

基于遗传自组织神经元网络的可见光与热红外遥感数据融合方法

杨贵军¹ 柳钦火¹ 刘 强¹ 顾行发¹

(1 中国科学院遥感应用研究所遥感科学国家重点实验室,北京市朝阳区大电路 9718 信箱,100101)

摘 要:提出了一种融合方法,充分发掘可见光数据高空间分辨率和热红外数据高时间分辨率的特点,在由可见光数据估算的地表参量与热红外数据间,通过遗传自组织神经网络建立非线性融合方法,最终获得高空间、高时间分辨率的地表温度数据,并利用 ASTER 卫星产品数据对该方法进行了验证。结果表明,该方法简便易行,精度较高,为快速获取高分辨率地表温度分布提供了一条新途径。

关键词:融合; 可见光数据; 热红外; 地表参量; 遗传自组织特征映射

中图法分类号:P237.3

目前,关于可见光数据与热红外数据的融合方法还很少,已有的方法大多围绕图像视觉效果融合处理,往往忽略了融合后热红外数据的物理意义,导致无法应用于遥感物理模型的计算^[1]。本文利用降低空间分辨率后的可见光-近红外数据(visible and near infrared, VNIR)反演地表相关参数,在同一空间分辨率下建立地表参数和地表温度(surface temperature, T_s)间的非线性神经网络映射关系。这种方法不是两种数据的简单合成,而是通过它们提供的中间过渡参量来实现的,此方法属于一种半经验模型。虽然估算出的子像元温度与实际反演得到的温度或实地测量的温度有一定的差距,但估算精度却远高于简单的植被指数估算法^[2],可以满足局部蒸散、地表通量计算的精度需求。

1 试验区 and 数据

试验区位于北京市顺义区(22 km×15 km),地表覆盖类型主要为植被、裸土地、城镇(包含其他人工建筑)及水面,其中植被主要为冬小麦和少量的低矮灌木。选择 2001 年 5 月 19 日过境的

ASTER 1B 产品数据,使用其中的 1 波段(0.52~0.60 μm)、2 波段(0.63~0.69 μm)和 3N 波段(0.76~0.86 μm)(空间分辨率均为 15 m)作为 VNIR 数据;温度产品(空间分辨率为 90 m)作为地表真实温度(T_s),并根据卫星过境时刻的探空气象数据,利用 MODTRAN 4 对以上数据进行大气校正;以 ASTER VNIR 波段为参考,对两者进行几何配准。为实现对不同地表覆盖下的子像元温度估算,利用 VNIR 数据进行监督分类。在估算过程中,对不同覆盖类型选取不同的输入参数进行神经网络训练,从而提高估算精度。

为验证方法的适用性,根据现有的数据构造一组不同空间分辨率的数据集。由于只有 90 m 分辨率的 ASTER 温度产品数据可供验证使用,所以设置了 VNIR(90 m)- T_s (360 m)、VNIR(90 m)- T_s (1 080 m)两种估算模式(依次定义为模式 1 和模式 2),VNIR 为可见光/近红外数据, T_s 为地表温度数据。两组数据由经大气校正后的 ASTER 15 m 可见光-近红外数据和 90 m 温度数据进行 Aggregate 重采样方法得到,对上述两种模式分别进行融合,获得分辨率为 90 m 的子像元地表温度,并将估算结果进行分析和比较。

收稿日期:2007-06-27。

项目来源:国家自然科学基金资助项目(40401042,40371087);中国科学院知识创新工程重要方向资助项目(KZCX3-SW-334, KZCX3-SW-338-2);中国科学院百人计划资助项目(KZCX0415);国家教育部留学回国人员科研启动基金重点资助项目(HX040013);国防科学技术工业委员会资助项目(KJSX0401)。

