

DOI: 10.5846/stxb201607201479

何宝忠,丁建丽,王飞,张喆,刘博华.基于物候特征的盐渍化信息数据挖掘研究.生态学报,2017,37(9): - .

He B Z, Ding J L, Wang F, Zhang Z, Liu B H. Research on data mining of salinization information based on phenological characters. Acta Ecologica Sinica, 2017, 37(9): - .

基于物候特征的盐渍化信息数据挖掘研究

何宝忠^{1,2}, 丁建丽^{1,2,*}, 王飞^{1,2}, 张喆^{1,2}, 刘博华^{1,2}

1 新疆大学资源与环境科学学院, 乌鲁木齐 830046

2 新疆大学绿洲生态教育部重点实验室, 乌鲁木齐 830046

摘要: 盐渍化是影响植被和作物长势的重要因素, 精确反演盐渍化的时空分布信息至关重要。基于 MOD13A1-NDVI 数据反演生长季开始日期(Start of season, SOS)、生长季结束日期(End of season, EOS)、生长季长度(Length of season, LEN)等物候参数和计算出能高精度反演盐渍化空间分布的多种植被指数、盐分指数、地形指数、干旱指数等参数后作为 BP-ANN 人工神经网络的输入因子来反演盐渍化信息, 同时按照植被类型和地貌类型进行分区来反演盐渍化信息, 以探讨盐渍化受植被和地貌类型的影响。主要结论如下: ①盐渍化的形成受多种因素的影响, 与物候参数大多呈非线性关系, 不能单纯的以某拟合公式来进行表达, 需要借助人工神经网络超强的非线性拟合能力来反演盐渍化信息。②通过深入挖掘植被物候信息, 在融入物候参数后的反演精度显著提高。可决系数 R^2 从 0.68(非物候参数)增加为 0.79(包括物候参数), 但是需要加入地形、影像数据和土壤水分等方面的信息来更加精确的反演盐渍化信息。生物累积量指标 LSI(Large seasonal integral) 和 SSI(Small seasonal integral) 能够很好的表征盐渍化的信息。③划分植被类型后的盐渍化提取精度进一步提高, 可决系数 R^2 达到了 0.88。④以地貌特征作为类型分区后, 反演结果的 R^2 达到了 0.85, 精度较高, 比以植被类型作为分区的精度略小。高程较低区域的盐渍化现象普遍较重, 盐渍化程度受到地形和地貌因素的影响显著。⑤农用地区域多为非盐渍化和轻盐渍化地, 稀疏植被区多为重盐渍化地。研究区的非盐渍化和轻盐渍化地、中盐渍化地和重度盐渍化地比例分别为 53.42%, 13.71%, 32.87%。以上的研究结果实际上是提出了一种融合物候信息和非物候参数来反演盐渍化信息的方法, 进行深入的植被物候监测盐渍化信息方面的数据挖掘, 在融入了物候参数后, 盐渍化的预测精度显著提高。

关键词: 盐渍化; 物候信息; 地表参数; 数据挖掘

Research on data mining of salinization information based on phenological characters

HE Baozhong^{1,2}, DING Jianli^{1,2,*}, WANG Fei^{1,2}, ZHANG Zhe^{1,2}, LIU Bohua^{1,2}

1 College of Resource and Environmental Science, Xinjiang University, Urumqi 830046, China

2 Key Laboratory for Oasis Ecology, Xinjiang University, Urumqi 830046, China

Abstract: Soil salinization is an important factor that affects crop and vegetation growth condition and can result in environmental impacts with considerable economic consequences. Therefore, it is necessary to determine an effective method to monitor spatiotemporal salinity distribution. We used MOD13A1 time-series NDVI data to determine the vegetation phenology, including start of season (SOS), end of season (EOS), length of season (LEN), etc., and calculated several vegetation, salinity, terrain, and drought indexes, and spatial models. These were used as input parameters for the BP-ANN model. Meanwhile, we predict the soil salinity through vegetation and geomorphological partitioning, which described the correlations between vegetation or geomorphic type and salinization. The main conclusions are as follows: salinity is

基金项目: 自治区重点实验室专项基金(2016D03001, 2014KL005); 自治区科技支疆项目(201591101); 2014 级新疆大学博士生科技创新项目(XJUBSCX-2014013); 国家自然科学基金项目(U1303381, 41261090, 41161063); 教育部促进与美大地区科研合作与高层次人才培养项目

收稿日期: 2016-07-20; 修订日期: 2017-03-03

* 通讯作者 Corresponding author. E-mail: Ding_jl@163.com

influenced by many factors, and many of them show non-linear relationships between phenological indicators and salinization, so we utilized artificial neural networks to predict soil salinity than mathematical equations; through a combination of phenology parameters, the precision of inversion salinity R^2 improved from 0.68 (no phenological indicators were included) to 0.79 (phenological indicators were included). However, additional auxiliary data to predict soil salinity, such as terrain, image, and soil moisture parameters should also be included. After the classification of the vegetation, the inversion precision improved obviously, where R^2 increased to 0.88. Phenological characters, such as large seasonal integrals (LSIs) and small seasonal integrals (SSIs) are good indicators to represent soil salinity. After geomorphological partitioning, R^2 increased to 0.85, indicating that it could be a good salinity predictor, but the ability of comprehensive inversion was lower than vegetation type partitioning. In farmland, the salinity level was low. The low, intermediate, and high salinization was 53.42, 13.71, and 32.87% respectively. Generally, salinization was higher at lower altitudes, and the salinity level was affected by terrain and geomorphological factors. The above conclusions indicate an effective method for the inversion of salinization levels that combines phenology and other parameters for comprehensively determining the effect of phenological information on salinity monitoring ability in data mining. The inversion of soil salinity is enhanced by the inclusion of phenological parameters.

Key Words: salinization; phenological information; land parameters; data mining

研究表明,在干旱区由于盐渍化和次生盐渍化所造成的大面积土地被迫撂荒和植被的第一性生产力下降,严重降低了土地生产力,限制着农业生产的发展^[1]。同时由于为短期利益的农业活动而忽视了长期的后果是加重盐渍化的重要原因^[2]。现在传统的方法来监测盐渍化表现出多方面的不足,而融合了遥感 RS、地理信息系统 GIS 的技术方法却显示出很多优势^[3]。国外学者利用遥感提取盐渍土信息主要有以下方法:波段选择、主成分分析、K-T 变换、IHS 变换、图像比值运算,以及最大相似性分类、神经网络、决策树、表面特征分解、模糊分类以及多源数据集成建模等信息提取技术^[4]。国内学者对土壤盐渍化状况遥感监测的研究多从静态角度,盐渍化信息提取的方法主要有目视解译、基于影像光谱特征的数字图像处理技术、遥感信息地理信息综合分类、基于地学知识发现的识别与分类、人工神经网络分类器(RBF 或 BP 神经网络模型)等^[4-5]。国内的一些学者还运用主要由各种植被指数、盐分指数或碱性指数等来构建特征空间来提取盐渍化信息^[6-9]。很多研究中都用到了归一化差值植被指数(Normalized differential vegetation index, NDVI)来作为参数,但 NDVI 值与土壤电导率之间存在的相关性可用于区分盐渍土和非盐渍土,但无法区分盐土和碱土,同时由于不同类型的植被生长在不同的盐渍化水平下,NDVI 表现出很大的不确切性^[2,4]。因此单纯的考虑一种表征植被状态的指数并不可取。综合国内外已有的研究可以发现存在以下的一些可以改进的地方:**请删掉此处“的”字**

