

# 科尔沁沙地土壤表层水分遥感反演模型研究

张宗海, 张建平

(内蒙古航空遥感测绘院, 内蒙古 呼和浩特 010010)

**摘要:** 为了对三北防护林体系和科尔沁沙地的沙漠化进行监测, 选择内蒙古翁牛特旗作为实验区, 利用 Landsat TM 遥感数据对实验区进行了地表土壤水分反演。文中采用热惯量法、温度植被干旱指数法和 BP 神经网络法进行地表土壤水分的反演, 3种算法均能较好地反映地表水分的空间分布趋势。并对三种反演算法建立的土壤含水量遥感信息模型进行了精度检验。统计结果表明: BP神经网络法建立的遥感信息模型精度最高; 温度植被干旱指数法建立的遥感信息模型精度居中; 基于热惯量法建立的土壤含水量遥感信息模型精度最低。实验结果为三北防护林和科尔沁沙地沙漠化监测奠定了部分数据基础。

**关键词:** 地表土壤水分反演; 热惯量法; 温度植被干旱指数法; BP神经网络

中图分类号: S152.7 文献标识码: A 文章编号: 1672-643X(2011)06-0127-06

## Research on the soil surface moisture retrieval model by remote sensing in Horqin sandy

ZHANG Zonghai, ZHANG Jianping

(Inner Mongolia Aviation Remote Sensing Surveying and Mapping Court Hohhot 010010, China)

**Abstract:** In order to monitor the desertification of the three-north shelterbelt and Horqin sandy, the paper selected Wengniute county of Inner Mongolia as an experimental area and displayed the surface soil moisture by using Landsat TM remote sensing data. This paper adopted the thermal inertia method, temperature vegetation drought index method and the BP neural network method to display the surface soil moisture, all of the three algorithms can better reflect the spatial distribution trend of surface soil moisture. And respectively executed precision inspection. Statistical results showed that the BP neural network method possessed the highest precision, temperature vegetation drought index method was secondary, the thermal inertia method was lowest. The experimental results can supply the part data foundation for the monitoring in three north shelterbelt and the desertification of Horqin sandy land.

**Key words:** soil surface moisture retrieval; thermal inertia method; temperature vegetation dryness index; BP neural network

土壤水分(Soil Moisture)是说明土壤含水量和持水能力的一个量,是用来研究土壤水分状况及其对植物有效性的重要环境因子<sup>[1-3]</sup>。也是农业气象、气候和环境研究中不可缺少的研究因子<sup>[4-6]</sup>。采用遥感技术提取土壤表层水分,与传统手段相比具有范围大、速度快、费用低、时态一致和数据连续等优点,因而在荒漠化监测、病虫害监测、预测林业灾情等得到广泛应用。Landsat TM的热红外波段(TM6)具有比NOAA、MODIS热红外波段更高的空间分辨率,适合于用来进行地表温度和热空间分布的精确分析进而确定土壤水分和热红外波段(TM6)

的相互关系。利用遥感方法进行土壤水分监测的研究过程中,根据研究目的的不同建立了各自不同的遥感反演模型。陈怀亮等在前人研究的基础上认为遥感监测土壤水分的主要方法有:热惯量法、作物缺水指数法、微波遥感、距平植被指数、热红外等方法<sup>[7-11]</sup>。本文采用了热惯量遥感信息模型、温度植被干旱指数法(TVDI)、BP神经网络法三种方法建立内蒙古翁牛特旗地区科尔沁沙地2008年8月25日土壤含水量的精确遥感信息模型,并利用理论精度和实际精度分别对三种方法建立的土壤含水量遥感信息模型进行了精度检验。

收稿日期:2011-08-28; 修回日期:2011-09-06

作者简介:张宗海(1965-),男,内蒙古呼和浩特人,高级工程师,主要从事大地测量和遥感应用、3S集成开发及遥感监测等相关领域研究。

通讯作者:张建平(1983-),男,内蒙古呼和浩特人,硕士,主要从事摄影测量和遥感应用研究。

# 1 研究区概况与研究方法

## 1.1 研究区概况

翁牛特旗地处大兴安岭西南段与七老图北端山脉汇接地带,科尔沁沙地西缘。地理坐标为东经 $117^{\circ}49' \sim 120^{\circ}43'$ ,北纬 $42^{\circ}26' \sim 43^{\circ}25'$ 。全境东西长250 km,南北宽84 km,全旗地势西高东低,西部最高海拔2 025 m,东部海拔最低286 m。地理环境复杂多样,中低山和丘陵约占土地总面积的66.1%。平原占33.9%。地貌特征自西向东依次为西部中山熔岩台地、中部低山黄土丘陵、东部平原沙丘三个类型区<sup>[12]</sup>。