2 融合方法

以模式 1 为例,融合的主要步骤为:① 利用地面实测数据和现有光谱库建立训练区,对 VNIR 90 m 数据进行监督分类,将地表覆盖分为植被、裸土、城镇及水面四类。② 分别将植被、裸土、城镇及水面对应的反射率数据从 VNIR 90 m 中分离出来。如果分类完全准确,理论上在空间分辨率降低过程中就不会产生混合像元问题,但通常很难保证 100% 分类的准确性,噪声像元仍然部分存在。再将分离出的反射率数据和分类结果的空间分辨率依次降低至 360 m,分别记为 $VNIR_{90}$ 、 $CLASS_{90}$ 、 $VNIR_{360}$ 、 $CLASS_{360}$ 及 T_{360} ($CLASS$ 为地表分类图,下标为分辨率大小)。③ 根据地表不同覆盖类型确定影响地表温度的主要参数,并利用以上数据反演出两个尺度下的地表参数。④ 在 360 m 空间分辨率下,利用 GA-SOFM 神经网络建立不同地表覆盖类型下的地表参量与 T_s 之间的映射关系。⑤ 将非线性映射关系应用到高分辨率 $VNIR_{90}$ 数据中,获得 90 m 分辨率子像元的地表温度,实现两种数据的融合。

2.1 网络输入参数获取

2.1.1 植被覆盖区

利用 CUPID 模型模拟植被冠层温度时,影响冠层温度的主要因素为气温、土壤表层水分、LAI、近红外反射率等。考虑到地表参数只能由 VNIR 数据反演获得,所以确定植被覆盖区域网络输入参数为 $NDVI$ 、 $TVDI$ 、 LAI 、 VWC 、 SWC 、近红外反射率(Ref_{NIR})、红波段反射率(Ref_R)、植被覆盖度(f_v)及 RVI ^[3-5]。选择 $TVDI$ 作为地表参数有以下两点考虑:① 利用 $VNIR_{360}$ 和 T_{360} 可以将 360 m 空间分辨率地表温度信息引入 SOFM 神经网络,使训练获得的映射关系中隐含了低分辨率地表温度的先验知识,这对非线性映射关系的建立起着关键性作用;② 对采用 $TVDI$ 作为评价地表水分或干旱状况的关键参量,国内外已普遍达成共识,且 $TVDI$ 也是对采用 VWC 和 SWC 参数的有利补充^[6,7]。

2.1.2 裸土覆盖区

裸土区地表温度主要受气温、土壤水分、大气状况、地形及土壤自身物理特性的影响(如土壤热容量、导热率)。另外,裸土可见光和近红外波段反射率的差异将大大减小。对于裸土或低覆盖率土壤,表面温度与地表含水量密切相关,参考植被覆盖区参数的选取,选择 SWC 、 SSC 、 $TVDI$ 、

Ref_{NIR} 、 Ref_R 及 RVI 作为裸土区参数,除 SWC 、 SSC 外,其他参量的计算方法与植被覆盖区一样。 SWC 、 SSC 参数的计算依据实测的不同含沙量和含水量的土壤光谱,统计出含沙量和含水量与干土反射率、干沙反射率及混合物反射率之间的指数经验关系,然后利用 VNIR 数据反演出土壤的含水量和含沙量^[8]。

2.1.3 城镇覆盖区

对于城镇覆盖区地表温度的估算,参照基于能量平衡理论估算城镇地表通量的方法,其中影响城镇能量平衡的主要参量是建筑物几何结构、表层发射率与反射率(屋顶、道路和墙面)、大气状况和太阳辐射状况^[9]。由于现有的 VNIR 和 T_s 数据很难预先估算出这些参数,所以选择 RVI 、 Ref_{NIR} 、 Ref_R 、 DVI (differenced vegetation index)和 $TVDI$ 作为参数。选择的主要依据是人工材料在可见光与近红外波段的反射率特征。另外,城镇地表是建筑物、植被、水面等不同覆盖类型的混合,所以 $TVDI$ 可作为其中的关键参量。

2.1.4 水面区域

水面在整个试验区仅占 8% 左右,水体温度主要受大气状况、太阳辐射、水体中物质的分布及物理化学状态决定。考虑到利用本文提供的数据反演出水体组分比较困难,水面参数仅选取了 RVI 、 Ref_{NIR} 、 Ref_R 和 DVI 。

按照上述方法分别计算出两种分辨率下(90 m 和 360 m)的地表参数,进行标准归一化后,提供给 GA-SOFM 神经网络作为输入参数使用。

2.2 GA-SOFM 神经网络构建与训练

2.2.1 SOFM 网络构建

输入参数的样本是随机选取的,选取的样本为试验区像元个数的 30%,另外选择 20% 作为检测数据。由于输入参数间具有一定的相关性,可将输入参数与对应地表温度的取值范围划分成不同的数值区间,即将地表参数与地表温度间的映射关系分类,提高网络的训练精度,而 SOFM 是按照自组织的特征自动进行分类映射的最佳神经网络。本文设计了带有 3 个隐含层的 SOFM 网络,网络的参数配置见表 1。