(1)多数对于监测盐渍化选择的参数是基于光谱特征^[10]、母质成因参数^[11-12]、地貌特征和数字高程模型(DEM)^[13]。但是对于植被的信息大多是用如 NDVI、修改型土壤调整植被指数(Modified soil adjusted vegetation index, MSAVI)和转换型土壤**请删掉此处“的”字**red soil adjusted vegetation index, TSAVI)等相关的指数。这些指数虽然各有优势,但解决的也只能是较理想下的土壤背景和植被覆盖等两大地类信息,不能用在每一种的自然环境状态下^[2]。同时,很多研究只是以盐生植被和非盐生植被来介绍植被在不同盐分下的长势情况,但较少对盐生植被与非盐生植被进行区别研究(即划分出盐生植被和非盐生植被,然后选择不同的方法或设置不同的参数进行监测,最终把不同监测的结果进行汇总,得到整个研究区盐渍化空间分布信息),这很可能使得最后提取的盐渍化信息精度有所降低。根据相关研究^[14-15],这种植被类型的划分更能有效的表征盐渍化程度的分布情况,因此本文也通过探讨划分不同的植被类型进行分区来反演盐渍化信息。

(2)很多研究对于盐渍化信息的提取只是针对某一特定时期进行的,选择的影像数据及其他辅助数据都围绕着采样时间进行,其结果是影像等辅助数据选择只是一期的的结果,但盐渍化在一定的区域内是多种自然原因和人类原因长期共同作用的结果^[5],而 MODIS 长时间序列的植被指数数据满足长期观测的条件。

(3)不同的植被与土壤类型,NDVI 等相关植被指数、盐分指数的变化^[16]、管理措施、虫害、疾病、气候和

土壤属性^[2]等会使得这些参数与盐分信息呈现出非线性化,因此有必要探讨运用人工神经网络强大而复杂的非线性拟合能力来反演盐渍化信息的时空分布情况。

(4)反演出的植被指数与含盐量的相关性很低,因为宽区间的光谱波段不能捕捉由于盐分的变化而出现的生物物理化学上的差异^[17],因此需要寻求一种能平衡时间分辨率、空间分辨率和波谱分辨率的数据源,而 MODIS 数据同时具备这些优点^[15],是一种良好的遥感数据源。

(5)研究表明当土壤足够干燥时,能够用遥感数据来进行较高精度的反演^[14],因此这限制了遥感数据主要适用于区域中降水稀少的干季,而不适用于降水集中的湿季^[6]。同时地表上一般均有植被覆盖,特别是在农耕区,因此监测作物的长势情况是一种潜力巨大,能够代替传统方式的方法,因为植被长势差的地区一般表征着重盐渍化程度集中的区域^[14]。这种方法在一些地方已经有成功运用的案例,特别是在完全没有植被存在的情况下^[18-19]。

(6)在先前的研究中,MODIS 连续数据和盐分的相关性很可能被低估,MODIS 连续时间序列的数据并没有被充分利用,特别是在物候信息方面^[15]。已有的报道中虽有用物候参数来进行研究,但研究较少,主要考虑到的只有植被类因素^[14-15],精度难免有所影响,极有可能存在一定的不确定性,因此本文通过加入物候信息来探讨反演盐渍化的信息。

综上,对于植被监测盐渍化信息的能力还没有充分挖掘。一般情况下植被受到盐渍化的影响会有着较低的光合作用,同时使得可见光反射率增高,近红外反射率降低^[20-21]。盐生植被一般具有较高的耐盐性,因此是区分盐渍化地区和非盐渍化地区的理想指标^[22]。MODIS 连续序列的数据平衡了光谱分辨率、时间分辨率和空间分辨率的优势^[15],可以用来进行大尺度的监测盐渍化信息。因此本文以渭干河-库车河三角洲绿洲为研究区,基于 MOD13A1-NDVI 数据来提取 2013 年植被多种物候信息,综合物候和非物候影响因子来反演研究区的盐渍化信息。

1 研究区概况

渭干河—库车河三角洲绿洲(以下简称渭库绿洲)位于新疆南部的塔里木盆地中北部,属大陆性暖温带干旱气候^[7]。根据对实地采样区域确定的边界范围为:82°10′—83°50′E;41°06′—41°40′N(图 1)。属于大陆性温带干旱气候。多年平均气温 11.6℃,多年平均降水量为 52mm,蒸降比为 54:1^[23]。土壤主要为潮土和草甸土^[7]。绿洲自然植被以盐生植被为主,如怪柳(*Tamarix*)、盐节木(*Halocnemum strabliaceum*)、盐爪爪(*Kalidium foliatum*)、花花柴(*Karelinia caspica*)、芦苇(*Phragmites communis*)、苦豆子(*Sophoraia pecuroides*)、白刺(*Nitraria sibirica*)、黑刺(*Lycium ruthenicum*)、骆驼

刺(*Aihagi sparsifolia*)、盐穗木(*Halostachys caspica*)、胡杨(*Populuseu phraticea*)等肉质多汁泌盐植物和盐生灌丛,主要呈片状分布在绿洲外围^[24]。农田植被主要由小麦、玉米、棉花等种植作物构成,主要分布在绿洲内部水资源丰富、种植环境良好、排灌渠设施完善的种植区^[24]。渭库绿洲盐类沉积规模大,土壤普遍盐渍化,盐渍化总面积超过研究的 50%,重度盐渍化(5—10 g/kg)面积达到 30%,因此绿洲的发展受到严重威胁^[23,25]。

2 研究方法 with 原理

综合物候参数、植被指数、盐渍化指数、干旱指数、特征空间、影像反射率、地形参数等 22 种参数来反演研究区盐渍化的空间分布信息。这些参数分别代表了物候特征、植被长势情况、盐渍化分布特征、干旱情况和地

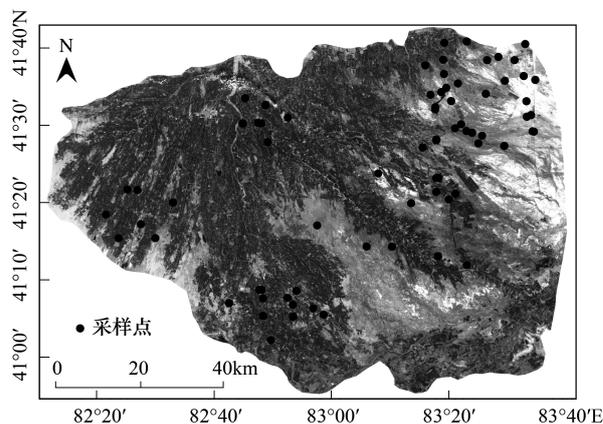


图 1 研究区及采样点分布图

Fig.1 Location of study area and distribution of sampling sites

形变化特征等。物候参数的定义见表 1^[15,26],非物候参数的定义见表 2。

表 1 物候参数的定义和生态学意义

Table 1 Definition and ecological meaning of the seasonal parameters

物候参数 Seasonal parameters	定义 Definition	生态学意义 Definition
生长季开始时间/生长季结束时间 SOS (Start of season)/EOS (End of season)	生长季开始和结束的日期	植被生长期和衰老期的时间段
生长季丰度 AMP (Amplitude)	生长季中植被指数最大值和最小值的差值	季节性光合作用的幅度
生长季长度 LEN (Length of season)	从生长开始的日期到生长结束的日期之间所经历的时间	生长季所经历的时间
生长季 NDVI(归一化差分植被指数)最小值 BASEV (Base level)	曲线左右两边最小值的平均值	生长季左右两端最低值的平均值
生长季 NDVI 最大值 PV (Peak value/Peak time)	生长期植被指数最大值	光合作用的最高水平和最大值到达的时间和值
生长季生长曲线的左/右斜率 Left/Right derivative (LD/RD)	从左边最低点到最高值的直线的斜率/从最高点向右边最低点直线的斜率	植被生长和衰退的速率
生长季大生物累积量 LSI (Large seasonal integral)	生长季开始日期和结束日期之间坐标轴拟合函数曲线上部的积分	累积的光合作用,与生物量和净初级生产力相关联(本文统称为生物累积量指标)
生长季小生物累积量 SSI (Small seasonal integral)	生长季开始的日期和结束日期之间坐标轴拟合函数曲线下部的积分	