采用 Landsat TM 遥感影像作为影像数据源,影像获取日期:2008年8月25日。对原始数据进行投影变换,投影转化为:GCS\_Krasovsky\_1940 Albers Conical Equal Area。根据野外测得的GPS控制点,对图像进行精确的几何校正(校正误差小于0.5个像元),大气校正等数据预处理。最后根据翁牛特旗行政边界从中切取覆盖翁牛特旗的子像元进行研究。研究区分布如图1所示。




图1 研究区分布图

## 1.2 遥感反演土壤水分理论基础

### 1.2.1 热惯量法

土壤热惯量是度量土壤热惰性的物理量,反映土壤阻止热变化的能力。它随土壤密度、热传导率、热容量的增加而增加,而土壤密度、热传导率、热容量等特性的变化在一定条件下取决于土壤含水量的变化,土壤热惯量与土壤含水量呈正相关关系。此外,土壤湿度控制着土壤表层温度日较差,土壤日较差与土壤含水量之间呈负相关关系,土壤日较差可利用卫星遥感数据获得。因此,可以使用热惯量法研究土壤水分。热惯量为:

$$P = \sqrt{\lambda \rho c} \quad (1)$$

式中: $P$ 为热惯量 $J/(m^2 \cdot K \cdot s^{1/2})$ , $\lambda$ 为热导率, $J/(m \cdot K \cdot s)$ , $\rho$ 为土壤密度 $kg/m^3$ , $c$ 为比热, $J/(kg \cdot K)$ 。

由于热惯量受其它因素影响,获取比较复杂。在实际应用时,常用表观热惯量 $ATI$ 来代替热惯量 $P$ :

$$ATI = \frac{1 - A}{T_d - T_n} \quad (2)$$

式中: $T_d$ 、 $T_n$ 分别为昼夜温度, $A$ 为全波段反照率;有了表观热惯量 $ATI$ 后,利用实测土壤含水量和表观热惯量进行回归分析,一般用下列经验公式计算土壤水分 $W$ 即:

$$\text{线性模式为: } W = a + b \times ATI \quad (3)$$

$$\text{幂指数模式为: } W = e^a (ATI)^b \quad (4)$$

式中: $a$ 和 $b$ 为回归系数。

### 1.2.2 温度植被干旱指数法(TVDI)

国内外许多学者研究发现:不同空间尺度和时间分辨率的地表温度( $T_s$ )和植被指数(NDVI)的关系之间存在明显的负相关关系。Price<sup>[13]</sup>等研究发现在植被覆盖和土壤湿度的变化范围较大区域内,以遥感资料获得的NDVI和 $T_s$ 为横纵坐标的散点图呈三角形。Moran<sup>[14]</sup>等从理论的角度分析,认为地表温度与植被指数的散点图呈梯形的关系。

Sandholt<sup>[15]</sup>等在研究土壤湿度时发现了 $T_s$ -NDVI的特征空间中存在很多等值线,于是提出了温度植被干旱指数(Temperature-Vegetation Dryness Index, TVDI)的概念。TVDI仅仅依靠图像数据通过植被指数和地表温度计算得到,其定义为:

$$TVDI = \frac{T_s - T_{s_{\min}}}{T_{s_{\max}} - T_{s_{\min}}} \quad (5)$$

式中: $T_{s_{\min}}$ 表示最小地表温度,对应的是湿边; $T_s$ 是任意像元的地表温度; $T_{s_{\max}} = a + bNDVI$ 为某一NDVI对应的最高温度,即干边; $a$ 、 $b$ 是干边拟合方程的系数。

在 $T_s$ -NDVI特征空间中,干边上 $TVDI = 1$ ,在湿边上 $TVDI = 0$ 。对于任一像元,利用NDVI确定 $T_{s_{\max}}$ ,根据 $T$ 在 $T_s$ /NDVI梯形中的位置,计算TVDI。TVDI越大,土壤湿度越低,TVDI越小,土壤湿度越高。使用TVDI方法反演土壤湿度具有模型参数可由图像数据直接获得的特点,计算简单方便,可以直接获得同一图像水分状况的相对土壤湿度值。

