

基于相关向量机的高光谱图像超分辨率算法

王晓飞^{1,2} 阎秋静² 张钧萍³ 汪爱华^{1,4}

¹北京二十一世纪科技发展有限公司, 北京 100096

²黑龙江大学黑龙江省高校电子工程重点实验室, 黑龙江 哈尔滨 150080

³哈尔滨工业大学信息工程系, 黑龙江 哈尔滨 150001; ⁴二十一世纪空间技术应用股份有限公司, 北京 100096

摘要 为了融合多光谱图像空间信息和高光谱图像光谱信息, 进而提高高光谱图像的空间分辨率, 提出了一种基于相关向量机(RVM)的高光谱图像超分辨率算法。介绍了多光谱与高光谱图像通过融合获得超分辨率图像的算法原理, 对 RVM 回归原理进行分析介绍。结合 RVM 在回归分析上的优势, 提出了利用 RVM 建立多光谱图像与高光谱图像之间的内在的空间及光谱对应关系, 通过融合两种图像的信息来提高图像的分辨率。实验结果表明: 归一化均方根误差小于 0.001, 光谱角误差小于 0.02, 较 Price、Elbakary 法有较大提升。本文提出的方法对高光谱图像重建具有良好的效果, 可为分类、目标检测和识别提供更合适的数据源。

关键词 遥感; 高光谱; 超分辨率; 相关向量机; 信息融合

中图分类号 TP751.1 文献标识码 A doi: 10.3788/CJL201441.s114001

Super-Resolution Reconstruction Algorithm Based on Relevance Vector Machine for Hyperspectral Image

Wang Xiaofei^{1,2} Yan Qiuqing² Zhang Junping³ Wang Aihua^{1,4}

¹ Beijing Twenty-First Century Science & Technology Development Co. Ltd, Beijing 100096, China

² Key Laboratory of Senior-Education for Electronic Engineering, Heilongjiang University, Harbin, Heilongjiang 150080, China

³ Department of Information Engineering, Harbin Institute of Technology, Harbin, Heilongjiang 150001, China

⁴ Twenty First Century Aerospace Technology Co. Ltd, Beijing 100096, China

Abstract In order to improve the space resolution of hyper-spectral image by fusing the spatial information of multispectral images and the spectral information of hyperspectral images, a hyperspectral image super-resolution algorithm based on relevance vector machine (RVM) is proposed. A brief introduction of the principle of the Price method which fuses multispectral and hyperspectral images to get the super-resolution image is given, and the RVM linear regression is introduced. Combining with the advantages of RVM in regression analysis, a resolution enhancement by revealing the correspondence of the spatial and spectral information is gotten. The experiment results show that the normalized root-mean-square (RMS) is lower than 0.001 and the spectral angel error is lower than 0.02, which gets a great improvement compared with the results of the Price method and the Elbakary method. The method proposed has a significant result in hyperspectral image reconstruction, which provides a much properer data source for classification, object detection and recognition.

Key words remote sensing hyperspectral; super-resolution; relevance vector machine; information fusion

OCIS codes 100.2000; 100.3020; 100.6640

1 引言

高光谱遥感是在测谱学基础上逐渐发展起来的

新型遥感技术,除了空间图像信息外,其所具有的精
细光谱信息,克服了宽波段遥感探测的局限,被广泛

收稿日期: 2013-09-24; 收到修改稿日期: 2013-11-10

基金项目: 国家自然科学基金(61271348)、北京市博士后资助、北京市科技计划(Z121100006112032)、黑龙江省高校电子工程重点实验室项目

作者简介: 王晓飞(1977—),男,博士,副教授,主要从事高光谱图像处理及应用方面的研究。

E-mail: nk_wxf@hlju.edu.cn

应用于多种领域,成为对地观测最重要的信息源之一^[1]。由于在设计遥感成像装置时,随着传感器接收的波段宽度变窄,要保持较高的图像信噪比,必须增大瞬时视场(IFOV)来获取更多的光能^[2],因此导致图像的空间分辨率随着光谱分辨率的增高而下降,使得高光谱图像的空间分辨率相对较低,给进一步应用,如特定目标的检测识别带来一系列的问题。