网络中,每个矢量运算单元对应一组网络输入参数(植被区 8 个、裸土区 7 个、城镇区 5 个、水面区 4 个),矢量单元个数代表映射关系类别划分数目。网络训练分为两步:首先根据输入参数进行自组织映射,将输入参数划分为若干类;然后对每类再重新进行训练,获得一组包含不同映射关系的训练集。自组织映射学习过程中参数设置如

表 1 SOFM 神经网络参数初始配置

Tab. 1 Initial Configuration of SOFM Neural Network

参数配置	层 号				
	竞争层	隐含层 1	隐含层 2	隐含层 3	输出层
邻域维数	5×5	—	—	—	—
邻域形状	Kohonen 方形	—	—	—	—
矢量运算单元个数	—	* 31	* 15	* 10	—
激活函数	—	正切双曲线	S 形函数	正切双曲线	S 形函数
学习规则	—	梯度与权变法	梯度与权变法	梯度与权变法	梯度与权变法
学习速率	—	* 1.00	* 0.80	* 0.60	* 0.001
动量因子	—	* 0.70	* 0.60	* 0.40	* 0.400

注：* 表示该参数进行了遗传算法优化。

下:学习率从 0.1 开始至 0.001 终止;在学习过程中,当连接权的值变化小于 0.000 1 时,学习终止;学习的最大次数为 20 000 次。最后重新训练过程中的参数配置为:终止条件为均方根误差小于 0.000 1,且达到最小;学习的最大次数为 30 000 次。

2.2.2 SOFM 网络参数遗传优化

为了充分发挥 GA 和 SOFM 的优势,将两者有机结合,利用 GA 对表 1 中的矢量运算单元个数、学习步长及学习速率三类参数取值进行优化。参数优化的大致步骤为:① 编码方法与初始群体的生成。由于试验中训练的数据都经过了标准归一化,处于[0.0,1.0]内,所以采用浮点数编码。由于在 SOFM 网络中共有三类待优化参数,所以染色体只含有三个基因,因此可定义染色体 j ($j = 1,2,\cdots,n$)的结构如下:学习速率为 0.4,动量因子为 0.7,矢量运算单元数为 15。② 对群体进行选择、交叉及变异遗传操作。其中,选择算子采用轮盘赌选择方法;交叉算子采用浮点线性交叉;变异算子选择均匀突变法。③ 根据 SOFM 神经网络适应度函数计算当前群体中所有遗传个体的适应度。④ 对个体按适应度值排序,对适应度值最高的个体解码后执行一次 SOFM 算子,并得到新一代种群 $P(t+1)$,世代数增 1。⑤ 判断是否符合优化准则,若不符合,则返回步骤②;若符合,则结束。

遗传算法中,需要选择的参数主要有群体大小 n 、选择概率 p_s 、交叉概率 p_c 以及变异概率 p_m 等。本文中, $n=60$, $p_s=0.06$, $p_c=0.5$, $p_m=0.1$ 。达到预先设定的最大演化代数或者当连续 3 代群体的平均适应度之差小于 0.01 时,迭代结束。

3 结果与讨论

3.1 地表参数的敏感性分析

敏感性分析步骤为:① 首先对各覆盖类型进

行 GA-SOFM 网络训练,获得正常情况下的网络映射关系和地表温度输出;② 重新构造输入参数样本;③ 对于网络输入参数中的其他参数样本,则全部取相应的参数样本均值;④ 将上述网络输入参数代入已经训练好的网络中,得到待分析参数对应的地表温度输出;⑤ 将此地表温度输出与正常情况下的地表温度输出进行比较,分析由输入参数变化导致的地表温度变化情况,如果地表温度变化范围较大,说明参数敏感性较高;否则,参数敏感性较低。