### 1.2.3 BP神经网络法

人工神经网络(ANN)具有很强的非线性映射能力,因而为土壤水分含量的反演提供了一种新的方法和手段<sup>[16-17]</sup>。BP网络模型是一种监督训练的多层神经网络,由输入层、隐含层和输出层组成。层间各个神经元实现全连接,同层神经元之间不连接。其算法的基本思想为:首先按随机给定的初始权值,从输入层经隐含层逐层计算各单元的输出值,然后计算模型实际输出值与期望输出值之间的误差,如其不符合要求,则沿误差最

大的方向反传回去,对各层权值进行调整,直至误差小于预定值。3层BP神经网络结构见图2。




图2 隐层为一层的BP网络的结构

网络共分为三层:  $i$  为输入层节点;  $j$  为隐层节点;  $k$  为输出层节点。定义网络的学习误差函数为

$$E = \frac{1}{2} \sum_k (d_k - y_k)^2 \quad (6)$$

式中:  $d_k$  表示网络的期望输出;  $y_k$  表示网络的实际输出。于是可推出各层权值修正公式如下:

(1) 隐含层与输出层:

$$\begin{aligned} w_{jk}(t+1) &= w_{jk}(t) + hd_k y_j \\ d_k &= y_k(1 - y_k)(d_k - y_k) \end{aligned} \quad (7)$$

(2) 输入层与隐含层:

$$\begin{aligned} w_{ij}(t+1) &= w_{ij}(t) + \eta \delta_j y_i \\ \delta_j &= y_j(1 - y_j) \sum_k \delta_k w_{jk} \end{aligned} \quad (8)$$

式中:  $\eta$  为学习率;  $\delta_k$   $\delta_j$  为修正值。

### 1.2.4 土壤含水量遥感信息模型

(1) 利用热惯量法反演土壤表层水分。有了表

观热惯量  $ATI$  后,常用下列线性经验公式计算出土壤水分  $W$  即:

$$W = a \times ATI + b \quad (9)$$

式中:  $ATI$  为表观热惯量,  $a$ 、 $b$  为回归系数。当然也可采用幂函数等非线性经验公式<sup>[18]</sup>。用实测的地面土壤水分数据与表观热惯量进行回归分析,最终得到的表观热惯量与土壤含水量的关系见图3,最后用拟合的方程反演土壤含水量见图4。

(2) 使用温度植被干旱指数法(TVDI)反演土壤水分。本文以2008年8月25日的  $T_s - NDVI$  特征空间为例,研究如何确定特征空间的干湿边参数。

从图5可以看出最大温度形成的点线主要分成4个部分:  $NDVI < 0$ ,  $0 < NDVI < 0.2$ ,  $0.2 < NDVI < 0.6$  和  $NDVI > 0.6$ 。在分析时,不考虑  $NDVI$  小于0的像元,这是因为  $NDVI < 0$  的地表主要为水体、云或雪,可以认为地表的湿度为100%。按照TVDI的原理,假定植被指数和陆地表面温度呈负线性关系,随着植被指数的增加,陆地表面温度最大值逐渐降低。但实际情况并非如此。实验证明,在干旱、半干旱地区,虽然植被的  $NDVI$  值高于裸土的  $NDVI$  值,植被可以被检测出来,但由于植被覆盖度很低,  $NDVI$  很难指示区域的植物生物量;已有研究显示,作物生长初期  $NDVI$  将过高估计植被覆盖度,而在作物生长的后期  $NDVI$  估计值偏低。因此,利用  $NDVI$  在植被发育中期或中等覆盖度(低-中等叶面积指数)地区进行植被检测更为适宜。




图3 表观热惯量与土壤含水量关系图




图4 热惯量法反演的土壤含水量图




图5 2008年8月25日  $T_s - NDVI$  特征空间图

利用前面所反演得到的  $TM - NDVI$  数据和  $TM - LST$  数据,进行2008年8月份研究区的土壤湿度反演。首先将植被指数和陆面温度合成一个文件,提取相同  $NDVI$  下的不同像元对应的所有温度中的最大陆地表面温度和最小陆地表面温度,形成  $NDVI - T_s$  特征空间图,可以发现,在  $NDVI > 0$  时,随着  $NDVI$  的增大,陆地表面温度的最大值在减小,同时,陆地表面温度的最小值在增大,且陆地表面温度的最大值、最小值与  $NDVI$  呈近似线性关系。用相

