

热红外与多光谱遥感图像的 神经网络回归融合方法研究

姚 为 韩 敏

(大连理工大学电子信息工程学院, 大连 116023)

摘 要 为验证神经网络方法用于遥感图像融合的有效性,归纳了利用神经网络对遥感数据进行回归来实现融合的3种途径,并提出了一种结合图像数据回归和多光谱遥感图像锐化技术来实现热红外图像的全色锐化新方法。这种热红外图像的全色锐化方法,利用了极限学习机(ELM)这种新型神经网络算法,快速高效地由训练样本得到遥感图像数据间的回归关系;同时,方法注重图像数据本身的物理含义,以提高热红外图像数据的真实质量为目标,是一种量化的图像融合方法。经这种方法融合得到的热红外数据也能很好地用于定量遥感的物理模型,为遥感的实际应用提供方便。该方法的有效性通过对ETM+图像进行实验得到了证明,而直接对热红外图像数据和全色图像数据进行回归的融合模式,在实验中则无法得到满意的结果。

关键词 遥感 图像融合 全色锐化 回归 极限学习机

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2010)08-1278-07

Fusion of Thermal Infrared and Multispectral Remote Sensing Images via Neural Network Regression

YAO Wei, HAN Min

(School of Electronic and Information Engineering, Dalian University of Technology, Dalian 116023)

Abstract The paper summarizes three modes for the use of neural network regression to fuse remote sensing images, while proposing a new pansharpening method, based on neural network regression, to fuse thermal infrared(TIR) image and the panchromatic(Pan) image, which can hardly be done using traditional image fusion techniques. Extreme learning machine algorithm is applied to obtain the regression relationship between remote sensing data, in a rapid and efficient manner, while the pansharpening for TIR focus on the internal physical relations of pixel values recorded as an image, and aiming at a real improvement of the TIR data quality rather than a visual enhancement. TIR data synthesized by this new image fusion method is qualified to be used in physical models. This provides convenience for quantitative remote sensing applications. Experiments on ETM+ images prove the effectiveness of this approach which achieves fairly accurate results, while direct fusing mode achieves dissatisfactory results.

Keywords remote sensing, image fusion, Pansharpening, regression, ELM

0 引 言

数据融合,也称为信息融合,是将来自多个传感

器或多源的信息进行综合处理,从而得到更为准确、可靠的结论,以达到更好地了解对象的目的^[1]。对不同平台、不同传感器获取的遥感影像数据进行综合应用的数据融合方法理论,称为遥感图像融合。

基金项目:国家科技支撑计划项目(2006BAB14B05);国家重点基础研究发展计划(973)项目(2006CB403405);国家自然科学基金项目(60674073)

收稿日期:2009-05-19;改回日期:2009-09-11

第一作者简介:姚 为(1983—),男。现为大连理工大学控制理论与控制工程专业博士研究生。研究方向为遥感图像处理。

E-mail: modestyao@mail.dlut.edu.cn

全色锐化^[2] (Pansharpening)方法是一类应用最广泛的遥感图像融合方法,全色锐化方法将全色波段的遥感图像与多光谱波段的影像相融合,结合全色图像高空间分辨率和多光谱图像高光谱分辨率的优势,实现对多光谱图像的空间分辨率增强。全色锐化方法,可以分为两类,一类是包括 IHS (亮度、色度、饱和度)变换,PCA (主成分分析)方法以及 GS (Gram-Schmidt)方法等众多常见方法在内的成分替代方法^[3];另一类是基于金字塔变换和小波变换的多分辨率分析方法^[4]。

Wald^[5]指出,“遥感图像融合以提高遥感图像的质量为目标,而质量的定义,则是由具体的实际应用所决定的”。对于模式识别和分类等应用,图像融合的理论方法着眼于视觉效果增强,包括颜色差别的增强和纹理细节的突出;对于定量遥感的应用和热红外图像的增强,则必须考虑图像光谱亮度值所代表的物理含义,要求融合结果能尽可能接近真实的地表辐射量信息。基于成分替代和多分辨率分析的全色锐化方法,更多地考虑融合图像的视觉效果,而忽略图像数据的物理含义,无法满足定量遥感应用的需求;另一方面,在一些实际应用如基于遥感数据建立的区域水循环、碳循环模型中,与地表温度直接相关的热红外遥感图像数据的重要性甚至超过了多光谱的遥感图像数据,然而,现有的遥感图像融合方法,多数是对多光谱图像进行处理,鲜见应用于热红外遥感图像的融合方法。针对这些问题,以 ETM + 遥感影像数据为例,探讨了实现遥感图像融合方法定量化的途径,比较了提高热红外遥感数据质量的几种不同融合模式,并提出一种对热红外图像进行全色锐化的融合方法。

