

土壤盐分含量的遥感反演研究

扶卿华¹, 倪绍祥^{2*}, 王世新¹, 周 艺¹

(1. 中国科学院遥感应用研究所, 北京 100101; 2. 南京师范大学地理科学学院, 南京 210097)

摘要: 土壤盐碱化是干旱、半干旱农业区主要的土地退化问题, 同时也是一个重要的环境问题。遥感技术能够快速、实时地提供盐碱地的性质、范围、盐碱程度等方面的信息。该文以河北省黄骅市为研究区, 通过对实测的土壤光谱的分析, 发现植被严重干扰了土壤对盐分含量光谱响应关系, 同时, 在 451.42~593.79 nm 波长范围内的土壤反射率对土壤盐分含量较为敏感, 在土壤光谱分析的基础上, 建立了土壤盐分含量反演的相关统计模型。但由于遥感影像特征与土壤盐分含量之间存在较复杂的非线性关系, 因此统计模型反演精度不够理想。因而, 又尝试运用 BP 神经网络方法来反演土壤盐分含量。研究表明, BP 神经网络模型具有很强的非线性拟合能力, 与统计模型相比, 其土壤盐分含量的反演精度有显著提高。

关键词: 土壤; 盐分; 遥感; 神经网络

中图分类号: TP79; S151.9

文献标识码: A

文章编号: 1002-6819(2006)12-0048-07

扶卿华, 倪绍祥, 王世新, 等. 土壤盐分含量的遥感反演研究[J]. 农业工程学报, 2006, 22(12): 48-54.

Fu Qinghua, Ni Shaoxiang, Wang Shixin, et al. Retrieval of soil salt content based on remote sensing[J]. Transactions of the CSAE, 2006, 22(12): 48-54. (in Chinese with English abstract)

0 引言

土壤盐碱化是干旱、半干旱农业区主要的土地退化问题, 获取有关盐化土壤的性状、范围、面积、地理分布及盐化程度等方面的实时、可靠的信息, 对治理盐碱化土壤, 防止其进一步退化和农业可持续发展至关重要。而遥感以其宏观、综合、动态、快速等特点, 已成为监测土壤盐碱化的一种新探测手段。国外利用卫星遥感监测土壤盐碱化始于 20 世纪 70 年代。20 世纪 90 年代以来, 随着遥感数据的光谱、时间、空间分辨率的不断提高, 遥感数据源更加丰富, 方法日趋成熟, 不同类型遥感数据在土壤盐碱化监测中获得广泛运用^[1-8], Bao 等 (1995)^[2] 研究发现: 与一般耕地相比, 盐分含量较高的土壤在可见光和近红外波段的光谱响应较强; 而且土壤的盐分含量越高, 光谱响应越强; 但在红光和绿光波段, 地面植被会影响含盐土壤的光谱响应。DWIVEDI 等 (1998)^[11] 用不同的图像变换方法(如 PCA、HIS、影像差值和比值法等)来研究盐化土壤的动态变化取得了较好的效果。Dehaan (2002)^[6] 利用 Hymap 高光谱影像成功

地绘制了澳大利亚 Murray 盆地土壤盐碱化分布图, 结果发现, 在高度盐化土壤区域, 圣彼得草和 seablite 草是最重要的土壤盐化指示器, 使用光谱角制图(SAM)、匹配滤波(MF)以及光谱特征拟合(SFF)技术同时生成了该区域的土壤盐化指示器分布图。近年来, 中国学者也有不少研究^[9-14], 彭望录 (1997)^[13] 研究了地下水埋深、地下水矿化度和地貌因子对土壤盐碱化的影响, 利用地理信息系统(GIS)技术, 并结合遥感数据和专家经验, 建立了用于综合分析土壤盐碱化的数学模型。关云秀 (2003)^[22] 则运用综合分类法对土壤盐碱化进行了研究, 其主要做法是: ①通过多季相图像数据的综合, 挖掘图像的时间信息; ②通过监督分类与非监督分类的结合, 挖掘影像的光谱信息; ③通过分类后处理过程, 运用图像空间或结构信息, 结合地学相关规律进行综合分析, 进一步消除同物异谱和异物同谱现象对分类结果的干扰。许迪 (2003)^[23] 用 LANDSAT 卫星遥感影像数据, 以及监督分类、植被指数(NDVI)等遥感图像处理方法, 对黄河上游的宁夏青铜峡灌区进行了土壤盐碱分布监测的应用研究。然而, 这些研究大多还是在定性分析层面上, 立足于影像光谱数据进行数理统计处理及实现土壤盐碱化的自动识别分类, 精度还较低, 而定量的机理研究则更为薄弱^[8-12]。本文以河北省黄骅市为研究区, 通过对野外实测光谱的分析, 找出土壤盐分含量的敏感波段范围, 建立土壤盐分含量反演模型, 并针对传统统计模型的不足, 尝试运用神经网络模型来解决土壤盐分含量的遥感反演问题。