表 2 非物候参数的定义与计算

Table 2 Definition of non-phenological indicator

类别 Auxiliary data	参数 Land surface parameters	公式 Formula	释义与来源 Definition and Reference/Source
盐渍化指数 Salinity Index	SI (Salinity index)	$\sqrt{B \times R}$	盐渍化指数 ^[27]
特征空间 Feature space	SDI (Salinity detect index model)	$SDI = \sqrt{(NDVI - 1)^2 + SI^2}$	盐渍化监测模型 ^[28]
植被指数 Vegetation index	NDVI (Normalized differential vegetation index)	$(NIR - R)/(NIR + R)$	归一化差值植被指数 ^[29]
	TSAVI (Transformed soil adjusted vegetation index)	$\frac{a(NIR - aR - b)}{aNIR + R - ab}$ a, b 为土壤线系数	转换型土壤调整植被指数 ^[30]
	MSAVI (Modified soil adjusted vegetation index)	$[(2NIR + 1) - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}] / 2$	修改型土壤调整植被指数 ^[31]
干旱指数 Drought index	TVDI (Temperature vegetation drought index)	$\frac{(T_s - T_{min})}{(T_{max} - T_{min})}$ $T_{max} = a + b \times NDVI$ $T_{min} = c + d \times NDVI$ a, b, c, d 分别是干边和湿边线性拟合方程的系数	温度干旱植被指数 ^[32]
地形参数 Terrain parameters	DEM	研究区的高程分布	数字高程模型
	SLOPE	arctan(高程差 / 水平距离)	坡度
	TWI (Topographic wetness index)	$\ln[\alpha / \tan(\beta)]$ α : 汇水面积, $\tan(\beta)$: 地形梯度	地形湿度指数 ^[33]
影像反射率 Spectral reflectance	Taghizadeh-Mehrjardi 等 ^[13]	移动	移到此处
	Blue	影像中的蓝波段反射率	蓝波段反射率
	Red	影像中的红波段反射率	
	Nir	影像中的近红外波段反射率	

B 蓝波段反射率, R 红波段反射率, NIR 近红外反射率

请把此处的“Taghizadeh-Mehrjardi等[13]”移动到该行的最右端, 因为最右端是列出的释义与来源

2.1 电导率数据的采集

选择具有代表性的土壤表层单元,测量单元的位置、数量、土壤质地和盐分状况和植被类型以及土地覆盖情况等进行选取(图 1)。对每个测量单元进行表层(0—10cm)土壤样品的采集。然后带回实验室中经过自然风干,磨碎,过 0.5mm 孔径筛、制作 1:5 比例的浸提液来测定土壤电导率和含盐量,采样时间为 2013 年 8 月,剔除不能提取物候参数对应像元的采样点,最终选出 87 个采样点来进行分析(图 1)。

2.2 地形参数的获取

研究表明地形参数中高程、坡度对盐渍化的聚集有重大影响^[13]。地形的高低直接决定了地下水与地表水的流向,这使得盐分会随着水流流向而发生不同程度的聚集,地势较高的区域一般盐渍化程度较低,地势较低的区域盐渍化程度一般较高。Moore 等^[34]研究发现土壤盐分和地形湿度指数有很强的相关性。地形湿度指数具有明确的物理意义:具有相同地形湿度指数的不同空间位置对降雨的水文响应相同,地形湿度指数频率分布相同的不同流域具有水文相似性。因此其频率分布及空间分布在流域的土壤分布及分布式水文模型等研究中具有重要的意义^[33]。同时地形湿度指数表征了地表水文特征的湿度程度,被用来对盐渍化程度进行分类^[34]。所有这些参数都反演于 500m 分辨率的 DEM 数据,具体计算公式参见表 2。

2.3 地表覆盖数据的获取

获取渭库 2009 年 500m 分辨率的土地利用产品 MODIS-MCD12Q1 的土地利用数据,从中国科学院资源环境科学数据中心(<http://www.resdc.cn>)下载 2010 年土地利用数据。由于中科院的土地利用数据分辨率是 1000 m,因此 2013 年使用的是 2009 年分辨较高的土地利用数据。

根据本研究目的和根据 MODIS 产品的土地覆盖划分的类型和文献[15]的分类,分为农田植被(代表不同作物类型的植被,主要是非盐生植被)、盐生植被(主要是稀疏植被,分布于为绿洲外围和荒漠区)和其他地类(代表了混合了农用地和稀疏植被的区域,主要包括稠密灌丛、稀疏灌丛、稀疏草原、草地、永久草地、自然植被等地类)等 3 大类。但由于其他地类中的样点主要位于绿洲荒漠交错带区域,受人类活动影响较大。在这个漫长的交错带上,其他地类分布的样点显得特别分散,如果单独进行反演极有可能会使得结果有较大的不确定性,因此其他地类中反演结果用不分区时的结果替代。

2.4 温度植被干旱指数(TVDI)

目前,基于植被指数(Vegetation index, VI)和地表温度(Surface temperature, T_s)的二维特征空间获取温度植被干旱指数(Temperature vegetation drought index, TVDI)综合了两个参数特有的生理生态意义,能有效地减小植被覆盖度对干旱监测的影响,准确性更高,实用性更强;且特征空间所需数据较少,获取方便,计算得到的 TVDI 的物理意义明确,应用较为广泛^[35]。因此本文以 TVDI 来表征地表的土壤水分,因为土壤水分和盐分之间的关系直接关系到利用遥感光谱信息监测土壤盐渍化的精度^[36]。很多研究表明 TVDI 对于不同地区的旱情监测或土壤湿度时空差异方面取得了显著的效果^[37]。同时刘立文^[38]等研究发现引入 DEM 数据对 T_s 做地形校正,减少了地形起伏对能量平衡的影响,所用模型为 C 校正模型。但是尽管 C 校正模型易于使用,但在森林覆盖的山区,其模型的几何关系与植被向地生长的特性不相符^[39]。为此,一些研究者提出了适用于森林山区遥感影像地形校正的 SCS 模型^[39]。由于 SCS 与 Cosine 模型一样存在过度校正的情况,所以依照 C 模型的建立方法,经验参数 C 被引入 SCS 形成了 SCS+C 模型,取得了较好的校正效果^[40]。因此本文采用基于奈曼最优分配法^[41]的 SCS+C 模型来校正 T_s ,最后得到 TVDI(表 2)。

2.5 盐渍化监测模型 SDI 的建立

综合分析归一化差值植被指数(NDVI)、盐分指数(SI)二者之间的关系,在此基础之上提出 NDVI-SI 特征空间概念,并构建土壤盐渍化遥感监测指数模型(SDI)。研究结果表明土壤表层含盐量与 SDI 相关性较高,对于干旱区盐渍地信息提取具有重要意义^[28]。因此根据采样日期选择 MODIS-NDVI 数据和计算盐分指数,构造二维特征空间 NDVI-SI,最后得到盐渍化监测模型 SDI,把 SDI 作为神经网络模型的一个输入变量。

