量。

以对熵贡献最大为选择机制,则选取 $\sqrt{\sigma_i} \mathbf{u}_i^T$ 最大的特征分量作为第一投影变换轴。

2 QPSO 用于低频融合

源图像经过平稳小波分解后分为低频和高频两部分,对最后一个分解层的低频子带采用线性加权方法融合。由文献[12]可知 QPSO 在全局寻优能力方面具有其他优化算法无可比拟的优点。本文将 QPSO 用于低频融合系数的优化搜索中,根据遥感图像内容自适应地选取加权系数。

QPSO 算法是基于种群的进化搜索技术,不仅参数个数少,并且在搜索能力上较优。

在 QPSO 中,粒子群按照下面的三个公式移动:

$$mbest = \frac{1}{M} \sum_{i=1}^M P_i = \left(\frac{1}{M} \sum_{i=1}^M P_{i1}, \frac{1}{M} \sum_{i=1}^M P_{i2}, \dots, \frac{1}{M} \sum_{i=1}^M P_{ij} \right) \quad (5)$$

$$PG_{ij} = f * P_{ij} + (1-f) * Pg_j; f = \text{rand} \quad (6)$$

$$x_{ij} = PG_{ij} \pm \alpha * |mbest_j - x_{ij}| * \ln(1/u); u = \text{rand} \quad (7)$$

其中: $mbest$ 是粒子群 $pbest$ 的中间位置; PG_{ij} 为 P_{ij} 和 Pg_j 之间的随机点; α 为 QPSO 的收缩扩张系数,它是 QPSO 收敛的一个重要的参数; $MAXITER$ 是迭代的最大次数。在这里,令 $\alpha = (1.0 - 0.5) \times (MAXITER - T) / MAXITER + 0.5$ 。

QPSO 的算法流程如图 1 所示。

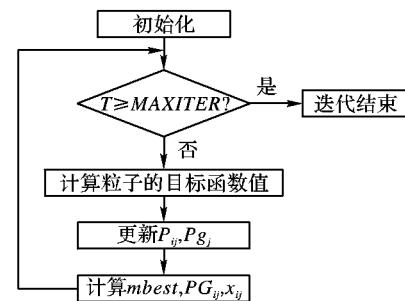


图 1 QPSO 算法流程

基于优化算法的低频融合,以线性加权值作为需要优化的决策变量,通过进化迭代寻找到最优权重值。遥感图像融合的评价指标是进行目标优化的基础,其设计的优劣程度决定了最终目标优化的性能。本文以偏差指数与信息熵作为目标函数(目标函数 = 信息熵 - 偏差指数),种群大小为 30,最大迭代次数为 200。

3 基于统计特征与统计建模的高频融合方法

遥感影像的边缘、线和区域等细节信息都包含在高频分量,该部分小波系数的处理方式直接影响着融合效果。本文的融合规则如下:

- 1) 多光谱第一熵主成分 g 与全色图像 f 分别进行小波分解;针对高频子图划分窗体 $M \times N$ 。
- 2) 所有窗体拉伸为 $(M \times N, 1)$ 的列向量,通过 ECA 变换降为三维。
- 3) 降维后 g 与 f 的窗体向量可分别记为 g_e 与 f_e ($3 \times 1, e$ 指窗体标号)。

4) 对应窗体, 按照下面公式统计它们之间的相似性 $S_{gf_e}^{[14]}$ 。

$$S_{gf_e} = 1 - \frac{|g_e - f_e|}{|g_e| + |f_e|} \quad (8)$$

5) 根据窗体的相似性, 选取高频子带匹配度阈值(这里取 $\alpha = 0.6$), 设置高频融合策略:

当 $S_{gf_e} > \alpha$ 时, 说明窗体整体差异较小, 针对窗体中的每个像素点采用统计建模的方式选取融合系数更为合理。

当 $S_{gf_e} \leq \alpha$ 时, 说明窗体整体差异大, 选取窗体梯度较大的高频信息作为融合结果。

6) 统计建模融合方式: 窗体中的每个像素逐点开窗, 作为分析窗口 W 。采用期望图像局部方差最大作为融合系数的估计依据^[15], 设置约束条件。具体过程如下:

$x = [f, g]^T$ 是全色与光谱图像经小波分解后的小波系数, $\beta = [\beta^f, \beta^g]^T$ 为全色与光谱图像的融合系数, 采用线性融合模型得到的期望光谱融合图像 \hat{g} 为: $\hat{g} = \beta^T x$ 。