收稿日期: 2006-01-16 修订日期: 2006-11-08

基金项目: 国家自然科学基金资助项目(40371081)

作者简介: 扶卿华(1978-), 男, 湖南常德人, 博士研究生, 主要从事遥感与 GIS 应用研究。北京 中国科学院遥感应用研究所, 100101。

Email: fqhuserboy@163.com

*通讯作者: 倪绍祥(1939-), 男, 教授, 博士生导师, 主要从事遥感与 GIS 应用研究。南京 南京师范大学地理科学学院, 210097。

Email: sxni@njnu.edu.cn

1 研究区与数据

河北省黄骅市北接天津, 东临渤海, 地处北纬 $38^{\circ}09'07'' \sim 38^{\circ}38'34''$ 和东经 $117^{\circ}04'32'' \sim 117^{\circ}49'42''$, 总面积 2251 km^2 。土壤以滨海盐渍化潮土和盐土为主。研究采用的数据主要有: 1) 野外实测土壤光谱数据。所用仪器为美国 ASD 公司的 FieldSpec 光谱仪, 波长范围 $300 \sim 1100 \text{ nm}$, 光谱分辨率 3.5 nm , 共 512 个波段, 光谱采样间隔 0.2 nm , 视角角 25° ; 2) 土壤样品化验分析数据, 共 51 个土壤样品; 3) ASTER 影像数据。ASTER 是第一台用于制图和温度精确测量的星载高空间分辨率多通道热红外成像仪。它由 3 个光学子系统组成, 即可见光近红外(VNIR)、短波红外(SWIR) 和热红外(TIR)。其中, VNIR 子系统在可见光与近红外区有三个波段, 空间分辨率为 15 m , 波段范围 $0.52 \sim 0.86 \mu\text{m}$, 可用于识别水体混浊度、泥沙含量, 并能有效区分健康植被和病害植被, 裸露的地表、土壤、岩层、地貌等影像清晰。在本研究中选用 2004 年 1 月 13 日无云覆盖的 ASTER 影像, 此时, 黄骅绝大部分地区植被较少或无植被覆盖裸露。首先利用 6S 模型对 ASTER 影像进行大气纠正, 然后利用在野外用差分 GPS 测定的控制点坐标数据对图像进行几何精纠正, 纠正后总体误差小于 0.5 个像元。此外, 还参考了与研究区有关的图件资料。

2 方法

2.1 地面实测光谱分析

土壤的反射光谱是其本身多种理化性质的综合产物。Csillag 等(1993)^[4]通过实验室反复试验发现了区分不同盐化和碱化过程土壤性状的 5 个有用波段, 即可见光($0.55 \sim 0.77 \mu\text{m}$)、近红外($0.9 \sim 1.3 \mu\text{m}$) 及中红外($1.94 \sim 2.15 \mu\text{m}$, $2.15 \sim 2.3 \mu\text{m}$, $2.33 \sim 2.4 \mu\text{m}$) 波段; 还发现, 当土壤水分含量较少时, 盐化土壤在可见光范围(尤其是蓝波段)的反射率较大。Mougenot 等(1993)^[7]指出, 盐化土壤的反射特征随不同的地表表现形态而不同。总体上, 盐壳比无盐但有作物的地表要显得光滑, 因而在可见光和近红外波段的反射较强。