图 2 显示的是特征空间 SDI 模型的示意图, AEB 是特征空间轨迹曲线。空间中距离点 D(1,0)越远,表

示盐渍化程度越严重,越近表示盐渍化程度越轻^[28]。根据两点之间的距离公式就可以得到从 C 点到 D 点的距离 L:

$$L = \sqrt{(NDVI - 1)^2 + SI^2} \quad (1)$$

从而 **差值 (变为“归一化差值植被指数”)** Salinization detection index, SDI

$$SDI = \sqrt{(NDVI - 1)^2 + SI^2} \quad (2)$$

2.6 植被指数与盐分指数的计算 **修改**

植被是盐渍化程度的一种重要指示剂,因此选择能够较好地反应土壤盐渍化程度的 4 种光谱指数(表 2):归一化植被指数 (NDVI)、修整型土壤调整植被指数 (MSAVI)、转换型土壤调整植被指数 (TSAVI) 和盐分指数(SI)。经过统计,NDVI 和 MSAVI、TSAVI 的相关性较低,相关系数均在 0.2 左右;MSAVI 和 TSAVI 具有高度的相关性,相关系数接近于 1;SI 与 MSAVI 和 TSAVI 的相关性较低,均为-0.16;SI 与 NDVI 的相关性较高,相关系数为-0.84;SDI 和 SI、NDVI 相关性较高,相关系数均大于 0.85 (与 NDVI 是负相关),与 TSAVI 和 MSAVI 相关性较低,相关系数均为-0.21。综上分析,尽管部分指数之间具有高度的相关性,但为了精确的捕捉盐渍化信息细节上的变化,把这 5 (包括 SDI) 个指标均作为反演的输入变量。

2.7 遥感反射率数据

研究表明地表反射率对于监测地表盐渍化的效果显著^[42]。因此选择蓝波段、红波段和近红外波段反射率作为参数来表征盐渍化的信息。经统计可得蓝波段和红波段的相关系数达到了 0.98,其他波段之间的相关系数的绝对值都小于 0.2,但蓝波段和红波段在不同土壤水分含量的盐渍地中的响应并不一致,同时作为反演的一个因子能更好的捕捉盐渍化变化的细节信息,因此这 3 个波段反射率全部用来作为反演输入的变量。

2.8 植被物候参数的计算

尽管 MOD13A1-NDVI 数据经过了大气和气溶胶的校正,但是厚重云雾仍然存在,因此在做平滑处理之前,需要根据 MODIS 质量控制产品(QA)对连续时间的序列数据赋予不同的权重^[15,26,43]。因此通过比较常用的 Savitzky-Golay、Asymmetric Gaussian 和 Double logistic model 等 3 种方法的滤波效果,本文最终选择用 Savitzky-Golay 滤波法来对影像数据做处理,得到重建后的 NDVI 曲线。拟合公式为:

$$\sum_{j=-n}^n C_j y_{i+j} \quad (3)$$

权重 $C_j = 1/(2n + 1)$, 数据值 y_i 被位置 t_i 的平均值所取代,这是从二次多项式最小二乘法的 $2n + 1$ 个点的滑动平均窗口中获得。同时加入 MODIS 产品质量控制影像文件,赋予像元不同的权重后可以有效的降低噪声的影响。滤波结果如图 3 所示,图中蓝线(具有不平滑特征的曲线)表示原始的序列曲线,红线(较为平滑的曲线)代表平滑去噪后的曲线。

采用动态阈值法从 NDVI 数据集中提取渭库绿洲的物候参数。主要是因为与传统的固定阈值法比较,动态阈值法与每个像元的 NDVI 季节变化幅度紧密相关,根据研究条件的不同,可以动态地确定阈值,并消除不同土壤背景值和植被类型的影响^[44]。根据相关学者^[45-47]对中国及中亚不同地区的研究,本文将提取生长季开始日期(Start of season, SOS)和生长季结束日期(End of season, EOS)的系数都设置为 30%。用儒略历

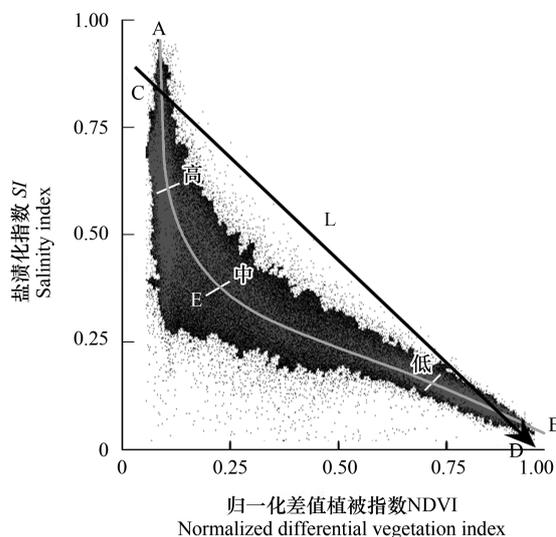


图 2 SDI 模型图形表达示意图

Fig.2 Sketch map of SDI under lowly, moderately and highly saline soils

注:A、E 和 B 分别是空间轨迹曲线 AEB 的起点,中间点和终点;L 是指从空间中任意一点如 C 点至 D 点的直线距离;由坐标轴 NDVI 和 SI 即可得到 SDI

(Julian calendar) 算法(1月1日为一年中第1天)进行物候期统计分析^[48]。

在经过了平滑和参数设置后,用 TIMESAT 软件计算季节性参数包括 SOS、EOS、生长季长度 (Length of season, LEN) 和生长季丰度 (Amplitude, AMP) 等 10 个参数。表 1 中阐述了不同指标所代表的生态学意义^[15,26]。

2.9 BP-ANN 模型的预测研究

由于光谱反射率和土壤参数间的转换函数是非线性的,因此人工神经网络 (Artificial neural network, ANN) 已被广泛用于获取土壤参数。目前利用人工神经网络的研究多集中于对土壤质地的土壤特性研究^[49]。同时盐渍土光谱数据的参数反演是将多维空间向低维空间的映射过程,这种映射关系是复杂的、非线性的。BP (Backpropagation) 神经网络是智能计算技术的重要分支,具有快速、有效地处理多维、非线性数据的能力。将 BP 神经网络用于反演盐渍土含盐量能大大提高反演精度,推动盐渍土遥感的定量化发展^[4]。所以结合前人的研究,本研究采用 3 层 BP 神经网络,来预测研究区盐渍化空间分布信息,见图 4。

神经网络是一种黑箱结构,多层神经网络能以任意精度逼近给定样本的分布和结构。训练过程无需人工操作,并且自动获得每个神经元的权重^[50]。它具有运算效率高、自学习能力强、适应面宽等优点^[51]。利用 BP 神经网络主要分为模型校正和模拟,主要思路为:建立三层神经网络,包括输入层,隐藏层和输出层,利用随机采样的数据对其进行训练,在利用训练好的网络对整个研究区的数据进行模拟与预测(图 4)。

输入层将信号输出到隐藏层,隐藏层第 j 个神经元所收到的信号为^[50]:

$$net_j(k, t) = \sum w_{ij} x'_i(k, t) \tag{4}$$

式中: k 为输出信号对应的模拟单元, t 为模拟时间, $net_j(k, t)$ 为隐藏层第 j 个神经元所接收到的信号, w_{ij} 为连接输入层和隐藏层之间的参数,即权重值。

隐藏层对该函数的响应为:

$$\frac{1}{1 + e^{-net_j(k, t)}} \tag{5}$$

所以输出层第 O_i 个神经元所

$$PV_i(k, t) = \sum_j w_{ji} \text{sig mod}_j(k, t) \tag{6}$$

式中, $PV_i(k, t)$ 为单元 n 在模拟时间 t 时刻第 R^2 个神经元所接收到的信号; ME 为隐藏层和输出层之间的参

数
请务必把这个“R²”换成原公式中的“i”,变为“第i个神经元...”