显然提高采样平面的单位成像单元数量和性能是一个直接获取高分辨率图像的办法,不过硬件的发展速度永远赶不上人的需求。所以科研人员就开始了图像超分辨率算法的研究,试图通过信号处理技术来改善硬件上的不足。其算法大致可分为三类:1)单幅图像的超分辨率算法;2)序列/多时相低分辨率图像的超分辨重建算法;3)加入其它图像或非图像信息的超分辨率算法。

近年来针对超分辨的研究文献主要集中在基于最大似然和最大后验概率估计的参数估计类方法上^[3]。因此在研究增强高光谱图像分辨率时,这些算法在高光谱图像中的应用也有很多学者给予了关注。还有一些算法是应用于增强多光谱图像的分辨率的,也可以推广到高光谱图像上,如常见的强度色调饱和度(IHS)和主成份分析(PCA)变换法等。另外,相比高光谱图像分辨率而言,多光谱图像空间分辨率更高些,而且在成像原理上较全色图像更接近高光谱图像,有人利用这一特点,提出了很多利用多光谱图像与高光谱图像信息融合的方式实现分辨率增强的算法。如 Winter 等^[4]从物理意义上讨论了利用多光谱图像对高光谱图像进行分辨率增强的可行性。而 Gomez 等^[5]利用小波分析技术,将多光谱图像的空间信息融合到高光谱数据中。在此基础上,张易凡等^[6]提出了基于三维(3D)小波变换的多光谱图像与高光谱图像的融合算法,最终得到的图像具有多光谱的空间分辨率和高光谱图像的光谱分辨率。这些算法都是通过将空间细节信息注入到多,高光谱图像中来提高图像的空间分辨率。

分辨率增强算法中新近出现了一个研究方向,即基于学习和模式识别的方法。该方法对训练数据中的低分辨率和高分辨率图像进行学习,从而得到二者间的对应模式,其中全色与多,高光谱图像融合的算法比较有代表的有 Price 算法^[7]。Elbakary 等^[8]通过分窗口的方式对 Price 的算法进行改进,对每一个窗口应用 Price 算法对图像进行分辨率增强,最终取得了不错的分辨率增强的效果。国内的如尹雯等^[9]提出了一种基于稀疏表示的遥感图像融

合方法,通过学习建立全色图像和多光谱图像之间的关系,从而得到高空间分辨率的多光谱图像。这类方法不仅可以融入机器学习与模式识别的成果,还能通过选择模式有针对性地对图像目标进行恢复,具有计算量少,能充分利用先验信息等诸多优点,目前这一领域还是很活跃的,不断地有新的算法出现。

2 Price 算法

Price 提出的使用高空间分辨率全色图像对(多光谱图像 TM 图像)进行超分辨率算法分两步:

1)对全色图像进行空间平滑,利用下采样将分辨率降到与多光谱图像同样大小,利用得到的降分辨率的全色图像与低分辨率多光谱图像对下面模型进行求解:

$$X_{\text{band}_i} = a_i Y_{\text{avg}} + b_i, \quad (1)$$

式中 X_{band_i} 代表低分辨率多光谱图像第 i 个波段的像素值, Y_{avg} 代表全色图像降分辨率后的像素值, a_i , b_i 代表待求系数。文献是通过最小均方回归分析来求解参数 a_i 和 b_i 的;

2)对下面公式求解:

$$Z_{\text{band}_i}^0 = a_i Y_{\text{HR}} + b_i, \quad (2)$$

式中 Y_{HR} 代表高空间分辨率全色图像。

这里的 $Z_{\text{band}_i}^0$ 还不能作为最终的增强结果,而需要进行修正,即利用修正因子 $f = Z_{\text{band}_i}^0 / Z_{\text{band}_i(\text{avg})}^0$, 来保证其均值等于其对应的低分辨率图像的像素值。即需要按下式再进行修正计算才能得到最终的分辨率增强后的图像。

$$Z_{\text{band}_i} = \frac{Z_{\text{band}_i}^0 \cdot X_{\text{band}_i}}{Z_{\text{band}_i(\text{avg})}^0}, \quad (3)$$

式中 Z_{band_i} 是最终的分辨率增强的结果, $Z_{\text{band}_i(\text{avg})}^0$ 是通过式 $Z_{\text{band}_i(\text{avg})}^0 = a_i Y_{\text{avg}} + b_i$ 计算的结果。