为了从定量角度研究土壤盐分含量与其反射光谱的关系, 在研究区的不同地点采集了 51 个土样, 并相应地同步测定了 49 个样点的反射光谱, 据此分析反射光谱数据与土壤盐分含量的关系。首先, 在波长 $400 \sim 1000 \text{ nm}$ 范围内, 对 49 个样点的反射光谱数据与土壤盐分含量数据进行相关分析(图 1)。由图 1 可见, 在波长 $400 \sim 1000 \text{ nm}$ 范围内, 两者的 Person 相关系数并不高, 最大值不到 0.4。此外, 还分析了不同植被覆盖下盐化土壤的光谱数据与盐分含量的相关性。在分析中, 用

各样点实测的遥感植被指数 (NDVI) 代表植被状况。NDVI 的计算公式如下

$$NDVI = \frac{\rho_{band3} - \rho_{band2}}{\rho_{band3} + \rho_{band2}} \quad (1)$$

式中 ρ_{band2} 、 ρ_{band3} ——分别代表实测的地面光谱按 ASTER 的 BAND2、BAND3 波段范围计算得到的反射率平均值。由图 2 可见, 当 NDVI 逐渐减小时, 实测光谱数据与土壤盐分含量的相关性明显增大; 反之, 当 NDVI 逐渐增大时, 实测光谱数据与土壤盐分含量之间的相关性在整个 NDVI 变化过程中一直不大(图 3)。其主要原因是: 植被对实测土壤的光谱产生干扰, 且植被覆盖越大此类干扰越大, 即光谱曲线中夹杂了更多植被的特征信息^[15-17]; 反之, 植被覆盖越小, 其影响也越小, 光谱曲线则可更多反映土壤的盐分含量状况。

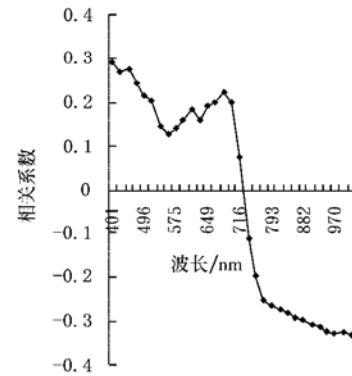


图 1 各波段土壤反射率与土壤盐分含量之间相关系数

Fig. 1 Correlation coefficients between reflectance of each band and soil salt content

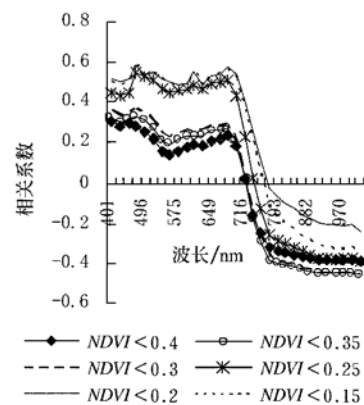


图 2 随着 NDVI 减少各波段反射率与土壤盐分含量相关性的变化

Fig. 2 Changes of correlation coefficients between reflectance of each band and soil salt content with the decrease of NDVI

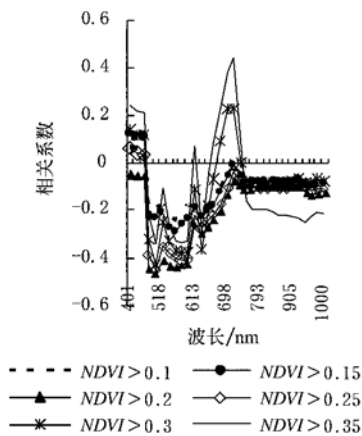


图3 随着NDVI增加各波段反射率与土壤盐分含量相关性的变化

Fig. 3 Changes of correlation coefficients between reflectance of each band and soil salt content with the increase of NDVI

为进一步研究实测光谱的不同波段对土壤盐分含量的敏感程度,又计算了实测光谱在各波段的反射率值的均方差,以及反射率值与土壤盐分含量之间的相关系数和诊断指数。所用诊断指数(P_i)^[24]的计算公式如下

$$P_i = \sigma_i \times R_i \quad (2)$$

式中 σ_i ——样本光谱曲线在波段*i*上反射率数值的均方差; R_i ——波段*i*上的反射率值与土壤盐分含量之间的相关系数。显然, σ_i 越大,样本光谱反射率在此波段的离散程度越大,不同样本在此波段可分性越明显; R_i 的绝对值越大,波段*i*反射率值与土壤盐分含量之间的相关性越好,两者的变化趋势一致或正好相反。分别计算了 P_i 的绝对值、 σ_i 、 R_i 的绝对值,并按从大到小的顺序列出了位于前10位的波段,具体结果见表1、2、3。由表1、2、3可见,波长为451.42~593.79 nm的土壤反射率对盐分含量较为敏感,因此该波段范围较适用于反演研究区土壤的盐分含量。