变量作为输入层数据,输出层为预测的电导率数据,由于隐藏层的神经元数目为 14 个。

请务必把这个“ME”换成原公式中的“w_{ji}”,变为“w_{ji}为隐藏层和输出层之间的参数”

选用均方根误差 (RMSE)、平均误差 (ME) 和可决系数 (R^2) (实测值与预测值之间线性拟合方程的可决系数) 来评价不同方法预测的精度^[6,13]。

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \tag{7}$$

$$ME = \frac{1}{n} \sum_{i=1}^n (P_i - O_i) \tag{8}$$

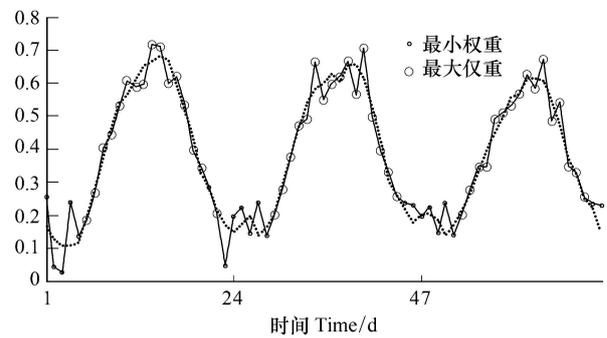


图 3 基于 QA 质量数据赋予权重的 Savitsky - Golay 滤波 (2012—2014 年)

Fig. 3 The QA weighted time series and Savitzky - Golay smoothed curves (2012—2014)

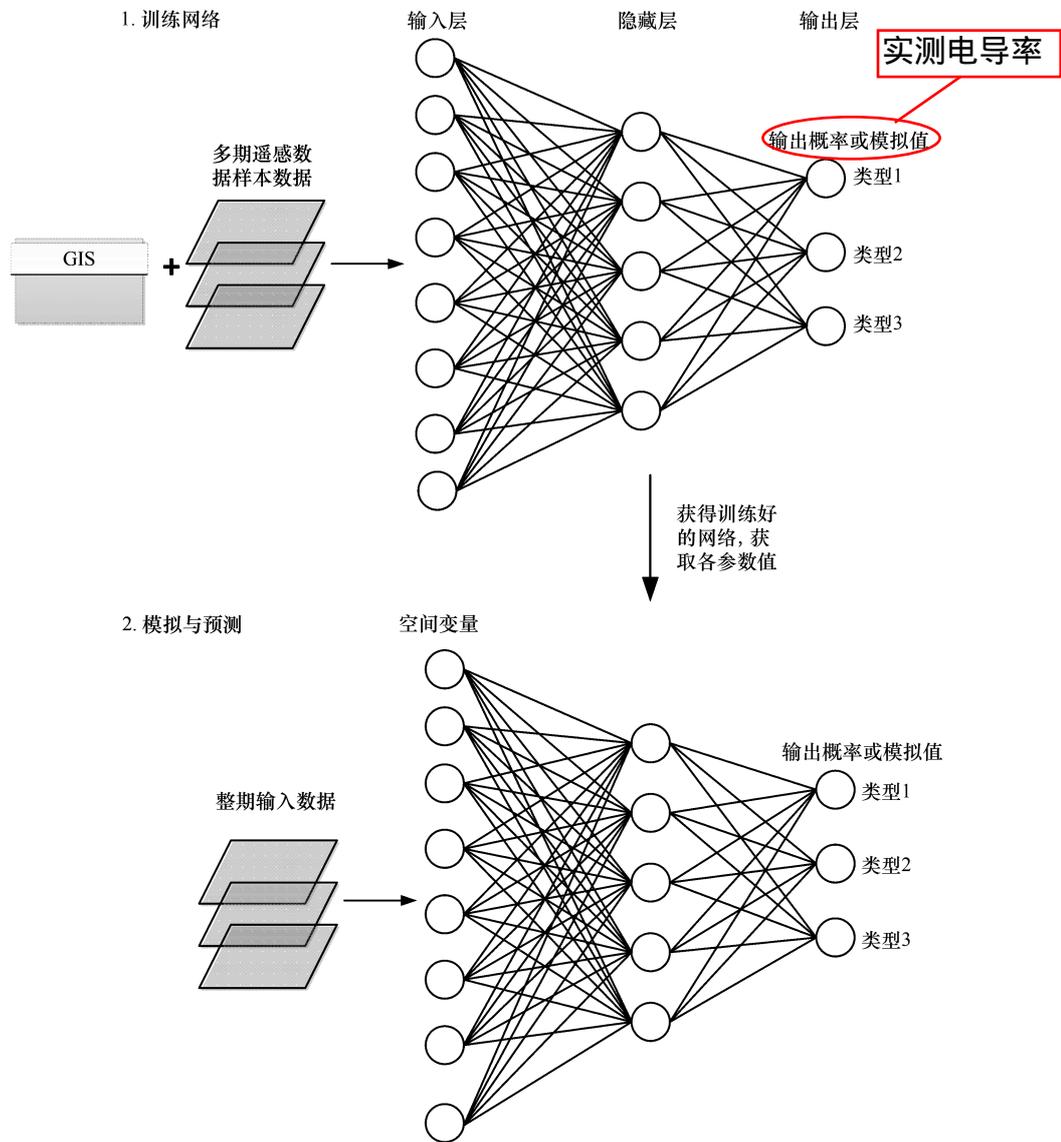


图4 基于BP神经网络的预测盐分模型流程图

Fig.4 The flowchart of prediction on salinity information based on BP-ANN model

$$R^2 = \left[\frac{\sum_{i=1}^n (O_i - O_{ave})(P_i - P_{ave})}{\sqrt{\sum_{i=1}^n (O_i - O_{ave})^2 (P_i - P_{ave})^2}} \right]^2 \quad (9)$$

式中 P_i 代表预测值, O_i 代表实测值, O_{ave} 代表实测平均值, P_{ave} 代表预测平均值, n 表示验证点的数量。RMSE 越小, R^2 越高, ME 绝对值越接近于 0, 精度越高, 反之越低。

3 实验结果和分析

3.1 不同参数的提取结果

依照上述描述的步骤计算出的各非物候参数见图 5。从图 5 中可以得到以下结论: ①从 NDVI 分布图可以得出, 渭库的绿洲内部的植被覆盖程度明显高于绿洲荒漠交错带和荒漠地区。②从 TVDI 分布图中可以得出绿洲内部的土壤含水量明显高于绿洲外围, 从绿洲内部-绿洲外围-荒漠区依次递减。③从坡度分布图

(SLOPE)中可以得到研究区坡度和高程的总体呈北高南低,且总体差异不大,是明显的平原地区。因此水流的总体趋势是从北往南和从西向东,绿洲荒漠交错带和荒漠区低”^[53]。④地形湿度指数空间分布信息显示出 TWI 较低的地区多位于地势较...多位于东部和南部地区。⑤MSAVI 和 TSAVI 的分布趋势与 NDVI 基本相同。⑥分布在绿洲内部农用地区域的 SI 数值明显低于荒漠区域。⑦SDI 空间分布结果表明绿洲农用地的 SDI 值明显低于非绿洲地区,在绿洲的大部分区域 SDI 小于 0.4,非绿洲区域 SDI 集中于大于 0.8,这在一定程度上表明在绿洲的盐渍化程度普遍比荒漠区低。

3.2 物候参数的提取结果

为了更好的挖掘不同物候参数在不同植被类型下提取盐渍化信息的能力,用野外实测的土壤含盐量数据与这 10 种物候参数做最佳线性或非线性方程的拟合,拟合结果见表 3。

表 3 不同物候参数对于盐分的最佳曲线拟合

Table 3 Different phenological parameters of best curve fitting with respect to salt content