分析结果表明,在植被覆盖区,输入参数的敏感性分为三个层次:直接关系土壤水分的参数 SWC 对估算结果的影响最大;其次是间接参数 TVDI、红光波段及近红外波段的反射率,其他参数对网络输出的贡献很小。在裸土区输入参数中,RVI、红光波段与近红外波段的反射率则是主要的影响因子,说明裸土区光谱空间的差异比反演的土壤水分和含沙量更重要,而且 TVDI 和 NDVI 比起 SWC 和 SSC 还要重要,也证实了光谱信息的重要性。城镇区则主要依靠红光波段与近红外波段的反射率,其他参数的贡献只占到全部 1/3 左右,显然结论符合城镇是建筑物、裸土、植被及水体的混合体,指数参数很难发挥作用。水面主要依赖于红光波段的反射率及相关联的 RVI 指数,这是由于水体中叶绿素的分布状况对水面温度有一定的影响,而近红外波段的反射率及相关指数的影响较小。

3.2 融合结果与精度分析

利用训练好的 GA-SOFM 网络分别在两种模式下进行融合计算,并将融合后 90 m 空间分辨率的地表温度数据与 ASTER 温度产品(90 m)进行比较,分别统计出方差、均值及相关系数等。融合结果及分析见图 1 和表 2。

将采用 GA-SOFM 神经元网络方法的融合结果与文献[1]的估算结果进行比较发现,本文方法精度约提高 3~4 倍左右,如图 2 所示。

表 2 两种模式下利用 GA-SOFM 网络地表温度融合结果与 ASTER 产品比较

Tab. 2 Comparing Between Fusion of Land Surface Temperature and ASTER Products Under Two Modes

覆盖类型	估算模式	均方根	归一化	平均	最小	最大	线性相关系数
		误差 (MSE)	均方根误差	绝对值误差	绝对值误差	绝对值误差	
植被覆盖区	模式 1	0.000 176	0.916 008	0.010 300	6.29×10^{-6}	0.063 289	0.585 000
	模式 2	0.000 169	0.913 224	0.010 219	5.91×10^{-7}	0.061 898	0.560 031
裸土覆盖区	模式 1	0.000 159	1.250 386	0.009 915	2.38×10^{-6}	0.059 348	0.623 734
	模式 2	0.000 064 1	0.504 555	0.005 866	7.01×10^{-7}	0.059 836	0.716 934
城镇覆盖区	模式 1	0.000 195	1.581 621	0.011 096	1.30×10^{-7}	0.068 638	0.428 686
	模式 2	0.000 336	2.719 702	0.014 877	2.09×10^{-6}	0.065 066	0.225 407
水面覆盖区	模式 1	0.000 401	1.354 696	0.015 950	1.76×10^{-5}	0.081 059	0.508 297
	模式 2	0.000 395	1.142 567	0.015 668	4.21×10^{-6}	0.075 639	0.523 681

总的来看,两种模式下,植被与城镇覆盖区的融合精度比较接近,但城镇覆盖区在模式 2 时的融合精度显著下降;而裸土和水面覆盖区的融合精度基本一致。其原因是:植被覆盖区内存在多种覆盖度,即存在多种不同面积比例的裸土、植被混合像元,由这些像元反演出的地表参数对应着较高敏感性的网络输入参数,如 SWC 等。当利用低分辨率的地表温度作为已知条件时,输入网络的信息主要由中、高覆盖度混合像元反演的地表参量提供,而低覆盖度混合像元提供的信息在空间分辨率降低时已经被大幅度抑制或削减,所以网络训练出的映射关系更适合中、高覆盖度的像元,对低覆盖度像元的响应较弱,导致模式 2 的估算精度有所下降。另外,为了检验不同植被覆盖度对估算精度的影响,分别进行了覆盖度大于

0.5 和小于 0.2 时两种模式估算下的子像元地表温度计算。结果表明,对于高植被覆盖度条件,两种模式的估算精度都很高,相反,估算精度都很低;但在两种不同植被覆盖度条件下,显然模式 1 的精度都是最好的。对于城镇覆盖区也存在相同的规律。对于裸土和水面覆盖区,正好与前两者相反,主要是由于二者受混合像元问题的影响较小,像元值大体相近。采用模式 1 时,网络获得的输入信息中包含了较多的异常温度噪声成分,致使网络估算精度较低;而采用模式 2 时,分辨率的降低过程即是空间域的低通滤波,使网络输入参数中自带的噪声得到一定的消除,裸土和水面覆盖区的估算精度有所提高,但提高的幅度有限。试验表明,估算采用的 VNIR 和 T_s 数据空间分辨率的差异不能太大,限制在 3~5 倍间为宜。