采用期望图像局部方差最大作为融合系数的估计依据, 则融合系数应使下式最大:

$$\max J(\beta) = \beta^T \Sigma_x \beta \quad (9)$$

$$\Sigma_g = \beta^T \Sigma_x \beta, \Sigma_x = \begin{bmatrix} \Sigma_f & \Sigma_{f,g} \\ \Sigma_{f,g} & \Sigma_g \end{bmatrix} \quad (10)$$

一般希望融合系数矢量为单位矢量, 即 $\mu_1(\beta) = \beta^T \beta - 1 = 0$; 而且为了保证极性的一致性, 符号约束为: $\text{sign}(\beta) = \text{sign}([\Sigma_{f,g}, \Sigma_g]^T)$ 。

$$\{\beta^T \Sigma_x = \lambda \beta^T, \beta^T \beta = 1 \quad (11)$$

$$\hat{\beta} = \text{abs}(v) \otimes \text{sign}([\Sigma_{f,g}, \Sigma_g]^T)$$

其中 v 为 Σ_x 的最大特征值对应的特征向量。

高频融合策略:

若 $\alpha \leq 0.6$, 基于窗体统计特征融合:

$$F_i = \begin{cases} g_i, & \text{grad}_{g_i} > \text{grad}_{f_i} \\ f_i, & \text{grad}_{g_i} \leq \text{grad}_{f_i} \end{cases} \quad (12)$$

若 $\alpha > 0.6$, 基于窗体内的每个像素点统计建模融合:

$$F_{i(x,y)} = \omega_{g_{i(x,y)}} \times g_{i(x,y)} + \omega_{f_{i(x,y)}} \times f_{i(x,y)} \quad (13)$$

4 算法实现

本文方法框架如图 2 所示。

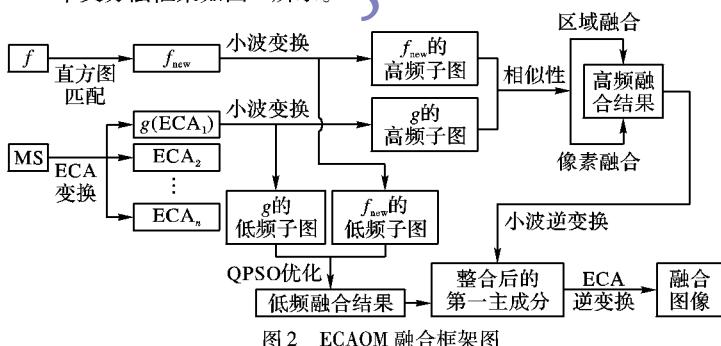


图 2 ECAOM 融合框架图

具体描述如下:

1) 将多光谱图像 MS 通过 ECA 变换, 获取第一熵主成分 g ; 全色图像 f 与 g 进行直方图匹配, 得到新的全色图像 f_{new} 。

2) 将全色图像 f_{new} 与 g 进行小波变换, 得到各自的低频与高频子图。

3) 低频子图以信息熵与偏差指数作为目标函数, 通过 QPSO 搜索最优权值。

4) 高频子图结合统计特征与统计建模方法设计融合策略。

5) 通过逆小波变换获得融合后的第一熵主成分, 最后经 ECA 变换得到最终的遥感图像融合结果。

5 实验结果与分析

为了检验本文算法的有效性, 以美国 IKONOS 公司拍摄的大小为 256×256 像素的天鹅湖卫星图片为例, 通过与传统方法相比较检测算法的融合效果。相比较的遥感融合算法主要有: HIS 方法、PCA 方法、DWT 方法、文献[15]的统计建模融合方法(Traditional Statistical Fusion Model, TSFM)以及基于 PCA 变换的本文方法(PCAOM, 即本文方法的 ECA 部分用 PCA 替代)。采用六种评价指标对融合图像进行客观的评价^[13,16], 它们分别是反映融合图像空间频率的熵(Entropy, E)、融合图像和 PAN 图像的交叉熵(Cross entropy, C)、标准差(Standard Deviation, SD)、平均梯度(Grad, G), 测量光谱保持性能的光谱扭曲(Spectral Distortion, SPD)和相关系数(Correlation Coefficient, COR)。

图 3(a)为全色图像, 分辨率在 1 m 左右, 实验中为了体现算法的有效性, 取分辨率 4 m 左右的多光谱图像如图 3(b)所示。图 3(c)为经过 HIS 变换的融合图像, 图 3(d)为经过 PCA 变换的融合图像, 图 3(e)是经过 DWT 的融合图像, 图 3(f)为 TSFM 方法获得的融合图像, 图 3(g)是本文方法在 PCA 变换下的融合图像, 图 3(h)为采用本文方法的融合图像。在实验中窗体大小均为 5×5 , 小波分解为 3 层, 小波函数为 sym4。