应的  $NDVI$  和最大、最小陆地表面温度进行拟合,得到湿边和干边方程,见表1。将方程的系数代入公式(5)中,计算出各像元的  $TVDI$  值。

表1  $T_s - NDVI$  特征空间拟合得到的干边和湿边方程

时间	干边方程	湿边方程
	$T_{s_{max}} =$	$T_{s_{min}} =$
2008 - 08	$-14.036x + 57.336$	$15.275x - 2.347$

以  $TVDI$  值作为不同土壤湿度的分级指标,将

土壤湿度划分为5级,分别是:极湿润( $0 < TVDI < 0.2$ )、湿润( $0.2 < TVDI < 0.4$ )、正常( $0.4 < TVDI < 0.6$ )、干旱( $0.6 < TVDI < 0.8$ )和极干旱( $0.8 < TVDI < 1$ )。由此可得到2008年8月的翁牛特旗土壤湿度分级图,如图6所示。

(3)用BP神经网络法反演土壤表层含水量。使用Matlab7.0的神经网络工具箱进行编程实现。经过多次调试,BP神经网络的训练程序编制如下:

```
P = input;
T = water;
net = newff( minmax( P ), [3 1], { 'tansig' ,
'purelin' } , 'traingdm' );
net.trainParam.mem_reduc = 4;
net.trainParam.show = 50;
net.trainParam.lr = 0.05;
net.trainParam.epochs = 5000;
net.trainParam.goal = 1e - 2;
net.trainParam.mc = 0.8;
rand( 'state', sum( 100 * clock ) )
net = init( net );
[net,tr] = train( net , P , T );
```

上式中,  $\text{input}$  是30组由LST、NDVI和NDWI组成的三维向量输入样本矩阵,选择这三个参量的原因是因为这三个参量在回归分析的时候对土壤含水量的影响都比较敏感;  $\text{water}$  是由相应实测土壤水分含量组成的一维矩阵;隐含层节点数视问题的复杂度经实验确定,一般确定隐含层节点数的方法采用试探法,先设定一个数为隐节点数,如果训练误差不能下降到所需范围就增加隐节点数,如果误差已经很小而分类效果依然很差,说明隐节点数过多,此时需适当减少隐节点数。通过不断测试本文中隐含层设置为3个神经元;隐含层训练函数为  $\text{tansig}$  函数;输出层训练函数为  $\text{purelin}$  线性函数;通过动量批梯度下降函数  $\text{traingdm}$  来调整权值和阈值;  $\text{lr}$  为学习率;  $\text{mc}$  为用来校正梯度的动量系数;  $\text{epochs}$  为网络训练次数;  $\text{goal}$  为目标均方误差。

网络训练3542次达到收敛,网络训练结束后。将30组随机选择的检验数据输入神经网络进行仿真,通过与实测值比较发现:平均相对误差达到15.21%,相对误差在10%以下的占45.62%,相对误差在20%以下的占92.46%,而将检验数据分别代入热惯量土壤水分反演模型和温度植被干旱指数模型,平均相对误差是12.10%,相对误差在10%以下的占54.43%,相对误差在20%以下的占

92.33%。(详见表2)同时,用BP神经网络模型反演出整个研究区域的土壤水分含量见图7,由图7可知,离河流、水域越远和沙地主体区域颜色越深,表明土壤水分含量较低,这符合研究区—翁牛特旗的实际情况,这也说明模拟结果是基本可靠的。