表1 诊断指数

Table 1 Diagnosis indexes

名次	1	2	3	4	5	6	7	8	9	10
波长/nm	585.88	584.30	587.47	582.72	589.05	581.14	590.63	592.21	593.79	579.56
$ P_i $	0.0601	0.0601	0.0595	0.0594	0.0587	0.0583	0.0577	0.0577	0.0574	0.0572

表2 相关系数

Table 2 Correlation coefficients

名次	1	2	3	4	5	6	7	8	9	10
波长/nm	453.01	454.59	451.42	456.17	457.75	459.33	460.91	462.50	464.08	465.66
$ R_i $	0.7086	0.7085	0.7080	0.7076	0.7073	0.7070	0.7065	0.7062	0.7059	0.7054

表3 标准差

Table 3 Standard deviations

名次	1	2	3	4	5	6	7	8	9	10
波长/nm	584.30	585.88	582.72	587.47	589.05	581.14	590.63	579.56	592.21	593.79
$ \sigma_i $	0.0870	0.0869	0.0861	0.0860	0.0845	0.0844	0.0829	0.0829	0.0828	0.0825

2.2 统计模型的建立与应用

由上节光谱分析可知,研究区的实测土壤反射率数据与土壤盐分含量数据存在较好相关关系。为了将两者的关系进一步量化,尝试建立了两者的统计模型,并用实测的土壤盐分含量数据检验该模型的反演精度。

在光谱分析中,发现植被覆盖过多会严重干扰土壤光谱对土壤盐分含量的响应关系,因此,结合研究区实际情况,本研究选取的影像的时间是一月份,此时,黄骅地区绝大部分地区植被较少,甚至部分地区无植被覆盖(即黄骅地区影像上有90%以上区域的 $NDVI < 0.3$)。于是,在模型样点选择过程中,剔除了植被很多(即

$NDVI > 0.3$)的样点,共选定32个样点,用于建立植被中低度覆盖的土壤盐分含量反演模型。但是正由于在模型建立过程中没有考虑植被多的样点,因此,在植被高覆盖的极少数区域,土壤盐分含量反演结果可能会出现较大误差,如何更好地解决这种情况下的植被干扰问题,还有待进一步研究探讨。

如前所述,440.35~593.79 nm的波段范围较适用于反演土壤盐分含量,与其大致对应的是ASTER的BAND1波段(520~600 nm)。此外,考虑到植被对土壤光谱的影响,因而又分别对比分析了 ρ_{band1} 、 $\rho_{band1} - NDVI$ 与土壤盐分含量的相关性, ρ_{band1} 与土壤盐分含

量的 PEARSON 相关系数为 0.60, R^2 为 0.36; 而 $\rho_{band1} - NDVI$ 与土壤盐分含量的 PEARSON 相关系数为 0.819, R^2 为 0.67。显然, $\rho_{band1} - NDVI$ 与土壤盐分含量的相关性好于 ρ_{band1} 与土壤盐分含量的相关性。其原因是: $\rho_{band1} - NDVI$ 在植被中低度覆盖情况下, 能够在一定程度上考虑了植被的影响, 因而它与土壤盐分含量的相关性明显提高。因此, 本研究采用 $\rho_{band1} - NDVI$ 与土壤盐分含量进行线性回归(见图 4), 得到如下回归方程为

$$y = 1.3788x + 0.3479 \quad (3)$$

式中 y ——土壤盐分含量; x —— $\rho_{band1} - NDVI$, ρ_{band1} 、 ρ_{band2} 、 ρ_{band3} ——分别代表实测的地面光谱按 ASTER 的 BAND1、BAND2、BAND3 波段范围计算得到的反射率平均值。然后, 利用所建统计模型(即 $y = 1.3623x + 0.3669$) 和 Aster 影像数据, 对整个研究区土壤盐分含量进行反演, 其中 51 个样点的模型反演结果和实测数据见表 4。从较大的相对误差可以看出, 统计模型的反演精度不够理想。




图 4 土壤盐分含量反演值(Y)与实测值(X)的散点图

Fig. 4 Scattered diagram between inversed and measured soil salt contents (Y) and (X)