观察图 3 所示的融合结果可以发现, HIS 方法虽然能够提升图像的空间分辨率, 但其导致了严重的颜色失真, 光谱信息的保持能力较差; PCA 方法也存在颜色失真的问题, 但是失真程度比 HIS 方法小; 其他方法的融合图像相比前两类结果, 颜色恰当且细节较清晰, 意味着空间分辨率有所提高且光谱信息有所保持。当然, 由于 PCAOM/ECAOM 方法有效地结合了主成分变换与小波变换, 且引入优化机制以及区域与像素相结合的融合策略, 直观上看, 它们的融合效果更优, 不仅能提升图像的空间分辨率, 丰富图像细节信息, 同时还能较好地保留原始多光谱图像的光谱信息。

除了主观辨识以外, 表 1 给出了客观的评价实验结果, 分波段分别统计评价指标。E 表示融合图像获取原始图像信息的能力, 由于 ECA 算法的引入, 以熵贡献最大的投影轴作为第一变换轴完成融合, 本文算法融合图像信息熵取值最大。C 反映了两幅图像对应像素的差异, 越小越好: HIS 方法与 PCA 方法的 C 值过大, 其他方法数值差异较小, 本文方法取值最小。SD 用于统计融合图像的方差, 由于 TSFM、PCAOM 和 ECAOM 方法都以方差作为目标函数, 因此它们保留了较大的方差值。G 指梯度, 反映了图像的清晰程度, PCA 方法的融合图像梯度最弱, 本文方法梯度最强。以上指标刻画了融合结果的空间分辨率, PCA 方法提升幅度最小, 表现为图像结果较模糊。融合方法提升空间分辨率能力由小到大的次序为: PCA、HIS、DWT、TSFM、PCAOM、ECAOM。同时希望能够尽可能地保持原有的光谱特性。COR 表示了图像之间的相关程度, 越大说明光谱的保持能力越好; SPD 反映了光谱扭曲, 越小越好。评价结果显示各方法光谱保持能力由弱到强为: HIS、PCA、DWT、TSFM、PCAOM、ECAOM。由此可知, 本文方法较好地提升了空间分辨率且保持了原有的光谱信息。