通过以上对比发现,用神经网络进行土壤水分的反演结果精度较高,说明用神经网络进行土壤含水量的反演是一种很有前途的反演方法。

表2 神经网络与统计算法的反演的土壤相对含水量数值比较  $^{\circ}\text{C}, \%$

LST	NDVI	NDWI	实测 含水量	神经网 络模型	热惯量 模型	TVDI 模型
28.5027	0.3530	0.36446	55.2	46.3	55.0	45.4
26.9783	0.3996	0.3851	55.3	66.0	63.3	60.8
30.9717	0.3043	0.2630	56.2	67.0	47.8	58.2
27.9218	0.3745	0.3968	57.9	61.3	59.1	60.3
27.9104	0.3781	0.4101	58.5	62.4	59.9	55.7
27.9320	0.3555	0.3387	59.7	54.8	54.7	63.4
24.8470	0.3548	0.4003	60.8	56.0	59.5	55.0
28.3104	0.3733	0.3464	63.5	54.6	60.5	57.2
28.4573	0.3769	0.3657	66.0	75.6	67.8	68.4
28.0168	0.4111	0.4079	67.9	67.6	65.1	66.5
27.5902	0.4029	0.3927	68.6	63.8	62.6	70.2
28.0600	0.3885	0.3994	74.1	67.2	64.5	67.4
27.2902	0.4006	0.4114	79.6	67.0	63.2	64.3
27.4467	0.3957	0.4208	60.0	33.4	49.3	53.4

## 2 土壤含水量精度检验与分析

### 2.1 精度检验

本研究对上述三种方法反演的土壤含水量进行精度检验:①利用理论精度进行精度检验,也就是对样地数据进行统计分析<sup>[19]</sup>,通过假设检验判定遥感反演的土壤含水量是否落在给定的区间内;②利用实际精度进行精度检验,也就是通过将所有实测样地的平均含水量和反演后的样地的平均含水量进行对比分析,评定精度的优劣。

应用2008年8月25日翁牛特旗的1:10万影像图,对调查区域进行了判读,综合考虑TM影像,找出其中影像单元比较均一、采样地块与周围土地各性状上差异不大,土壤水分状况具有代表性、取样方便的样方100个。具体的调查方法是在预选出的调查图斑内,选择具有代表性的样方,样方大小为(30 m × 30 m)与影像上一个像元所代表的地面大小相对应,每个样方内调查的样点设置如图8所示,最后取均值。用GPS定位确定精确的样方地理位置,并对样方进行植被、土壤等方面的各项因子调查。




图 6 翁牛特旗 2008 年 8 月土壤湿度分级图




图 7 神经网络反演的研究区土壤水分含量分布图




图 8 每个样地中样点的设置

以草地为例 样地实测的含水量均值:  $N = 30$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = 0.041065 \quad (10)$$

样本方差:

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = 4.15 \times 10^{-4} \quad (11)$$

估计值  $\bar{y}$  的方差:

$$v(\bar{y}) = \frac{s^2}{n} = 2.025 \times 10^{-5} \quad (12)$$

当  $\alpha = 0.005$  时抽样绝对误差:

$$\begin{aligned} \Delta \bar{y} &= t_{n-1} \sqrt{v(\bar{y})} \\ &= 2.86 \times 0.0045 = 0.01287 \end{aligned} \quad (13)$$

置信区间为(0.02769 0.05343)。

当  $\alpha = 0.025$  时抽样绝对误差:

$$\begin{aligned} \Delta \bar{y} &= t_{n-1} \sqrt{v(\bar{y})} \\ &= 2.09 \times 0.0045 = 0.009405 \end{aligned} \quad (14)$$

置信区间为(0.03115 0.04997)。

当  $\alpha = 0.05$  时抽样绝对误差:

$$\begin{aligned} \Delta \bar{y} &= t_{n-1} \sqrt{v(\bar{y})} \\ &= 1.73 \times 0.0045 = 0.007785 \end{aligned} \quad (15)$$

置信区间为(0.03277 0.04835); 从热惯量法反演的土壤含水量图像中截取一小块含有草地的反演图像, 计算得到土壤含水量均值为 0.02933, 在置信区间为  $\alpha = 0.005$  内, 计算反演的相对误差为:

$$E = \frac{D_y}{y} = \frac{0.01287}{0.04056} = 0.3173 \quad (16)$$

所以利用热惯量法反演的土壤含水量理论精度为:

$$\zeta = (1 - E) \times 100\% = 68.27\% \quad (17)$$

式中:  $\zeta$  表示理论精度。

依此类推, 分别从温度植被干旱指数法、BP 神经网络法反演的土壤水分图像中截取一小块草地的反演结果图像, 计算各自土壤含水量均值分别为 0.04896 和 0.03374, 在置信区间为  $\alpha = 0.025$  和  $\alpha = 0.05$  内, 计算得到温度植被干旱指数法、BP 神经网络法反演出来的土壤含水量理论精度分别为