物候参数 Seasonal parameters	不分地类 Not distinguish between land use types	农用地 Farmland	稀疏植被 Wasteland/Sparse vegetation
SOS	回归方程 $y = -0.01711x^2 + 1.5631x + 126.33$ R^2 0.059	$y = -0.21545x^2 + 6.304x + 126.1$ 0.480	$y = 84.062x^{0.19227}$ 0.193
EOS	回归方程 $y = -0.03602x^2 + 1.2852x + 320.15$ R^2 0.125	$y = -0.11765x^2 + 2.5831x + 313.52$ 0.117	$y = -0.02487x^2 + 0.61905x + 330.06$ 0.134
AMP	回归方程 $y = -0.06505\ln(x) + 0.34513$ R^2 0.325	$y = 0.54723e^{-0.07568x}$ 0.774	$y = -0.00018x^2 + 0.00959x + 0.03063$ 0.169
LEN	回归方程 $y = -0.01892x^2 - 0.27791x + 193.82$ R^2 0.066	$y = -1.489x + 184.53$ 0.250	$y = 0.04096x^2 - 3.6001x + 227.26$ 0.156
BASEV	回归方程 $y = -0.01891\ln(x) + 0.14099$ R^2 0.471	$y = 0.14292x^{-0.14348}$ 0.557	$y = -0.00002x^2 + 0.00121x + 0.07052$ 0.078
PV	回归方程 $y = -0.08396\ln(x) + 0.48611$ R^2 0.392	$y = -0.02211x + 0.69989$ 0.790	$y = -0.0002x^2 + 0.0108x + 0.10115$ 0.170
LD	回归方程 $y = -0.0218\ln(x) + 0.09973$ R^2 0.314	$y = 0.17084e^{-0.08996x}$ 0.752	$y = -0.00004x^2 + 0.00249x + 0.00038$ 0.212
RD	回归方程 $y = -0.01215\ln(x) + 0.06395$ R^2 0.343	$y = 0.0991e^{-0.07653x}$ 0.930	$y = -0.00004x^2 + 0.00182x + 0.01016$ 0.076
LSI	回归方程 $y = -0.88105\ln(x) + 4.9869$ R^2 0.481	$y = 7.3082e^{-0.06407x}$ 0.881	$y = -0.00128x^2 + 0.06155x + 1.5843$ 0.077
SSI	回归方程 $y = -0.61375\ln(x) + 3.0944$ R^2 0.394	$y = 5.0114e^{-0.08723}$ 0.819	$y = -0.0011x^2 + 0.05623x + 0.52468$ 0.097

SOS; Start of season, 生长季开始时间; EOS; End of season, 生长季结束时间; AMP; Amplitude, 生长季幅度; LEN; Length of season, 生长季长度; BASEV; Base level, 生长季 NDVI 最小值; LD; Left derivative, 生长季曲线左导数; RD; Right derivative, 生长季曲线的右斜率; LSI; Large seasonal integral, 生长季大生物累积量; SSI; Small seasonal integral, 生长季小生物累积量

表 3 中分为了不分植被类型和分植被类型的两种情况,分别对绿洲内部农用地、绿洲外围与荒漠地区最重要的代表非盐生植被的农田区实测样点数据和代表盐生植被的绿洲外围与荒漠地区的实测样点数据进行了拟合。可得以下结论:①在真实的田间测量情况下,可决系数 R^2 的变化范围为 0.06—0.48,因此不分地类的拟合结果精度较低,不足以解释盐渍化信息的细节信息。②划分地类后的农用地 R^2 有了明显的提高,大多在 0.55 以上,最大值到达了 0.92,但是对于稀疏植被区 R^2 较低,因此单纯的用某个拟合曲线不能很好的反应盐渍化的空间分布特征。③分地类和不分地类的最佳拟合方程大多是非线性的。④从农用地最佳拟合曲线可以得出拟合方程多为单调递减函数,即随着含盐量的增加,其对应物候参数的值在逐渐降低,最明显的就是 LSI、RD、LD、PV 这几个参数,这些参数都代表了光合作用的情况信息,说明农用地植被对于盐分情况的变化极为敏感,盐分越重对于农