1 方 法

热红外 (TIR) 图像与多光谱 (MS) 图像的成像原理不同,多光谱图像记录了包括可见光和近红外、中红外波段地表反射的太阳光辐射强度信息,热红外图像则包含了地表自身发射的热红外辐射的辐射强度信息。两类辐射虽由不同的辐射源产生,但考虑到地表的太阳辐射在一个相当大的区域范围内几乎可以看成常数,地表反射的太阳辐射大小也和地表自身辐射一样,最终是由地物的几何、物理性质所决定,因此,两类辐射信息之间,必然有着较强的内在相关性。利用神经网络方法对大量数据进行回归,是挖

掘物理量间隐含相关性的行之有效的方法,因而如果能利用回归方法得到两类辐射间的相关关系,就能实现对多光谱图像和热红外图像的融合。

图 1 给出了将回归方法应用于遥感图像融合来实现热红外图像分辨率增强的 3 种模式,其中方块代表了不同波段的遥感图像,箭头代表了融合过程中图像细节信息 (空间分辨率) 在不同波段图像间的传递。图中所示的这 3 种融合模式分别是:

模式 1 直接利用神经网络建立多光谱图像与热红外图像数据的回归关系,实现对多光谱图像和热红外图像的融合;

模式 2 通过全色锐化方法对多光谱图像进行增强,并利用神经网络包含的回归关系,得到分辨率水平与全色波段图像一致的热红外图像;

模式 3 直接利用神经网络建立全色图像数据与热红外图像数据间的回归关系,来实现对热红外图像的全色锐化。

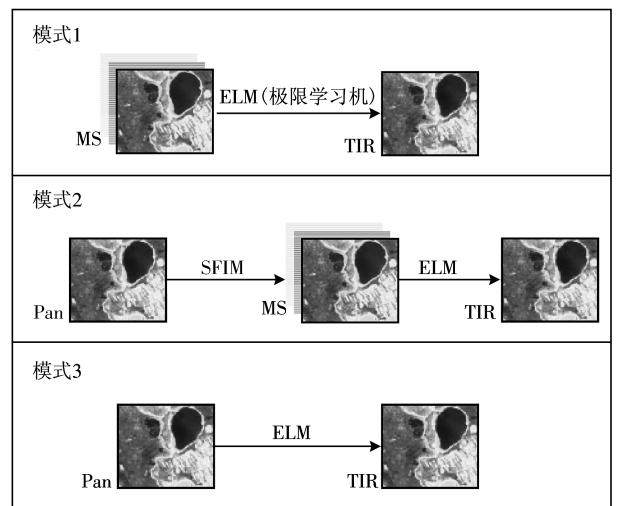


图 1 热红外图像融合的 3 种模式

Fig. 1 Three modes for the fusion of TIR image

此外, Aiazzi 等人^[6]在 2007 年提出自适应 IHS 图像融合方法 GIHSA, 利用回归方法来确定各多光谱波段构成图像亮度分量 I 时的权重, 这种做法可以看做回归方法应用于遥感图像融合的一种内部结合模式。

1.1 ELM 网络

本文的研究利用极限学习机 (ELM) 对 ETM + 遥感图像数据进行回归。极限学习机是新近提出的一种基于单隐层前向神经网络的机器学习方法。作为一种新型的前向神经网络算法, ELM 具有的最大优势就是计算速度快, 从而能高效地应付大规模