76.82%、81.81%。

计算实测样地的平均土壤含水量: 取  $N = 41$

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i = 0.051637 \quad (18)$$

分别从热惯量法、温度植被干旱指数法和 BP 神经网络法反演出的土壤含水量图像中, 分别从各类中找出 41 个实测样地对应的图像像元的土壤含水量, 它们的平均值为:

$$\bar{y}_{\text{samp1}} = \frac{1}{n} \sum_{i=1}^n y_{\text{samp1}} = 0.06337 \quad (19)$$

$$\bar{y}_{\text{samp2}} = \frac{1}{n} \sum_{i=1}^n y_{\text{samp2}} = 0.05879 \quad (20)$$

$$\bar{y}_{\text{samp3}} = \frac{1}{n} \sum_{i=1}^n y_{\text{samp3}} = 0.05537 \quad (21)$$

式中:  $\text{samp1}$ 、 $\text{samp2}$ 、 $\text{samp3}$  分别表示实测样地数据对应的利用热惯量法、温度植被干旱指数法、BP 神经网络法反演得到的土壤水分图像像元。所以, 土壤含水量的实际精度可以通过下式得到:

$$\varphi_{\text{samp1}} = \left(1 - \frac{\bar{y}_{\text{samp1}} - \bar{y}}{\bar{y}}\right) \times 100\% = 77.28\% \quad (22)$$

$$\varphi_{\text{samp2}} = \left(1 - \frac{\bar{y}_{\text{samp2}} - \bar{y}}{\bar{y}}\right) \times 100\% = 86.15\% \quad (23)$$

$$\varphi_{\text{samp3}} = \left(1 - \frac{\bar{y}_{\text{samp3}} - \bar{y}}{\bar{y}}\right) \times 100\% = 92.17\% \quad (24)$$

式中:  $\varphi$  表示实际精度;  $\bar{y}$  为实测土壤含水量均值;  $\bar{y}_{\text{sample}i}$  为利用各自模型反演得到的像元土壤含水量均值 ( $i = 1, 2, 3$ )。

## 2.2 结果分析

从上面三种模型反演得到的土壤水分分布情况看, 依次按沙地 - 草地 - 农田 - 水库的顺序土壤水分含量逐渐增加, 通过实地考察对比, 这也比较符合本研究区土地类型分布规律。通过上面的精度检验结果我们得到下面的结论: 利用 BP 神经网络法建立的遥感信息反演模型精度最高, 理论精度和实际精度分别为 81.81% 和 92.17%; 使用温度植被干旱指数法(TVDI)反演的土壤水分精度次之, 理论精

度和实际精度分别达到 76.82% 和 86.15%; 利用热惯量法反演的土壤含水量理论精度和实际精度分别为 68.27% 和 77.28% 精度最低。

### 3 讨论与结论

#### 3.1 结论

本文以 Landsat TM 影像为数据源,以科尔沁沙地西缘内蒙古翁牛特旗作为研究试验区。首先完成了对遥感图像进行辐射校正、几何校正、大气校正等预处理,为土壤含水量的定量反演做数据准备。接下来进行了研究区地表反照率( ALBEDO)、植被指数( NDVI)、地表温度( LST)的计算,然后采用了热惯量遥感信息模型、温度植被干旱指数法( TVDI)、BP 神经网络法三种方法分别建立内蒙古翁牛特旗地区科尔沁沙地土壤含水量的精确遥感信息模型,并利用理论精度和实际精度分别对基于热惯量遥感信息模型、温度植被干旱指数法( TVDI)、BP 神经网络法建立的土壤含水量遥感信息模型进行了精度检验。统计结果表明:BP 神经网络法建立的遥感信息模型理论精度和实际精度最大,分别为 81.81% 和 92.17%; 温度植被干旱指数法建立的遥感信息模型理论精度 76.82%、实际精度 86.15%; 基于热惯量法建立的土壤含水量遥感信息模型理论精度和实际精度最低,分别为 68.27% 和 77.28%。由于地表温度、土壤热惯量除了受土壤含水量影响以外,还受地形、植被、土壤质地、有机质含量等其它因素的影响。从反演精度考虑,在裸土或植被稀疏的地区应该采用热惯量法来进行反演。在植被覆盖较大的区域宜采用温度植被干旱指数法( TVDI) 来反演土壤含水量。