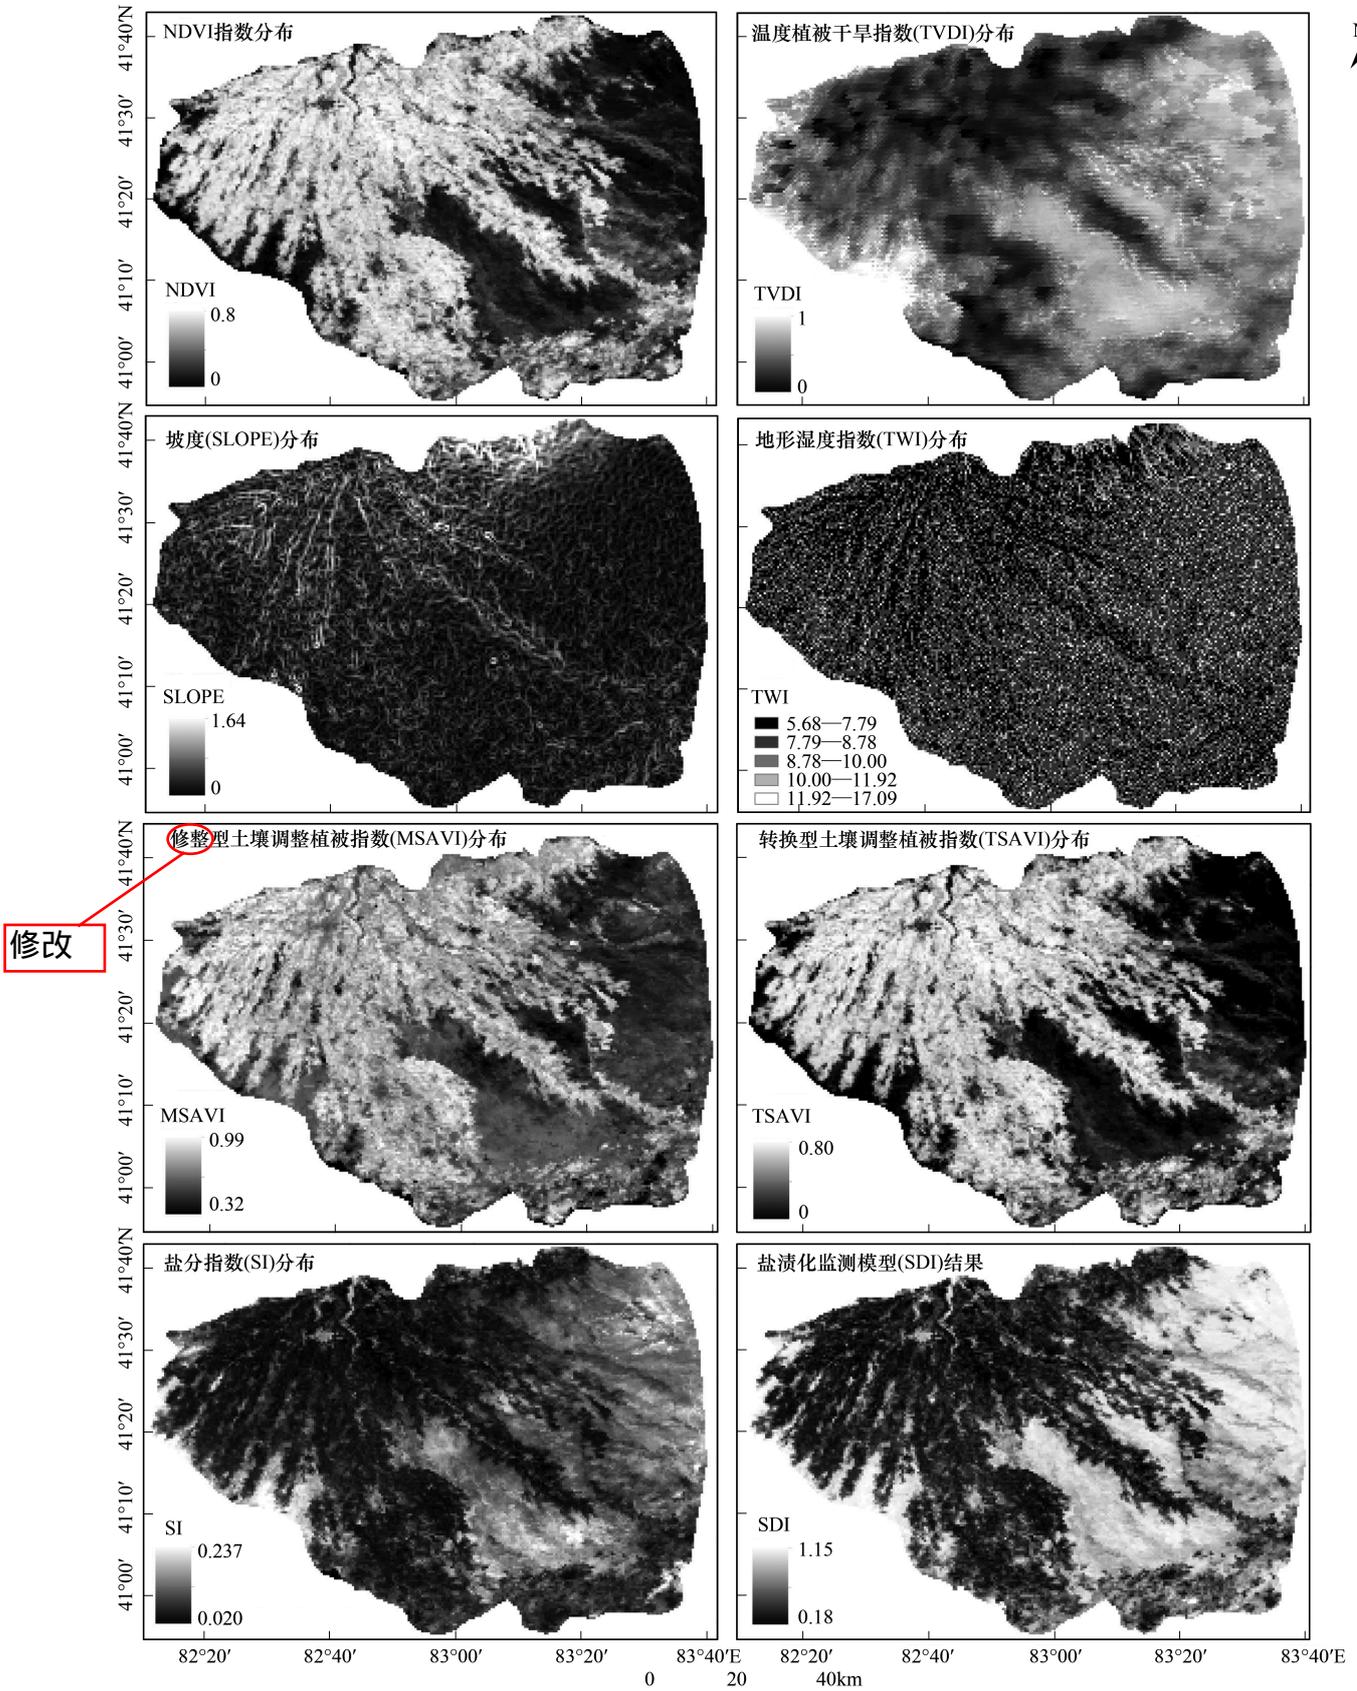


图5 各非物候参数的计算结果

Fig.5 Calculation results of the non-phenological parameters

作物的生产量的影响越大。⑤对于稀疏植被,情况更为复杂。大多是呈下开方向的二次多项式方程,即先随着盐分的增加对应物候参数的值也在增加,到达一个最大之后又随着盐分的增加而减小,如 EOS、AMP、BASE、PV、LD、RD 和 SSI。这就说明盐生植被的确具有一定耐盐性,但是当盐分含量到达一定程度之后也会对其生长造成较大的影响。⑥通过以上 5 点的分析,可以得出尽管通过深挖植被的信息可以较好的反演盐渍化信息,但至少对于盐生植被区域只用植被的物候信息反演盐渍化信息的效果并不理想,需要借用其他方面的参数来参与反演。

通过以上 6 点的分析可以得出植被信息只是反演盐渍化的一种重要指示剂,但不能适用于所有植被类型,用最佳曲线拟合的方式来反演盐渍化信息不具有普适性。基于以上的分析,本研究运用 BP-ANN 人工神经网络来结合物候参数、地形信息、影像数据、野外实测数据等 22 个参数来反演盐渍化信息。

因为从表 3 的结果来看指示光合作用的 LSI 和 SSI 指数与盐分含量的相关性较高,这表明生物累积量的信号能更好反映盐渍化信息。可能主要是因为对于不同类型的植被对于盐渍化程度的响应不同,同种植被对于不同盐含量的响应也不同,不同植被对于同一水平的盐分含量响应也会不同,但是这一切都会原原本本的记录在植被的体内,最突出的就是它的长势情况,最终就会导致生物累积量的不同,所以 LSI 和 SSI 的表征盐渍化的能力要优于其他几个物候参数,因此图 6 中只显示 LSI 和 SSI 分布图。

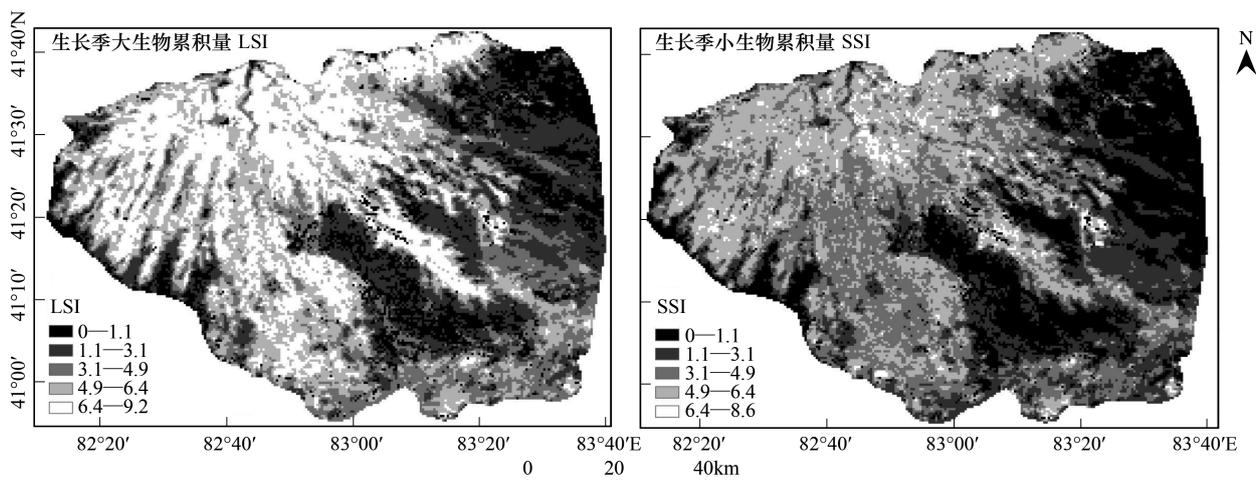


图 6 生物累积量分布图

Fig.6 Biomass accumulation patterns

从图 6 中的 LSI 空间分布可以得出位于绿洲农用地植被区域的累积生物量明显大于绿洲荒漠交错带与荒漠地区。农用地的生物量值最高,值域在 4.9—9.2 之间;绿洲荒漠过渡带的生物量值较低,值域在 1.1—4.9 之间;荒漠地区生物量值最低,也是盐渍化程度最严重的区域,值域在 0—1.1 之间。图 6 中 SSI 分布的情况与 LSI 类似,不同的是对于同一区域的累积生物量的值要明显低于 LSI 的值,如在农田区的 SSI 值大部分处于 4.9—6.4 之间,而 LSI 值大部分在 6.4—9.2 之间。SSI 值在绿洲和荒漠地区低于 4.9 的区域面积明显大于 LSI 低值区。