的遥感图像数据^[7]。同时,ELM 具有的良好的泛化能力也在实验和实际应用中都得到了证明。

单隐层前向网络结构如图 2 所示。假设训练样本集由 N 个不同的样本 $(x_i, t_i) \in \mathbf{R}_n \times \mathbf{R}_m (i=1,2,\dots, N)$ 组成,则网络的前向计算过程可以表示为

$$HV = T \tag{1}$$

其中

$$H = \begin{bmatrix} g(a_1, b_1, x_1) & g(a_2, b_2, x_1) & \cdots & g(a_L, b_L, x_1) \\ \vdots & \vdots & & \vdots \\ g(a_1, b_1, x_N) & g(a_2, b_2, x_N) & \cdots & g(a_L, b_L, x_N) \end{bmatrix}_{N \times L}$$

$$V = \begin{bmatrix} v_1^T \\ \vdots \\ v_L^T \end{bmatrix}_{L \times m}, T = \begin{bmatrix} t_1^T \\ \vdots \\ t_N^T \end{bmatrix}_{N \times m}$$

$a_i = [a_{i1}, a_{i2}, \dots, a_{in}]^T, i=1,2,\dots, L$, 为输入节点与第 i 个隐层节点的连接权值; b_i 为第 i 个隐层节点偏置值; v_i 为第 i 个隐层节点与输出节点的连接权值; H 表示网络的隐层输出矩阵。选择 Sigmoid 函数作为隐层节点激活函数

$$g(a_i, b_i, x_i) = sig(a_i x_i + b_i) \tag{2}$$

如果激活函数 $g(x)$ 无限可微,那么网络参数并不需要全部进行调整,其中输入与隐层的连接权值以及隐层的偏置值可以随机选择,这时候 ELM 算法分 3 步来计算网络的权值:

- 1) 随机选取输入连接权值和偏置值 a_i, b_i ;
- 2) 计算网络隐层输出矩阵 H ;
- 3) 计算矩阵 H 的 Moore-Penrose 广义逆 H' , 从而得到输出权值 $V = H'T$ 。

网络输出连接权值通过直接求解线性方程组来获得,这正是 ELM 算法简单并且快速的原因。




图 2 单隐层前向神经网络

Fig. 2 Single-hidden-layer feedforward neural networks

1.2 基于 ELM 的多光谱与热红外图像的融合

ETM + 遥感数据集包含 6 个多光谱波段的图像,对应于 3 个可见光波段、1 个近红外波段和 2 个中红外波段,空间分辨率均为 30 m。ETM + 的热红外波段的图像空间分辨率为 60 m,而全色波段的图像空间分辨率为 15 m。

在融合之前,需要对图像进行辐射校正等预处理,这些过程在这里不做详细的说明。另一方面,根据量化的需求,所有的遥感图都要由灰度值(DN 值)图像还原成辐射强度图像。

为实现模式 1 的图像融合,首先通过低通滤波对多光谱图像进行降分辨率处理,得到 60 m 分辨率的多光谱图像 I_{MS60} ,利用 I_{MS60} 和 60 m 分辨率的原始热红外图像 I_{TIR60} 训练 ELM 网络,得到多光谱数据与热红外数据间的回归关系。

然后,将 30 m 分辨率的原始多光谱图像 I_{MS30} ,作为训练好的 ELM 网络的输入,得到的输出就是分辨率提高一倍的热红外图像 I_{TIR30} 。

模式 1 的融合方法已有一些相关的研究,杨贵军等人^[8]在 2007 年提出结合遗传算法与自组织映射神经网络方法对 ASTER 的可见光和热红外遥感数据进行了融合,并且得到了较好的结果。

1.3 ELM 结合 SFIM 的热红外图像全色锐化

考虑到 ETM + 还包含一个 15 m 分辨率的全色波段的数据,希望利用这个波段的数据对热红外图像的分辨率作进一步的增强处理,因此,本文提出一种将用于多光谱与全色图像融合的全色锐化方法和 ELM 网络回归方法相结合的遥感图像融合方法,来实现热红外图像的全色锐化。

同样首先利用降分辨率处理得到的多光谱图像 I_{MS60} 和 I_{TIR60} 数据训练 ELM 网络,得到两类辐射量数据间的回归关系。然后,利用经全色锐化处理得到的分辨率增强了的多光谱图像 I_{MS15} 作为 ELM 网络的输入,从而得到了同样具有 15 m 分辨率的热红外图像 I_{TIR15} ,热红外图像的分辨率提升了 4 倍。