#### 3.2 今后工作的建议

(1) 由于研究区域较大,遥感野外调查受时间、经费、交通等因素限制,大部分样点、样方沿公路设置,数量有限且分布不均匀,如果能在基础数据和地图的基础上只对变化的区域进行专门的调查,能够大幅度提高一次监测或调查的速度。

(2) 利用遥感进行土壤水分含量监测,反演得到的是间接表征土壤水分信息的地表物理参数值。为了进一步提高遥感反演土壤水分的精度,应在遥感反演的地表物理参数和地表物理参数与水分含量建立关系的准确性两个方面进行更加深入的研究。

(3) 植被指数受土壤湿度、土壤颜色、土壤亮度、大气、传感器、云雾等因素的影响和制约,在实际应用中为了保证植被指数的真实性,通过什么方法来消除这些影响有待于进一步研究。

(4) 地表反照率具有地带性分布特征,受地表起伏、植被盖度等因素的影响。在本文中使用了空间分辨率为 90 米的 DEM 数据只进行了地形校正,在以后的研究中如能将高分辨率 DEM 数据引入模型,相信对精度的提升会有一定的帮助。

(5) 在地表温度 LST 的反演过程中,大气参数的估算误差、地表覆盖的遥感分类误差以及地表比辐射率的计算误差等均会对 LST 的反演结果产生影响,本文没有分析这些误差的影响。至于这些参数的影响有多大,还有待今后进一步研究。

#### 参考文献:

- [1] 余涛,田国良. 热惯量法在监测土壤表层水分变化中的研究[J]. 遥感学报,1997,1(1):24-31.
- [2] 刘培君,张琳,艾里西尔·库尔班等. 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.
- [3] 陈怀亮. 麦田土壤水分 NOAA/AVHRR 遥感监测方法研究[J]. 遥感技术与应用,1998,13(4):27-35.
- [4] 隋洪智,田国良,李付琴. 农田蒸散双层模型及其在干旱遥感监测中的应用[J]. 遥感学报,1997,1(3):220-224.
- [5] 张仁华. 对于定量热红外遥感的一些思考[J]. 国土资源遥感,1999(1):1-6.
- [6] 郭广猛,杨青生. 利用 MODIS 数据反演地表温度研究[J]. 遥感技术与应用,2004,19(1):34-36.
- [7] 胡远满,徐崇刑,布仁仓等. RS 与 GIS 在城市热岛效应研究中的应用[J]. 环境保护科学,2002,25(2):1-3.
- [8] 吴泽宁,余弘蜻. 遥感计算土壤含水量方法的比较研究. 灌溉排水学报,2004,23(2):69-72.
- [9] Watson K, Pohn H A. Thermal inertia mapping from satellites discrimination of geologic units in Oman [J]. Journal Of Geophysical Research - Atmospheres, 1974, 2(2): 147-158.
- [10] Bijleveld R A. Tell USA combined surface temperature, soil moisture and evaporation mapping approach [R]. Paper Presented at 12th Int Symp On Remote Sensing of Environment, Manila, Philippines, 1978: 20-26.
- [11] Pratt A, Ellyett C D. The thermal inertia approach to mapping of soil moisture and geology [J]. Remote Sensing of Environment, 1979, 8: 151-168.
- [12] 翁牛特旗志编纂委员会. 翁牛特旗志[M]. 呼和浩特: 内蒙古人民出版社, 1993.
- [13] Price J C. Using spatial context in satellite data to infer regional scale evapotranspiration [J]. IEEE Transactions on Geosciences and Remote Sensing, 1990, (28): 940-948.
- [14] Moron M S, Clarke T R, Inoue Y, et al. Estimating crop water deficit using the relation Between surface air temperature and spectral vegetation index [J]. Remote Sensing of Environment, 1994, (49): 246-163.