从公式可以看出,这种算法核心都是将全色图像的空间分辨率降低到与多光谱的同样大小来生成回归问题的训练样本,并根据训练样本建立起多光谱图像的每个波段图像与全色图像之间的映射关系,然后利用原始的全色图像按照对应的映射关系生成多光谱图像每个波段,最终经过简单的处理后得到高空间分辨率的多光谱图像。这种映射关系的生成,需要每个波段图像与全色图像之间具有较强的相关性。不过遗憾的是,当参与成像的光谱范围扩大,并且波段数大幅增加时,即从多光谱发展到高光谱图像时,这种相关性就变得很弱了。

相比全色图像,多光谱图像各波段与高光谱图像

的各波段间的相关性更强一些。由于多光谱图像也往往覆盖了高光谱图像的大部分波段,如 TM 的可见蓝光(0.45~0.52 μm)、可见绿光(0.52~0.60 μm)、可见红光(0.63~0.69 μm)、近红外光(0.76~0.90 μm)、中红外光(1.55~1.75 μm)及(2.08~2.35 μm)这 6 个波段图像,基本上覆盖了机载可见光红外成像光谱仪(AVIRIS)所用的 410~2450 nm 中除去大气窗口的光谱波长范围,使得它们之间也具有较强相关性。这样将(2)式扩展就可以得到多光谱与高光谱融合的图像超分辨率公式:

$$X_{\text{band}_i} = \sum_j a_{ij} Y_j^{\text{avg}} + b_i, \quad (4)$$

式中 X_{band_i} 是低分辨率高光谱图像在波段 i 的像素值, Y_j^{avg} 是降分辨率的多光谱图像的第 j 个波段的像素值, a_{ij} 和 b_i 是待求系数。

而对于回归分析而言,如果继续利用最小均方回归分析来求解参数 a_i 和 b_i 来建立 Y^{avg} 与 X_{band_i} 的对应关系,则不能很好地解决由于维数增加而带来的非线性问题,这里,采用近些年一些学者研究的在处理非线性回归问题中具有良好性能的相关向量回

归机^[10]来完成此任务。

3 相关向量机回归原理

对于一维目标函数的回归问题,假定训练集为 $\{x_n, t_n\}_{n=1}^N$, 目标函数是来自带有附加噪声的模型的样本,即:

$$t_n = y(x_n; \omega) + \epsilon_n, \quad (5)$$

式中 ϵ_n 是一个独立分布的噪声分量,通常都假设其遵循零均值方差为 σ^2 的高斯分布,即 $\epsilon_n \sim N(0, \sigma^2)$, 因此, $p(t_n | x) \sim N[t_n | y(x_n), \sigma^2]$, 表示 t_n 是一个均值为 $y(x_n)$, 方差为 σ^2 的高斯分布。则相关向量机最后的回归形式可表示为:

$$y(x; \omega) = \sum_{i=1}^N \omega_i K(x, x_i) + \omega_0, \quad (6)$$

式中 $K(x, x_i)$ 是一个核函数, ω_i 是回归系数。对应系数不为零的向量称为相关向量。

可以合理地假设 $\{t_n\}_{n=1}^N$ 是相互独立的随机变量,结合(1)式,则训练集的概率分布函数为

$$p(t | \omega, \sigma^2) = (2\pi\sigma^2)^{-N/2} \exp\left(-\frac{1}{2\sigma^2} \|t - \Phi\omega\|^2\right), \quad (7)$$

式中 $t = (t_1, \dots, t_N)^T$, $\omega = (\omega_1, \dots, \omega_N)^T$, Φ 是一个 $N \times (N+1)$ 设计矩阵,其中 $\phi_{m1} = 1, \phi_{mm} = K(x_m, x_{m-1})$ 。由前面的概率估计,可求得条件概率为:

$$p(t^* | t) = \int_{\Theta} p(t^* | \omega, \delta^2) p(\omega, \delta^2 | t) d\omega d\delta^2 = \int_{\Theta} p(t^* | \omega, \delta^2) \frac{p(t | \omega, \delta^2) p(\omega, \sigma^2)}{p(t)} d\omega d\delta^2. \quad (8)$$