2.3 神经网络模型的建立与应用

人工神经网络(ANN)具有很强的非线性映射能力, 因而为土壤盐分含量的反演提供了一种新的方法和手段^[18, 19]。其中, BP(back-propagation)网络目前应用最为广泛。它采用“误差反向传播”算法, 即有教师指导的 δ 率学习算法。首先由教师对每一种输入模式设定一个期望输出值, 然后对网络输入实际的学习记忆模式, 并由输入层经隐层向输出层传播, 此过程为“模式顺传播”。实际输出与期望输出的差即是误差。按照误差平方最小这一规则, 由输出层往隐层逐层修正连接权值和阈值, 此过程即为“误差反向传播”。随着“模式顺传播”和“误差逆传播”过程的交替反复进行, 不断调整网络的权值和阈值, 使得误差信号最小, 最终使网络的实际输出逐渐向各自所对应的期望输出值逼近。

表 4 使用统计模型的土壤盐分含量反演结果

Table 4 Soil salt content extracted from the statistics model

样点编号	实测土壤盐分含量 /%	预测土壤盐分含量 /%	相对误差 /%	样点编号	实测土壤盐分含量 /%	预测土壤盐分含量 /%	相对误差 /%
1	0.47	0.349	-25.74	27	0.69	0.181	-73.77
2	0.19	0.296	55.79	28	0.64	0.089	-86.09
3	1.20	0.678	-43.50	29	0.54	0.252	-53.33
4	0.20	0.236	18.00	30	0.71	0.377	-46.90
5	0.40	0.677	69.25	31	0.38	0.360	-5.26
6	0.23	0.210	-8.70	32	1.29	0.458	-64.50
7	0.17	0.267	57.06	33	0.48	0.391	-18.54
8	1.20	0.706	-41.17	34	0.44	0.680	54.55
9	0.25	0.416	66.40	35	0.61	0.415	-31.97
10	0.17	0.262	54.12	36	0.58	0.434	-25.17
11	0.12	0.416	246.67	37	0.2	0.224	12.00
12	0.11	0.293	166.36	38	0.38	0.457	20.26
13	0.28	0.773	176.07	39	0.48	0.452	-5.83
14	0.91	0.495	-45.60	40	0.17	0.309	81.76
15	0.42	0.220	-47.62	41	0.09	0.217	141.11
16	0.34	0.545	60.29	42	0.48	0.436	-9.17
17	0.41	0.577	40.73	43	0.31	0.212	-31.61
18	0.28	0.312	11.43	44	0.02	0.036	80.00
19	0.28	1.020	264.29	45	0.02	0.091	355.00
20	0.17	0.919	440.59	46	0.06	0.100	66.67
21	0.74	0.340	-54.05	47	0.11	0.205	86.36
22	1.15	0.696	-39.48	48	0.05	0.023	-54.00
23	0.48	0.263	-45.21	49	0.06	0.236	293.33
24	0.44	0.436	-0.91	50	0.07	0.204	191.43
25	0.31	0.091	-70.65	51	0.13	0.362	178.46
26	1.24	0.215	-82.66				

本研究利用 MATLAB 软件进行网络结构设计, 将 51 个土壤样本数据分成两组: 一组作为训练样本, 共 43 个样本; 另一组为测试样本, 共 8 个样本。Aster 影像数据的 BAND1、BAND2 和 BAND3 反射率数据作为网络的输入, 土壤盐分含量作为网络的输出。在进行网络训练之前, 对神经网络的输入和输出数据进行归一化和标准化处理, 以加快网络的训练速度。神经网络模型中的输入层和隐层采用 Tan-sigmoid 传输函数, 输出层则采用 Purelin 线性传输函数。为了保持系统稳定, 开始选取较小的学习速度, 然后再通过观察训练过程中梯度变化、均方误差变化值和误差下降曲线的判断来进行调整。应指出的是, 采用适当的隐含层结点数是网络成败的关键。如果隐含层结点数太少, 网络可获取解决问题的信息太少, 网络则难以处理复杂的问题; 若隐含层结点数过多, 将使网络训练时间急剧增加。本研究的隐含层节点数的确定采用逐步增长法, 即先从一个较简单的网络开始, 隐层单元数设置为 2 个, 如不符合要求则逐