过程中利用平滑滤波亮度调制(SFIM)方法来实现原始多光谱图像 I_{MS30} 的全色锐化。SFIM 方法^[9]由 Liu 等人在 2000 年提出,相对于其他一些全色锐化方法,SFIM 的优势是它考虑了反射光波段遥感图像的成像原理,有很好的物理基础。

SFIM 的理论认为,反射光波段(包括了多光谱和全色)的 DN 值遥感图像 I_{DN} 中各像素点的亮度大小,由太阳光的强度和地表对太阳光的反射率这两个因

素决定,因此,可以对反射光波段遥感图像进行分解

$$I_{DN}(\lambda) = \rho(\lambda)E(\lambda) \quad (3)$$

其中, $E(\lambda)$ 和 $\rho(\lambda)$ 分别表示波长为 λ 的太阳光的辐射强度大小和地表对该波长太阳光的反射率。

然而,式(3)只是一种定性的表示,应该以更严密的分解形式作为 SFIM 方法的基础,即

$$R(\lambda) = \rho(\lambda)E(\lambda) \quad (4)$$

其中, $R(\lambda)$ 表示地表反射波长为 λ 的太阳光的辐射强度大小。在辐射强度和 DN 值成比例关系时,基于式(3)的推导,不会造成错误^[10],但对于 ETM + 的遥感数据,图像 DN 值和地表辐射强度间成线性而非比例关系,这时候式(3)两端即不直接相等,甚至不成比例关系。

相应地,应该对辐射强度图像而不是 DN 值图像使用 SFIM 方法:

$$\begin{bmatrix} I_{MS15}(1) \\ I_{MS15}(2) \\ \vdots \\ I_{MS15}(6) \end{bmatrix} = r \begin{bmatrix} I_{MS30}(1) \\ I_{MS30}(2) \\ \vdots \\ I_{MS30}(6) \end{bmatrix} = \frac{I_{Pan15}}{I_{Pan30}} \begin{bmatrix} I_{MS30}(1) \\ I_{MS30}(2) \\ \vdots \\ I_{MS30}(6) \end{bmatrix} \quad (5)$$

式中, $I_{MS30}(1) \sim I_{MS30}(6)$ 和 I_{Pan15} 分别表示对应 ETM + 多光谱和全色波段的辐射强度图像, I_{Pan30} 是分辨率降低到 30 m 的全色辐射强度图像, $I_{MS15}(1) \sim I_{MS15}(6)$ 是融合得到的分辨率增强到 15 m 的 6 个波段的多光谱辐射强度图像。

1.4 全色与热红外图像的直接融合

虽然不能直接的利用 SFIM 等常规融合方法对热红外图像和全色图像进行融合,但考虑到全色图像与多光谱图像一样记录了地表反射太阳光的辐射强度信息,反射的全色波段太阳辐射和地表的热红外辐射之间,也有着内在的联系,因此,进一步尝试直接对全色图像和热红外图像进行融合。

首先对全色波段图像进行降分辨率处理得到与热红外分辨率一致的全色图像 I_{Pan60} ,将 I_{Pan60} 和 I_{TIR60} 数据分别作为输入样本和输出样本重新训练 ELM 网络,得到全色图像数据与热红外图像数据间的回归关系。将原始高分辨率的全色图像数据 I_{Pan15} 输入训练好的 ELM 网络,输出得到分辨率与全色图像一致的热红外图像 I_{TIR15} 。

2 实验

2.1 实验数据

实验用到了 2002 年 9 月 22 日扎龙湿地的

ETM + 遥感图像,对应的条带号为 112/27,卫星的过境时间为北京时间下午 2 点。选取湿地内部一个 190×220 (对应多光谱波段的像素点个数) 的区域 1 作为 ELM 的训练样本集的数据来源,所有的融合操作也都是对该目标区域的各波段图像进行。该目标区域的地物构成具有很好的代表性,主要包括明水体,芦苇沼泽和农田。目标区域的热红外图像如图 3 所示。选取另外一个 250×270 的参考区域 2,从该区域的图像中得到的多光谱数据和热红外数据作为 ELM 网络的测试样本集。