相关向量机(RVM)是将每一个参数定义了一个先验概率分布来做限制。然后引进超参数,使每个权系数都有一个对应的超参数独立地对其进行限制和约束,为 ω 加上先决条件:它们的概率分布是落在 0 周围的正态分布: $p(\omega_i | \alpha_i) = N(\omega_i | 0, \alpha_i^{-1})$, $\alpha = [\alpha_0, \alpha_1, \alpha_2, \dots, \alpha_N]^T$ 。则

$$p(\omega | \alpha) = \prod_{i=0}^N N(\omega_i | 0, \alpha_i^{-1}) = \prod_{i=0}^N \frac{\alpha_i}{\sqrt{2\pi}} \exp\left(-\frac{\alpha_i \omega_i^2}{2}\right), \quad (9)$$

这样,就为每一个权值设置了独立的超参数。

对于给定一个新的检验点 x^* , 其相应的目标预测 t^* 的分布:

$$p(t^* | t) = \int p(t^* | \omega, \alpha, \delta^2) p(\omega, \alpha, \delta^2 | t) d\omega d\alpha d\delta^2, \quad (10)$$

对于 $p(t^* | \omega, \alpha, \delta^2)$ 中,因为 t^* 只和 ω 与 σ^2 直接相关,由马尔可夫性质得到:

$$p(t^* | \omega, \alpha, \sigma^2) = p(t^* | \omega, \sigma^2) = N[t^* | y(x^*, \omega), \sigma^2], \quad (11)$$

有了先验之后,由贝叶斯准则可以得到所有未知参数的后验概率:

$$p(\omega, \alpha, \sigma^2 | t) = \frac{p(t | \omega, \alpha, \sigma^2) p(\omega, \alpha, \sigma^2)}{p(t)}, \quad (12)$$

由于(8)式不易直接计算,将后验分解如下:

$$p(\omega, \alpha, \sigma^2 | t) = p(\omega | t, \alpha, \sigma^2) p(\alpha, \sigma^2 | t), \quad (13)$$

对于(9)式等号右边第一项,可直接计算:

$$p(\omega | t, \alpha, \sigma^2) = \frac{p(t | \omega, \sigma^2) p(\omega | \alpha)}{p(t | \alpha, \sigma^2)} = (2\pi)^{-(N+1)/2} |\Sigma|^{-1/2} \exp\left[-\frac{1}{2} (\omega - \mu)^\top \Sigma^{-1} (\omega - \mu)\right], \quad (14)$$

$$p(t|\alpha, \sigma^2) = (2\pi)^{-N/2} |\Omega|^{-1/2} \exp\left(-\frac{t^T \Omega^{-1} t}{2}\right), \quad (15)$$

式中后验分布的方差 $\Sigma = (\sigma^{-2} \Phi^T \Phi + A)^{-1}$, $A = \text{diag}(\alpha_0, \alpha_1, \dots, \alpha_N)$, 均值 $\mu = \sigma^{-2} \Sigma \Phi^T t$ 。

4 RVM 图像超分辨率算法

有了前面 RVM 回归分析的基础, 就可以利用 RVM 来建立 Y^{avg} 与 X_{band_i} 的对应关系, 从而实现本文的利用高空间分辨率的多光谱来对高光图像进行分辨率增强算法。具体如下:

1) 将低分辨率图像和下采样后的多光谱图像分成 K 个大小相同的窗。对于第 k 个窗口, (4) 式可以写作

$$X_k^{\text{band}_i} = \psi_{ik}(Y_k^{\text{avg}}), \quad (16)$$

式中 $X_k^{\text{band}_i}$ 是低分辨率高光图像波段 i 在第 k 个窗口的灰度值, Y_k^{avg} 是降分辨率的多光谱图像在第 k 个窗口的光谱向量, $\psi_{ik}(Y_k^{\text{avg}})$ 是对 Y_k^{avg} 进行的某个函数运算。

为了解决回归分析中可能会出现非线性问题, 这里采用 RVM 对 $\psi(\cdot)$ 所表示的映射关系进行估计, 即以 Y_k^{avg} 为输入值, $X_k^{\text{band}_i}$ 为目标输出值对 RVM 进行训练, 建立起 Y_k^{avg} 所在空间与 $X_k^{\text{band}_i}$ 所在空间的对应关系;