步增加隐层单元数,直到合适为止。为了确定最佳的隐含层节点数,分别计算了当其它网络参数相同、且最大训练次数都为 1500 次、而隐含层节点数不同情况下训练样本的 R 和 MSE (见表 5)。

表 5 不同隐含层节点数情况下训练样本的 MSE 和 R

Table 5 MSE and R of the training samples with different node numbers in the hidden layer

隐含层节点数	2	3	4	5	6	7	8
MSE	2.799	2.181	0.807	1.120	0.861	0.377	0.105
R	0.626	0.725	0.909	0.910	0.902	0.958	0.989
隐含层节点数	9	10	11	12	13	14	15
MSE	0.115	0.058	0.0159	0.072	0.218	0.662	0.318
R	0.988	0.994	0.992	0.989	0.988	0.938	0.967

通过反复试验,并综合考虑时间效率和模拟效果,隐层的节点数确定为 11 个。在网络训练过程中,有时会产生“过拟合”现象^[20],即训练集的误差被训练得非常小,而当把训练好的网络用于新的数据时却产生很大误差。本研究从以下方面来处理过拟合现象:1) 修改性能函数。典型的性能函数是网络均方差 MSE ,编程时需要将网络性能函数的缺省值 MSE 改为 $MSEREG$,即: $NET.performFcn = 'msereg'$,并指定性能比例值,如: $NET.performParam.ratio = 0.5$,这可在一定程度上抑制过拟合;2) 提前结束。具体做法是,将样本数据分为训练集和监控集两部分,前者用于更新网络权重和偏置量,后者用于防止网络过拟合的出现^[21];3) 尽量合理设置期望误差。从理论上说,期望误差越小越好,但期望误差太小,网络需要的训练时间太长,而且可能出现过拟合现象。在本研究中,通过大量试验,期望误差设置为 0.001。

训练样本的神经网络模型模拟结果见表 6 及其模型反演值与实测值的散点图见图 5,而测试样本的神经网络模型模拟结果见表 7 及其模型反演值与实测值的散点图见图 6。由表 6、7 和图 5、6 可见,与统计模型相比,神经网络模型的土壤盐分预测效果要好得多,其相对误差最大为 37%,最小为 0;而统计模型预测的相对误差最大为 440.59%,最小为 -86.09%。可见,神经网络模型具有很强的线性和非线性拟合能力,在模拟遥感影像特征与土壤盐分含量之间这种比较复杂的关系上具有很大优势。同时,用 BP 神经网络模型反演出整个研究区域的土壤盐分含量见图 7,由图 7 可知,离海越近区域颜色越浅(注:水域统一用全黑色),表明土壤盐分含量较高,这符合研究区——黄骅市的实际情况,这也说明模拟结果是基本可靠的。

表 6 训练样本的网络预测结果

Table 6 Predicted values of the training samples from the model

训练样点编号	实测值 /%	神经网络模型模拟值 /%	相对误差 /%	训练样点编号	实测值 /%	神经网络模型模拟值 /%	相对误差 /%
1	0.020	0.017	-15	22	0.340	0.340	0
2	0.050	0.066	31	23	0.380	0.380	0
3	0.060	0.062	3	24	0.380	0.380	0
4	0.060	0.060	0	25	0.400	0.400	0
5	0.070	0.079	13	26	0.420	0.420	0
6	0.090	0.118	31	27	0.440	0.444	1
7	0.110	0.110	0	28	0.440	0.440	0
8	0.120	0.121	1	29	0.470	0.470	0
9	0.130	0.131	1	30	0.480	0.480	0
10	0.170	0.160	-6	31	0.480	0.480	0
11	0.170	0.167	-2	32	0.480	0.475	-1
12	0.170	0.170	0	33	0.540	0.583	8
13	0.170	0.170	0	34	0.580	0.574	-1
14	0.200	0.160	-20	35	0.610	0.622	2
15	0.200	0.158	-21	36	0.640	0.698	9
16	0.230	0.230	0	37	0.690	0.676	-2
17	0.250	0.183	-27	38	0.740	0.733	-1
18	0.280	0.280	0	39	0.910	0.910	0
19	0.280	0.280	0	40	1.150	1.127	-2
20	0.310	0.217	-30	41	1.200	1.200	0
21	0.310	0.310	0	42	1.200	1.200	0