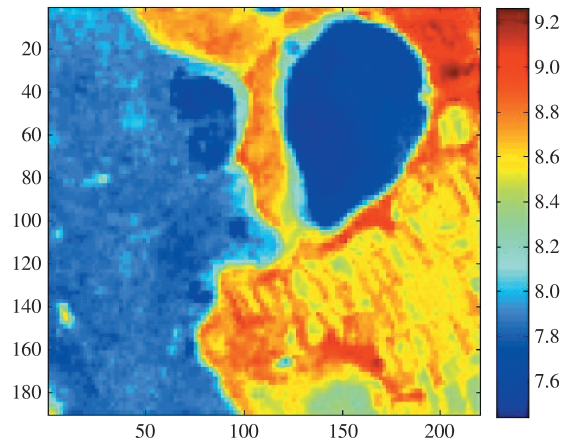


图 3 目标区域热红外图像

Fig. 3 TIR image of objective region

2.2 实验结果

对应着上一节给出热红外图像与反射率图像融合的 3 种模式,整个实验过程也分为 3 个部分。首先由子区域 1 的图像提取出 I_{MS60} 和 I_{TIR60} 辐射强度数据,构造网络的训练样本集,训练结果如图 4 所示。RMSE 为均方根误差,横坐标表示模型输出,相对于纵坐标表示的真实值的相关系数为 0.978 4。

接着对训练好的网络进行测试,检验得到的回归关系是否能进行空间尺度上的推广。同样的,由子区域 2 的图像提取出多光谱波段和热红外波段的辐射强度数据构成测试样本集 I_{MS60} (Test)和 I_{TIR60} (Test),测试得到的结果如图 5 所示。模型输出相对于真实值的相关系数为 0.925 0。

再次由子区域 1 的图像提取原始的 I_{MS30} 辐射强度数据作为 ELM 网络的数据,得到了分辨率增强到 30 m 的 I_{TIR30} 辐射强度数据,对应的增强后的热红外图像如图 6 所示。

根据模式 2 的融合方法,对子区域 1 的多光谱图像进行全色锐化,得到 15 m 分辨率 6 波段的多光




图 4 ELM 网络训练结果

Fig. 4 Training results of the ELM network




图 5 ELM 网络测试结果

Fig. 5 Testing results of the ELM network




图 6 模式 1 得到的 TIR 融合图像

Fig. 6 Fusion result of TIR image via mode 1

谱图像集 $I_{MS15}(1) \sim I_{MS15}(6)$ 。将 I_{MS15} 辐射强度数据作为 ELM 网络的输入,得到了分辨率增强到 15 m 的 I_{TIR15} 辐射强度数据,对应的增强后的热红外图像如图 7 所示。




图 7 模式 2 得到的 TIR 融合图像

Fig. 7 Fusion result of TIR image via mode 2

重新训练 ELM 网络,来实现模式 3 的热红外图像与全色图像的融合。由分辨率降低到 60 m 的全色波段辐射强度数据 I_{Pan60} 和原始热红外辐射强度数据 I_{TIR60} 构造训练样本集。在训练完成之后,将 15 m 分辨率的原始全色辐射强度数据 I_{Pan15} 输入网络,得到输出 I_{TIR15} 的数值有严重的发散,甚至达到 10^5 量级。分析原因,认为是由于全色图像数据相对与多光谱图像,存在极大程度的信息缺失,不能反映地物发射率的频谱特征,因此,数据表现出的全色波段反射与热红外辐射间的相关性是非常弱的。

2.3 结果评价

将按模式 1 和模式 2 得到 TIR 图像重采样到原始 TIR 图像的分辨率水平,得到辐射强度数据集 I'_{TIR30} 和 I'_{TIR15} ,计算这两个数据集与原始 TIR 图像的辐射强度数据 I_{TIR60} 间的相关系数(CC)和相对于原始数据的 RMSE,得到的结果如表 1 所示。定义两个模式得到结果相对于原始数据的误差分别为