2) 将原始多光谱图像 Y 也分成 K 个大小相等的窗, 每个窗都与下采样后的多光谱图像所分的窗相对应。将第 k 个窗的图像 Y_k 输入到 $\psi_{ik}(\cdot)$, 这样即可以得到:

$$Z_{\text{band}_{ik}}^{\circ} = \psi_{ik}(Y_k), \quad (17)$$

式中 $Z_{\text{band}_{ik}}^{\circ}$ 代表第 i 个波段的第 k 个窗中间值, 将其代入下式来保证分辨率增强后其与原始图像对应位置的均值不变。

$$Z_k^{\text{band}_i} = Z_{\text{band}_{ik}}^{\circ} \cdot X_k^{\text{band}_i} / Z_{\text{band}_{ik}(\text{avg})}^{\circ}, \quad (18)$$

式中 $Z_k^{\text{band}_i}$ 表示高光图像分辨率增强后第 k 个窗的结果, $Z_{\text{band}_{ik}(\text{avg})}^{\circ}$ 表示通过式 $Z_{\text{band}_{ik}(\text{avg})}^{\circ} = \psi_{ik}(Y_k^{\text{avg}})$ 计算的结果。将所有窗对应的 $Z_k^{\text{band}_i}$ 都计算出来后, 即可以将其合并, 得到最终的分辨率增强的结果。

5 仿真实验及性能分析

为了测试本文所提的算法性能, 实验利用大小为 $400 \text{ pixel} \times 400 \text{ pixel}$ 的 AVIRIS 传感器成像的圣地亚哥某地的高光谱数据, 对其进行空间重采样得到一幅低空间分辨率的高光谱图像, 按照多光谱成像参数对其光谱重采样得到一幅高空间分辨率的多光谱图像。其中高光图像大小为 $100 \text{ pixel} \times 100 \text{ pixel}$, 而多光谱图像大小为 $400 \text{ pixel} \times 400 \text{ pixel}$, 即一个高光图像像素点对应了多光谱图像的 4×4 个点。

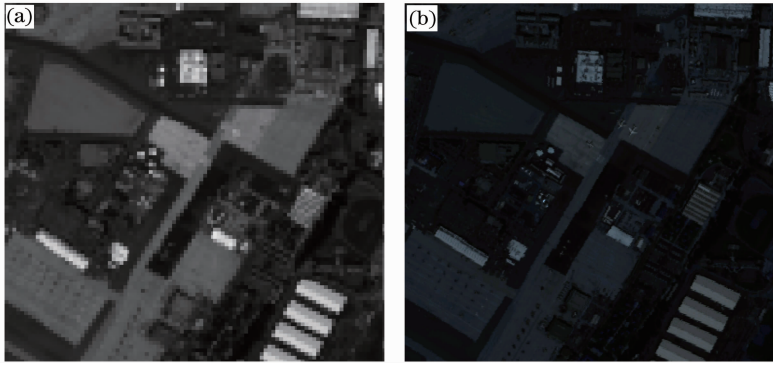


图 1 实验数据。(a) 低分辨高光数据; (b) 多光谱数据

Fig. 1 Experimental data. (a) Hyperspectral data of low-resolution; (b) multi-spectral data

因此实验分别利用 Price 法及其引进的 Elbakary 法和本文方法对该数据进行分辨率增强, 并分别从均方根误差 ϵ_{rms} 、光谱角误差 ϵ_{sam} 出发来对三种算法的增强效果进行评价。并将增强结果应用于目标检测, 以此来检验分辨率增强对目标检测的影响。其中 ϵ_{rms} 和 ϵ_{sam} 计算公式为

$$\epsilon_{\text{rms}} = \sqrt{\sum_n \sum_i [Z_{\text{band}_i}(n) - G_i(n)]^2 / (N \times B)}, \quad (19)$$

$$\epsilon_{\text{sam}} = \frac{1}{N} \sum_n \cos^{-1} \left[\frac{[Z_{\text{band}}(n)]^T G(n)}{\|Z_{\text{band}}(n)\| \cdot \|G(n)\|} \right], \quad (20)$$