表 7 测试样本的网络预测结果

Table 7 Predicted values of the test samples from the model

测试样点编号	实测值 /%	神经网络模型模拟值 /%	相对误差 /%	测试样点编号	实测值 /%	神经网络模型模拟值 /%	相对误差 /%
1	0.020	0.020	0	5	0.41	0.500	22
2	0.110	0.101	-8	6	0.48	0.653	36
3	0.190	0.152	-20	7	0.71	0.589	-17
4	0.280	0.384	37	8	1.24	1.290	4




图 5 训练样本土壤盐分含量的实测值(A)与模型预测值(T)的散点图

Fig. 5 Scatter diagram between measured values (A) and predicted values (T) for the training samples




图6 测试样本土壤盐分含量的实测值(A)与模型预测值(T)的散点图

Fig. 6 Scatter diagram between measured values (A) and predicted values (T) for the test samples




图7 神经网络反演的研究区土壤盐分含量分布图

Fig. 7 Map of soil salt content inverted by the ANN model in the study area

3 结论与分析

通过研究, 获得以下初步结论:

1) 对在研究区实测的49个样点的土壤反射光谱的分析表明, 波长451.42~593.79 nm区域的土壤反射率对土壤盐分含量较为敏感, 即该波段范围较适用于研究区土壤盐分含量的反演。

2) 综合考虑实测光谱分析的结果和研究区的实际情况, 选择了32个较少甚至无植被覆盖的样点来建立土壤盐分遥感反演模型。对比分析了 $\rho_{band1} - NDVI$ 与土壤盐分含量的相关性和 ρ_{band1} 与土壤盐分含量的相关性, 结果表明, $\rho_{band1} - NDVI$ 相关性较好, 在较少植被覆盖情况下, 能较好地消除植被信息的干扰, 因此, 选用

$\rho_{band1} - NDVI$ 反演土壤盐分含量。但由于遥感影像特征与土壤盐分含量之间存在较复杂非线性关系, 因此据其所建立的统计模型对土壤盐分含量的反演精度不够理想。

3) BP神经网络模型因具有很强的线性和非线性拟合能力, 与统计模型的预测结果相比, 其土壤盐分含量的反演精度有显著提高, 基本符合研究区土壤盐分分布的实际状况。

为了进一步提高土壤盐分遥感反演的精度, 在BP神经网络模型反演中, 应尝试使用径向函数神经网络方法、遗传算法及支持向量机等其它方法, 以提高人工神经网络的泛化能力。其次, 应通过建立各类盐化土壤和含盐量不同的盐化土壤的光谱库, 并加强对盐化土壤的光谱特征及其与土壤盐分含量之间关系机理的研究。此外, 应进一步深入研究如何更好排除植被、土壤水分、土壤有机质等干扰因素的影响, 以提高模型反演土壤盐分含量的精度。

[参 考 文 献]

- [1] Dwivedi R S, Rso B R M. The selection of the best possible Landsat TM band combination for delineating salt-affected soils[J]. International Journal of Remote Sensing, 1992, 13(11): 2051- 2058.
- [2] Rao B R M, Sankar T R, Dwivedi R S, et al. Spectral behaviour of salt-affected soils[J]. International Journal of Remote Sensing, 1995, 16(12): 2125- 2136.
- [3] Bowers S S, Hanks R J. Reflectance of radiant energy from soils[J]. Soil Science, 1965, 100: 130- 138.
- [4] Csillag F, Pa'sztor L, Biehl L. Spectral band selection for the characterization of salinity status of soils[J]. Remote Sensing of Environment, 1993(43): 231- 242.
- [5] D Wang C, Wilson, Shannon M C. Interpretation of salinity and irrigation effects on soybean canopy reflectance in visible and near-infrared spectrum domain[J]. Int J remote sensing, 2002, 23(5): 811- 824.
- [6] Dehaan R L, Taylor G R. Field-derived spectra of salinized soils and vegetation as indicators of irrigation-induced soil salinization[J]. Remote Sens of Envir, 2002, (80): 406- 417.
- [7] Mougenot B, Epema G F, Pouget M. Remote sensing of salt affected soils[J]. Remote Sens Rev, 1993, 7: 241- 259.
- [8] Dwivedi R S, Sreenivas K, et al. Inventory of salt-affected soils and waterlogged areas: a remote sensing approach [J]. International Journal of Remote Sensing, 1999, 20(8): 1589- 1599.
- [9] 胡庆荣. 含水含盐土壤介电特性试验研究及对雷达图像的相应分析[D]. 中国科学院遥感应用研究所, 2003.
- [10] 骆玉霞. GIS支持下的TM图像土壤盐渍化分级[J]. 遥感