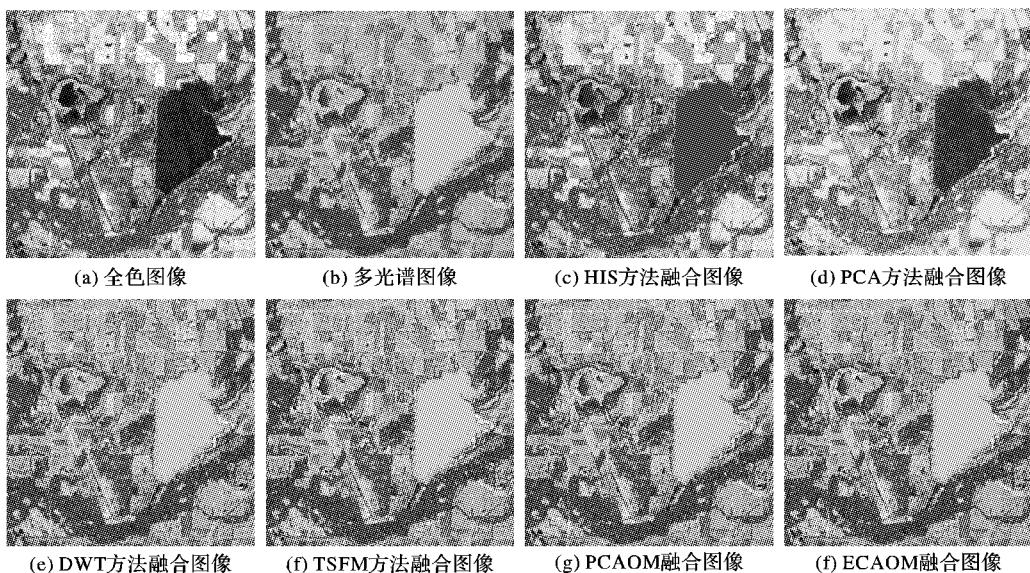


图3 源图像以及用各种方法获得的融合图像

表1 图3中融合图像的质量评价

波段	融合方法	E	C	SD	G	COR	SPD
XS1	IHS	4.8216	0.5008	84.2869	20.4889	0.9108	55.3213
	PCA	4.9061	0.5263	75.4200	19.3245	0.9336	33.3210
	DWT	5.2582	0.0263	58.8573	30.2313	0.9541	13.0431
	TSFM($T=0.1$)	5.2761	0.0248	60.6811	35.1064	0.9745	9.9571
	PCAOM	5.2748	0.0195	60.3010	36.6981	0.9813	8.8378
	ECAOM	5.2813	0.0182	60.5372	36.8923	0.9825	8.7956
XS2	IHS	4.7951	0.7322	30.5551	17.9701	0.7624	55.3213
	PCA	5.2783	0.7421	49.9900	16.3474	0.5917	35.4587
	DWT	5.2377	0.0137	59.0430	30.7744	0.9474	13.8497
	TSFM($T=0.99$)	5.2617	0.0188	61.0229	35.3313	0.9745	9.9567
	PCAOM	5.2795	0.0153	60.7231	36.4788	0.9803	8.8505
	ECAOM	5.2803	0.0145	61.0302	36.8712	0.9812	8.8002
XS3	IHS	4.8254	0.4714	31.4192	18.1017	0.7741	55.3213
	PCA	5.2921	0.4973	50.8900	17.3443	0.6592	34.3545
	DWT	5.3244	0.0386	60.1286	30.9171	0.9518	13.5702
	TSFM($T=0.98$)	5.3518	0.0379	62.0062	35.4612	0.9751	10.0217
	PCAOM	5.3571	0.0312	61.6144	35.9843	0.9809	8.8562
	ECAOM	5.3654	0.0298	61.9254	36.1324	0.9823	8.7121

6 结语

遥感图像融合通常在低空间分辨率的多光谱图像和高空间分辨率的全色图像之间进行,融合方法应兼顾空间分辨率的提升和多光谱的保持。基于此目的,本文提出了一种结合ECA变换与优化方法的遥感图像融合手段。光谱图像的多波段经ECA变换,以熵贡献最大投影轴为第一变换轴,在降维的同时尽可能地保留更多的图像信息。针对熵主成分与全色图像进行小波分解。低频子图以信息熵与偏差指数为目标函数,自适应地选取融合权值,较好地保留了光谱特性;高频子图根据对应窗体的相似度,分别设置基于窗体梯度的区域融合策略以及基于统计模型的像素点融合策略。实验结果表明,相对于其他方法,本文方法无论是主观评价还是客观评价,融合图像在空间细节信息的表现能力和光谱特性的保持方面都有更好的效果。融合算法的实时性以及算法中有关窗体大小、小波分解层数以及相似度阈值的自适应选择,是后续研究的重点。

参考文献:

- [1] YANG S, WANG M, JIAO L. Fusion of multispectral and panchromatic images based on support value transform and adaptive principal component analysis [J]. Information Fusion, 2012, 13(3): 177–184.
- [2] YANG S, WANG M, JIAO L. Contourlet hidden Markov tree and clarity-saliency driven PCNN based remote sensing images fusion [J]. Applied Soft Computing, 2012, 12(1): 228–237.
- [3] LUO X, ZHANG J, DAI Q. A regional image fusion based on similarity characteristics [J]. Signal Processing, 2012, 92(5): 1268–1280.
- [4] TU T-M, SU S-C, SHYU H-C, et al. Efficient intensity-hue-saturation-based image fusion with saturation compensation [J]. Optical Engineering, 2001, 40(5): 720–728.
- [5] CHU H, ZHU W. Fusion of IKONOS satellite imagery using IHS transform and local variation [J]. IEEE Geoscience and Remote Sensing Letters, 2008, 5(4): 653–657.

(下转第475页)

对所需时间明显减少。表2显示了用本文算法和其他算法对face进行超分辨率所需时间的对比,由此可以进一步验证本文算法在时间上具有很大的优势。

表2 不同算法对face进行超分辨率的计算时间比较 s

算法	训练字典时间	总时间
Yang 算法 ^[11]	21 360. 730	22 356. 290
本文算法	461. 161	468. 662

4 结语

针对单张彩色图像的超分辨率重建问题,本文在稀疏表示的超分辨率模型基础上,提出利用金字塔结构增强用低分辨率自身训练高低分辨率字典的能力;同时结合RGB颜色通道的稀疏表示方法,增强了对彩色图像块的信息提取。实验结果表明,本文所提出的单张彩色图像的超分辨率方法能够获得更好的效果。此外,本文不需要额外的训练图像,一方面提高了对不同图像类型的自适应性,另一方面也加快了字典训练速度。如何利用图像自身获得更强的稀疏表示能力将是下一步的研究方向。

参考文献:

- [1] KER S, KANADE T. Limits on super-resolution and how to break them [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(9): 1167–1183.
- [2] PARK S C, PARK M K, KANG M G. Super-resolution image construction: a technical overview [J]. IEEE Signal Processing Magazine, 2003, 20(3): 21–36.
- [3] 曾强宇, 何小海, 陈为龙. 基于改进量化约束集的压缩视频超分辨率重建算法[J]. 计算机应用, 2011, 31(1): 151–153, 166.
- [4] KEYS R C. Cubic convolution interpolation for digital image processing [J]. IEEE Transactions on Acoustics, Speech, and Signal Processing, 1981, 29(6): 1153–1160.
- [5] MARQUINA A, OSHER S J. Image super-resolution by TV-regularization and Bregman iteration [J]. Journal of Scientific Computing, 2008, 37(3): 367–382.
- [6] DAI S Y, HAN M, XU W, et al. Soft edge smoothness prior for alpha channel super resolution [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, DC: IEEE Computer Society, 2007: 1–8.
- [7] SUN J, XU Z B, SHUM H-Y. Image super-resolution using gradient profile prior [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, DC: IEEE Computer Society, 2008: 1–8.
- [8] FREEMAN W T, PASZTOR E C, CARMICHAEL O T. Learning low-level vision [J]. International Journal of Computer Vision, 2000, 40(1): 25–47.
- [9] ELAD M, DATSENKO D. Example-based regularization deployed to super-resolution reconstruction of single image [J]. The Computer Journal, 2007, 52(1): 15–30.
- [10] CHANG H, YEUNG D-Y, XIONG Y-M. Super-resolution through neighbor embedding [C]// Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, DC: IEEE Computer Society, 2004. 275–282.
- [11] YANG J C, WRIGHT J, HUANG T S, et al. Image super-resolution via sparse representation [J]. IEEE Transactions on Image Processing, 2010, 19(11): 2861–2873.
- [12] MAIRAL J, ELAD M, SAPIRO G. Sparse representation for color image restoration [J]. IEEE Transactions on Image Processing, 2008, 17(1): 53–69.
- [13] PATHY C, REZAIIFAR R, KRISHNAPRASAD P S. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition [C]// Proceedings of the 27th Asilomar Conference on Signals, Systems and Computers. Piscataway: IEEE, 1993: 40–44.
- [14] AHARON M, ELAD M, BRUCKSTEIN A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311–4322.
- [15] CHEN S S, DONOHO D L, SAUNDERS M A. Atomic decomposition by basis pursuit [J]. SIAM Journal on Scientific Computing, 1998, 20(1): 33–61.

(上接第471页)

- [6] CHAVEZ P S, Jr, SIDES S C, ANDERSON J A. Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT panchromatic [J]. Photogrammetric Engineering and Remote Sensing, 1991, 57(3): 295–303.
- [7] YÉSOU H, BESNUS Y, POLET Y. Extraction of spectral information from Landsat TM data and merger with SPOT panchromatic imagery—a contribution to the study of geological structures [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 1993, 48(5): 23–26.
- [8] CHOI J, YU K, KIM Y. A new adaptive component-substitution-based satellite image fusion by using partial replacement [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(1): 295–309.
- [9] LI SHUTAO, KWOK J T, WANG YAONAN. Using the discrete wavelet frame transform to merge Landsat TM and SPOT panchromatic images [J]. Information Fusion, 2002, 3(1): 17–23.
- [10] CHEN SHAO-SHUI, SU HONGBO, ZHANG RENHUA, et al. Fusing remote sensing images using à trous wavelet transform and empirical mode decomposition [J]. Pattern Recognition Letters, 2008, 29(3): 330–342.
- [11] JENSSSEN R. Kernel entropy component analysis [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 32(5): 847–860.
- [12] SUN JUN, XU WENBO, FENG BIN. A global search strategy of quantum-behaved particle swarm optimization [C]// Proceedings of IEEE Conference on Cybernetics and Intelligent Systems. Piscataway: IEEE, 2004: 111–116.
- [13] WEI X Y, XU H P, LI J W, et al. Comparison of diverse approaches for synthetic aperture radar images pixel fusion under different precision registration [J]. IET Image Processing, 2011, 5(8): 661–670.
- [14] THUNG K-H, PARAMESRAN R, LIM C-L. Content-based image quality metric using similarity measure of moment vectors [J]. Pattern Recognition, 2012, 45(6): 2193–2204.
- [15] 余二勇, 王润生, 徐学文. 基于统计模型的遥感图像多分辨率融合方法[J]. 电子学报, 2008, 36(3): 490–493.
- [16] LUO XIAOQING, WU XIAOJUN. New metric of image fusion based on region similarity [J]. Optical Engineering, 2010, 49(4): 047006-1–047006-13.