(下转第 136 页)

放热系数沿流动方向的变化关系如图6所示。由图可见,在相同的 $Re$ 值时,放热系数沿流动方向呈现单调减小的趋势;不同的 $Re$ 值,放热系数不同,单调减小的趋势相同。这是由于流体在流动过程中温度不断增高,在相同的 $Re$ 值时,与管壁间温度梯度减小,放热系数减小;较高的 $Re$ 值时,流体温度相对低,放热系数相对高。




图7  $Nu$  随  $Re$  的变化关系 图8  $Nuz$  随  $S_1 = S_2$  的变化关系  
( $S_1 = S_2 = 2.0$ ) ( $Re = 2 \times 10^4$ )

放热系数随 $Re$ 的变化关系如图7所示。由图可见:放热系数随 $Re$ 的增大而增大,即 $Nu$ 随 $Re$ 单调增加。对所得数据进行拟合(拟合优度为99.83%),结果为:

$$Nu = -2559066.64 + 6498727.90 \times e^{-2((Re-150360.43)/225882.36)^2} \quad (12)$$

对纵向放热系数累加和得图8纵向总放热系数( $Nuz$ )随纵、横向间距的变化关系。由图可见:放热系数随纵、横向间距增大而减小,即 $Nu$ 随 $Re$ 单调减小。对所得数据进行拟合(拟合优度为99.97%),结果为:

$$Nu = 884062.43 - 185103.03e^{-2((S_1-4.425)/2.770)^2} \quad (13)$$

## 4 结 语

对椭圆管外加热水流动过程这一复杂问题进行了深入研究,获得了如下结论:

(1) 熵产主要发生在管壁表面附近,而在系统内部区域熵产较小,可以忽略。

(2) 熵产随雷诺数的增大而增大,熵产与雷诺数存在对应关系。设计时宜选择较小的雷诺数,产生的熵产较小,对设备的动力消耗有利。熵产随着纵、横向间距增加而减小,熵产与纵、横向间距存在对应关系。设计时间距宜在1.75~2.0间。

(3) 在相同的雷诺数值时,熵产、放热系数沿流动方向呈现单调减小的趋势;不同的雷诺数值,熵产、放热系数不同,单调减小的趋势相同。放热系数随 $Re$ 的增大而增大,且与雷诺数存在对应关系。纵向总放热系数随纵、横向间距增大而减小,且存在对应关系。

## 参考文献:

- [1] 吴双应,李友荣,曾丹苓. 换热管传热过程的熵产分析[J]. 重庆大学学报, 2001, 21(2): 92-95.
- [2] 过增元. 热流体力学[M]. 北京: 清华大学出版社, 1992.
- [3] 黄素逸, 杨金宝, 赵永湘. 横掠椭圆管的放热研究[J]. 流体工程, 1984, 1(10): 11-15.
- [4] 李庆领, 张淑华. 顺排椭圆管束的对流换热及流阻特性[J]. 化工机械, 2001, 24(4): 187-190.
- [5] 陶文铨. 数值传热学[M]. 西安: 西安交通大学出版社, 2001.
- [6] 陈群. 对流传递过程的不可逆性及其优化[D]. 北京: 清华大学, 2008.
- [7] K 霍曼, A 伊齐拉利, F 霍曼. 流体饱和和多孔介质中热发展强迫对流的熵产分析[J]. 应用数学和力学, 2008, 29(2): 902-910.
- [8] 过增元. 热流体力学[M]. 北京: 清华大学出版社, 1992.
- [9] 李万平. 计算流体力学[M]. 武汉: 华中科技大学出版社, 2004.
- [10] 杨伟, 杨琳琳, 孙跃, 等. 分水器二维湍流数值模拟与分析[J]. 水资源与水工程学报, 2010, 21(4): 89-95.
- [11] 王乃华, 滕斌, 高翔, 等. 螺旋翅片管束换热过程的熵产分析[J]. 动力工程, 2009, 29(2): 163-167.

(上接第132页)

- [15] Sandholt I, Rasmussen K, Andersen J. A simple interpretation of the surface temperature /vegetation index space for assessment of surface moisture status [J]. Remote Sensing of Environment, 2002, 79: 213-224.
- [16] Kwod T Y, Yeung D Y. Efficient cross-validation for feed forward neural networks[C]//. In IEEE Conference on Neural Networks. Proceedings, 1995: 2789-2794.

- [17] 马啸, 朱丽萍. 神经网络在应用雷达遥感反演土壤水分中的应用[J]. 水资源研究, 2003, 24(4): 22-24.
- [18] Henrichsen B L. Detention on drought: Ethiopia 1983-1984 [J]. Remote Sensing, 1986, 7(7): 1447-1451.
- [19] Gadallah F L, Csillag F. Desertification multisensor imagery with moment matching [J]. INT. J. Remote sensing, 2000, 21(12): 2505-2511.