- 信息, 2001, 4, 12- 15.
- [11] 关元秀, 刘高焕. 黄河三角洲盐碱地动态变化遥感监测[J]. 国土资源遥感, 2003, 56(2): 19- 22.
- [12] 关元秀, 刘高焕. 区域土壤盐碱化遥感监测研究综述[J]. 遥感技术与应用, 2001, 16(1): 40- 44.
- [13] 彭望录, 李天杰. TM 数据的 Kauth-Thomas 变换在盐碱土分析中的作用——以阳高盆地为例[J]. 环境遥感, 1989, 4(3): 183- 190.
- [14] 彭望录. 土壤盐渍化量化的遥感与 GIS 实验[J]. 遥感学报, 1997, 1(3): 237- 240.
- [15] 马超飞, 蔺启忠, 马建文, 等. 定量消除植被影响的补偿置换方法研究[J]. 中国图像图形学报, 1999, 4(7): 553- 556.
- [16] 马超飞, 刘素红, 蔺启忠. 专题信息提取中降低植被影响的处理方法研究[J]. 遥感技术与应用, 1998, 13(4): 9- 13.
- [17] 陈晋, 陈云浩, 何春阳, 等. 基于土地覆盖分类的植被覆盖率估算亚像元模型与应用[J]. 遥感学报, 2001, 5(6): 416- 423.
- [18] 高大启. 有教师的线性基本函数前向三层神经网络结构研究[J]. 计算机学报, 1998, 21(1): 80- 86.
- [19] 廖宁放, 高稚允. BP 神经网络用于函数逼近的最佳隐层结构[J]. 北京理工大学学报, 1998, 18(4): 476- 480.
- [20] 闵惜琳, 刘国华. 用 MATLAB 神经网络工具箱开发 BP 网络应用[J]. 计算机应用, 2001, 21(8): 163- 164.
- [21] 李丽霞, 王彤, 范逢曦. 早停止策略在 BP 神经网络中的应用[J]. 数理医药学杂志, 2004, 17(2): 165- 167.
- [22] 关元秀, 刘高焕. 黄河三角洲盐碱地动态变化遥感监测[J]. 国土资源遥感, 2003, 56(2): 19- 22.
- [23] 许迪, 王少丽. 利用 NDVI 指数识别作物及土壤盐碱分布的应用研究[J]. 灌溉排水学报, 2003, 22(6): 5- 8.
- [24] 王成. 地面高光谱数据在作物水肥状况诊断与生物化学参量估算中的应用[D]. 南京: 南京师范大学, 2001.

Retrieval of soil salt content based on remote sensing

Fu Qinghua¹, Ni Shaoxiang^{2*}, Wang Shixin¹, Zhu Yi¹

(1. Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101, China;

2. College of Geographical Sciences, Nanjing Normal University, Nanjing 210097, China)

Abstract: soil salinization is one of the most important problems of land degradation and the basic environmental problem in arid and semi-arid regions. The remote sensing technology can rapidly and timely provide the information about properties, geographical distribution and extent of soil salinization. Taking the city Huanghua of Hebei Province in China as the study area and through the analysis on the data of soil spectrum measured in field, it was found in this study that vegetation affects greatly the spectral response of soil for salt content, and at the same time the spectrum ranging from 451.42 nm to 593.79 nm is much sensitive to the variation in soil salt content and, therefore, based on the analysis of soil spectrum, the relevant statistic model for predicting soil salt content was constructed. However, due to rather complicated non-linear relations existed between image features and soil salt content, the results of soil salt content retrieved from the statistic model is not so ideal. For this reason, an artificial neural network model (BP model) was constructed and applied in the retrieval of soil salt content. Because of its superior ability for solving the non-linear problem, the BP model provided a much better accuracy in retrieval of soil salt content compared with the results from the statistic model.

Key words: soil; salt; remote sensing; artificial neural network