式中 N 是增强后高光图像总的像素数, B 是高光图像的波段数, G_i 是真实的高光谱图像第 i 个波段图像。

其计算结果(窗口大小为 10 时)及精度分别如图 2、表 1 所示。

从结果可以看出, 本文算法在窗口大小为 $10 \text{ pixel} \times 10 \text{ pixel}$ 时, 效果比较好, 增强后图像与真实图像的误差较小, 归一化均方根误差小于 0.001; 光谱角误差小于 0.02。整体超分辨率效果较 Price、Elbakary 法有较大提升。




图 2 不同方法实验结果对比。(a) Price 方法结果；(b) Elbakary 法结果；(c)本文方法结果

Fig. 2 Comparison of the experiment results in different methods. (a) Price method; (b) Elbakary method; (c) proposed method

表 1 不同方法分辨率增强误差

Table 1 Error of resolution enhancement in different methods

Error	Price method	Elbakary method			Proposed method		
		5×5	10×10	20×20	5×5	10×10	20×20
RMS error (normalized)	0.019	0.0014	0.0027	0.0034	0.0011	0.0009	0.0012
Spectral angle error	0.068	0.035	0.046	0.048	0.025	0.016	0.024

6 结 论

为了获取更高空间分辨率的高光谱图像,从融合多光谱空间信息和高光谱光谱信息的角度出发,提出了一种基于相关向量机的图像超分辨率算法。对算法的原理进行了分析和介绍。实验结果表明:归一化均方根误差小于0.001,光谱角误差小于0.02,较 Price、Elbakary 法有较大提升。该方法对高光谱图像重建具有良好效果,可为后续分类、目标检测和识别等应用提供更高分辨率的高光谱图像。

参 考 文 献

- 1 Meng Xin, Li Jianxin, Zhu Rihong, *et al.*. Compressive sampling recovery method of narrow-band hyperspectral interferometric imaging[J]. *Acta Optica Sinica*, 2013, 33(1): 0130001.
孟鑫,李建欣,朱日宏,等.窄带高光谱干涉成像的压缩采样复原方法[J].*光学学报*, 2013, 33(1): 0130001.
- 2 Xue Qingsheng. Optical system design of a spaceborne broadband far ultraviolet hyperspectral imager [J]. *Acta Optica Sinica*, 2013, 33(3): 0322001.
薛庆生.星载宽波段远紫外高光谱成像仪光学系统设计[J].*光学学报*, 2013, 33(3): 0322001.
- 3 Zhang Hui, Xu Hui, Lin Liangkui. Super-resolution method of closely spaced objects based on sparse reconstruction using single

- frame infrared data [J]. *Acta Optica Sinica*, 2013, 33(4): 0411001.
- 张慧,徐晖,林两魁.基于稀疏重构的空间邻近目标红外单帧图像超分辨率方法[J].*光学学报*, 2013, 33(4): 0411001.
- 4 M E Winter, E M Winter. Physics-based resolution enhancement of hyper-spectral data[C]. *SPIE*, 2002, 4725: 580-587.
- 5 R B Gomez, A Jazaeri, M Kafatos. Wavelet-based hyperspectral and multispectral image fusion[C]. *SPIE*, 2001, 4383: 36-42.
- 6 Zhang Yifan, He Mingyi. Multi-spectral and hyperspectral image fusion using 3-D wavelet transform[J]. *J Electronics*, 2007, 24(2): 218-224.
- 7 J C Price. Combining panchromatic and multispectral imagery from dual resolution satellite instruments[J]. *Remote Sensing of Environment*, 1987, 21(2): 119-128.
- 8 M Elbakary, M Alam. Super-resolution construction of multispectral imagery based on local enhancement [J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, 5(2): 276-279.
- 9 Yin Wen, Li Yuanxiang, Zhou Zeming, *et al.*. Remote sensing image fusion based on sparse representation [J]. *Acta Optica Sinica*, 2013, 33(4): 0428003.
- 尹雯,李元祥,周则明,等.基于稀疏表示的遥感图像融合方法[J].*光学学报*, 2013, 33(4): 0428003.
- 10 Zhao Chunhui, Qi Bin, Zhang Yi. Hyperspectral image classification based on variational relevance vector machine[J]. *Acta Optica Sinica*, 2012, 32(8): 0828004.
- 赵春晖,齐滨,张焱.基于改进型相关向量机的高光谱图像分类[J].*光学学报*, 2012, 32(8): 0828004.

栏目编辑:李志兰