$$d_{mode1} = I'_{TIR30} - I_{TIR60} \quad (6)$$

$$d_{mode2} = I'_{TIR15} - I_{TIR60} \quad (7)$$

得到热红外辐射强度的模型输出结果和真实数据间的误差在 104 50 个 I_{TIR60} 图像的像素点上的分布情况如图 8 和图 9 所示。

表 1 两个模式融合结果的评价指标

Tab. 1 Statistical assessments for fusion results of the 2 modes

	CC	RMSE
模式 1	0.975 2	0.115 9
模式 2	0.908 1	0.212 0




图 8 模式 1 融合方法的结果误差
Fig. 8 Error of fusion result via mode 1




图 9 模式 2 融合方法的结果误差
Fig. 9 Error of fusion result via mode 2

对比两个模式结果的统计数据以及各个点上误差数值,可以看出,模式 2 的结果相对与模式 1 的结果,精度有明显的下降。然而,考虑到模式 2 得到 TIR 数据比模式 1 的结果具有更高的分辨率,并且与 7~9.5 W/m² 的辐射强度数值对比,0.212 W/m² 的均方根误差以及 -0.2~0.2 W/m² 的误差主体分布范围,是可以接受的结果。

3 结 论

对遥感图像融合方法的研究,已不再满足单纯提高图像视觉效果,而逐渐以真实的改进图像数据的质量为目标,融合方法定量化已成为发展的趋势。相对于传统的融合方法,回归和智能图像融合方法

更容易获取图像数据间包含的内在物理关系;同时,回归方法也是目前实现热红外图像和反射光图像融合的唯一解决方案。

将 ELM 神经网络回归方法用于图像融合的 3 种模式,对多光谱数据与热红外数据回归的 2 种模式均得到了较好的结果,而直接对全色数据与热红外数据进行回归的做法证明是不可行的。其中模式 2 代表了本文提出的一种将 ELM 回归与 SFIM 全色锐化相结合的新图像融合方法,该方法在对多光谱图像进行增强的基础上,利用回归的思想实现了对热红外图像的全色锐化,即间接地对全色图像和热红外图像进行融合。新方法的有效性通过实验得到了证明,这种结合多光谱图像锐化和神经网络回归的新思路,为实现图像融合技术与定量遥感应用的

结合,提供了一条可行之径。

参考文献 (References)

- [1] Pohl C, Genderen V J L. Multisensor image fusion in remote sensing: concepts, methods and applications [J]. International Journal of Remote Sensing, 1998, 19(5): 823-854.
- [2] Gamba P, Chanussot J. Foreword to the special issue on data fusion [J]. IEEE Transactions on Geoscience and Remote Sensing, 2008, 46(5): 1283-1288.
- [3] Alparone L, Wald L, Chanussot J, et al. Comparison of pansharpening algorithms; outcome of the 2006 GRS-S data-fusion contest [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(10): 3012-3021.
- [4] Ranchin T, Wald L. Fusion of high spatial and spectral resolution images: the ARSIS concept and its implementation [J]. Photogrammetric Engineering & Remote Sensing, 2000, 66(1): 49-61.
- [5] Wald L. Some terms of reference in data fusion [J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(3): 1190-1193.
- [6] Aiazzi B, Baronti S, Selva M. Improving component substitution pansharpening through multivariate regression of MS + Pan data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(10): 3230-3239.
- [7] Huang G B, Zhu Q Y, Siew C K. Extreme learning machine: theory and applications [J]. Neurocomputing, 2006, 70(1/3): 489-501.
- [8] Yang Guijun, Liu Qinhuo, Liu Qiang, et al. Fusion of visible and thermal infrared remote sensing data based on GA-SOFM neural network [J]. Geomatics and Information Science of Wuhan University, 2007, 32(9): 786-790. [杨贵军, 柳钦火, 刘强, 等. 基于遗传自组织神经网络的可见光与热红外遥感数据融合方法 [J]. 武汉大学学报: 信息科学版, 2007, 32(9): 786-790.]
- [9] Liu J G. Smoothing filter-based intensity modulation: a spectral preserve image fusion technique for improving spatial details [J]. International Journal of Remote Sensing, 2000, 21(18): 3461-3472.
- [10] Tu T M, Lee Y C, Huang P S, et al. Modified smoothing-filter-based technique for IKONOS-QuickBird image fusion [J]. Optical Engineering, 2006, 45(6): 66201-66210.