图 1 利用 VNIR(90 m)- T_s (360 m、1 080 m) 两种模式下地表温度融合结果

Fig. 1 Results of Fusion of Land Surface Temperature Under Two Modes




图 2 GA-SOFM 与植被指数法^[1]模拟精度比较

Fig. 2 Comparison of Fusion Accuracy Between GA-SOFN and Vegetation Index Method^[1]

4 结 语

本文方法无需地面大量的观测数据,直接通过两种遥感数据进行融合,方法的技术可行性较强;方法简便易行,具有很好的可操作性和重复性,非常适合缺少地表先验知识条件下的高分辨

率地表温度估算。如果考虑短时期内环境和地表修正因子,并建立相应的误差修正模型,该方法还可用于连续时相的地表温度场估算。由于该方法是基于不同地表分类进行的,分类误差会对融合精度有很大影响,所以,需要选择更为适合和准确的分类方法,提高分类精度,减少噪声像元对神经网络映射关系的影响。下一步将利用现有的卫星

数据进行大量的验证,完善融合方法,并引入误差修正模型,使融合精度逐步提高。

参 考 文 献

[1] 韩玲,吴汉宁. 多源遥感影像数据融合方法在地学中的应用[J]. 地球科学与环境学报, 2005, 27(3): 77-80

[2] Kustas W P, Norman J M, Anderson M C, et al. Estimating Subpixel Surface Temperatures and Energy Fluxes from the Vegetation Index-radiometric Temperature Relationship[J]. Remote Sensing of Environment, 2003, 85(4):429-440

[3] Fischer A. A Model for the Seasonal Variations of Vegetation Indices in Coarse Resolution Data and Its Inversion to Extract Crop Parameters[J]. Remote Sensing of Environment, 1994b,48(4): 220-230

[4] Carlson T N, Gillies R R, Perry E M. A Method to Make Use of Thermal Infrared Temperature and NDVI Measurements to Infer Soil Water Content and Fractional Vegetation Cover[J]. Remote Sensing Reviews, 1994, 52: 45-59

[5] 刘培君, 张琳. 卫星遥感估测土壤水分的一种方法[J]. 遥感学报, 1997, 1(2):135-138

[6] Thomas J J, Daoyi C, Michael C, et al. Vegetation Water Content Mapping Using Landsat Data Derived Normalized Difference Water Index for Corn and Soybeans[J]. Remote Sensing of Environment, 2004, 92:475-482

[7] Qi Shuhua, Wang Changyao, Niu Zheng. Evaluating Soil Moisture Status in China Using the Temperature/Vegetation Dryness Index (TVDI) [J]. Journal of Remote Sensing, 2003, 7(5):420-427(in Chinese)

[8] 肖青. 机载遥感数据的定量化研究[D]. 北京:中国科学院遥感应用研究所, 2002

[9] Noilhan J, Mahfouf J F. The ISBA Land Surface Parameterization Scheme [J]. Global Planet Change, 1996, 13: 145-159

第一作者简介:杨贵军, 博士生。主要从事定量遥感、图像分析处理、3S集成开发及资源环境遥感监测等相关领域的研究。
E-mail:guijun. yang@163. com

Fusion of Visible and Thermal Infrared Remote Sensing Data
Based on GA-SOFM Neural Network

YANG Guijun¹ LIU Qinhuo¹ LIU Qiang¹ GU Xingfa¹

(1 State Key Laboratory of Remote Sensing Science, Institute of Remote Sensing Applications, Chinese Academy of Sciences, P. O. Box 9718, Datun Road, Chaoyang District, Beijing 100101, China)

Abstract: An approach which can take advantage of high spatial resolution feature of visible data and high temporal resolution feature of thermal infrared data, is adapted by a nonlinear fusion method based on GA-SOFM-ANN to map the relation between retrieved land surface parameters from visible data and temperature. According to this method, a result of fusing both visible data with spatial resolution feature and thermal infrared data with temporal feature is finished. A case of testing method is showed, utilizing the ASTER data. The conclusions show that it is a new approach to quickly estimate and acquire high resolution land surface temperature.

Key words: fusion; visible data; thermal infrared; land surface parameter; GA-SOFM

About the first author: YANG Guijun, Ph.D candidate, majors in quantitative remote sensing, digital image processing, 3S technology inter-
gration and remote sensing monitoring of resources and environment.
E-mail: guijun. yang@163. com