3.3 不分区 BP-ANN 神经网络

把提取出来的 10 种物候参数(SOS、EOS、AMP、LEN、BASEV、PV、LD、RD、LSI、SSI)和 12 种非物候参数(NDVI、SI、SDI、TVDI、MSAVI、TSAVI、DEM、坡度(SLOPE)、TWI、蓝/红近红外波段反射率)作为 BP-ANN 的输入因子。由于含盐量和电导率之间有着极好的相关性,可以用电导率表征含盐量^[13],因此把野外实测的电导率(1:5 比例的浸提液电导率)作为输出结果。隐藏层的神经元数目设置为 14 个。

具体过程如下:

①采样:利用野外实际采样的 87 个采样点,其中 50 个样点作为训练样本,37 个样点作为测试样本。

②预测 2013 年盐渍化分布情况:利用 Matlab 创建 BP 神经网络,利用训练好的网络来对测试数据和逐像元数据进行预测,精度验证结果见表 4,预测结果见图 7。

3.4 分区 BP-ANN 神经网络盐渍化信息反演

分别把位于农用地、稀疏植被区和其他地类的野外采样点提取出来。用位于不同地类的采样点来训练神经网络,分别得到分区之后的结果图,然后用各自地类的矢量边界分别裁剪对应的结果图,最后在 ArcGIS 软件中进行镶嵌处理,得到分区之后的盐渍化信息分布图。其中由于其他地类区的反演结果用不分区的结果代替。

具体过程如下:

①采样:按照不同地物类型采集样本,然后按照如上的设置提取训练样本和测试样本(实测数据中 60% 用于训练,40%用于测试)。

②预测 2013 年盐渍化分布情况:利用 Matlab 创建 BP 神经网络,利用训练好的网络来对测试数据和逐像元数据进行预测,得到不同分区的预测结果,结果见图 8,镶嵌后的结果如图 9 所示,精度验证结果见表 4。

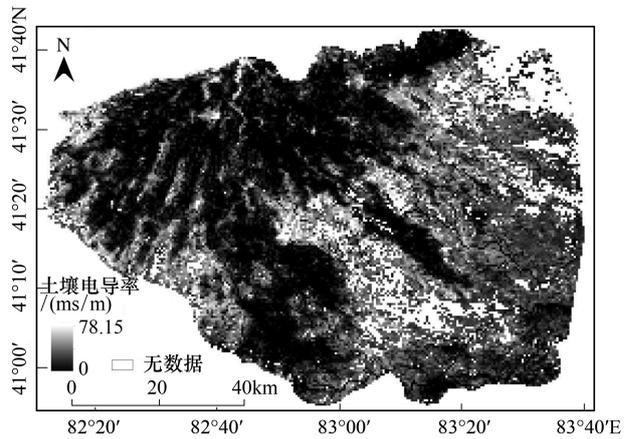


图 7 不划分植被类型盐渍化分布图

Fig.7 Spatial distribution patterns of soil salinity in 2013 without vegetation partitioning

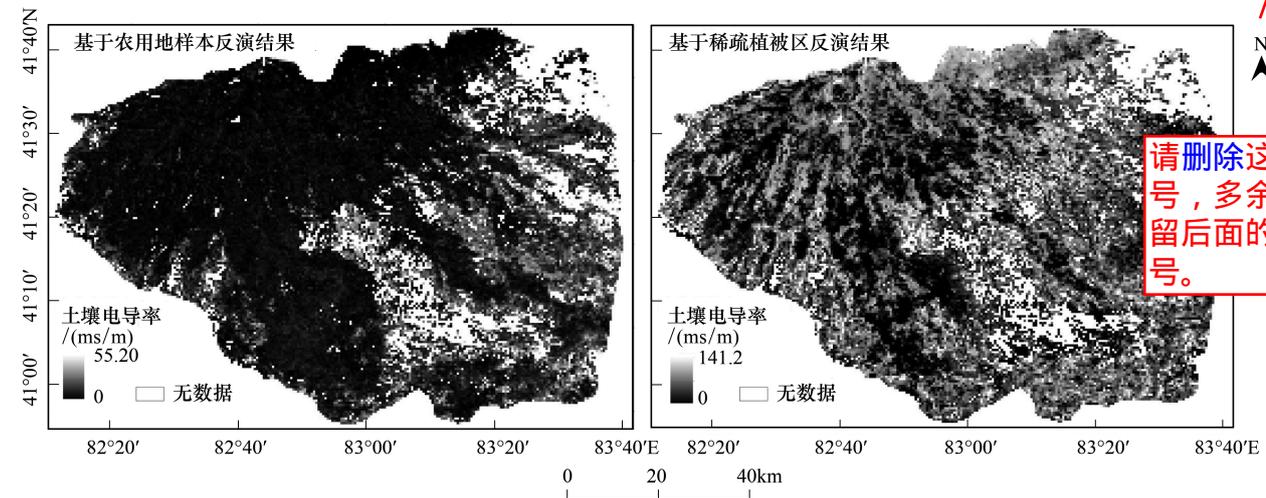


图 8 基于不同植被类型分区盐渍化的反演结果

Fig.8 The inversion results of soil salinity based on vegetation partitioning

同时只用非盐渍化的 12 个参数来反演盐渍化分布情况,精度比较结果见表 4。

从表 4 中可以得出当无物候参数参与反演时可得:不分区和分区的总体差别不显著,几乎一致。**RMSE** 从 11.55 增加为 12.30, **ME** 绝对值从 0.88 增加为 2.46, **R²** 从 0.68 下降为 0.67,从这几个方面可知分区后的总体精度略有下降,但是分区后农用地部分的反演精度较高, **RMSE** 从不分区时的 11.55 陡降为农用地部分的 4.21, **R²** 也从 0.68 上升为 0.73;对于稀疏植被,分区后的精度反而明显降低, **RMSE** 从 11.55 上升为 14.22, **R²** 从 0.68 下降为 0.54,可见对于稀疏植被区,单纯的用物候参数进行反演效果不理想,需要探讨用其他方法以及加入其他参数后来进行反演。当有物候参数参与反演时可得:分区后的精度明显要高于不分区时的精度,如 **RMSE** 从不分区时的 9.55 减少到分区后的 7.73, **ME** 从 0.42 减少为 0.04, **R²** 从 0.79 升高到 0.8787,这个 0.8787 并没有位于 0.79 和 0.8765(农用地)之间,主要原因是镶嵌时的其他地类中的采样点拟合精度高于不分区时

的整体精度, R^2 达到了 0.90, 所以分区后镶嵌的结果的 R^2 更高。因此总体而言, 按照植被类型分区后的预测精度明显高于不分区时的精度。这可能主要是因为不分区时神经网络训练的过程中是对所有样点进行全局最优拟合, 在误差反馈的过程中权重的分配根据所有样点而变化, 但是如地理坐标投影一样, 局部区域的误差会变大, 因此神经网络训练好的结果难免会受到其他样点的影响, 精度较低。相反, 在按照不同植被类型进行分区后, 对每种植被区的样本进行专门训练就不会受其他植被类型样点的干扰, 拟合出的方程与匹配的权重更加符合局部区域的实际情况, 所以最终的预测精度较高。对比国内相关学者对于该区域的研究^[6-7, 24], 发现其 $RMSE$ 普遍较低, 实测值与预测值的相关性一般都在 0.84 以上, 但是对比国外相关学者^[13] 的研究, 发现其 $RMSE$ 普遍较高, 一般数值在 20 以上, 本文结果介于二者之间, 但是从相关性和可决系数 R^2 上看, 本文反演结果的精度较高。主要原因可能是采样时间与研究的时段不同和研究方法上的差异等。但是国外的研究一般都是基于大数据量的样点统计出来的结果, 更加具有统计学意义, 因此以后应该对研究区多采集样点, 来更好的对比国内外研究的精度。

表 4 通过植被类型分区后不同结果反演的精度比较

Table 4 Comparing different inversion precision results through vegetation type partitioning

参数 Parameters	指标 Indicators	所有样点(不分区) Whole sample (non-partitioning)	农用地 Cropland	稀疏植被 Wasteland/Sparse vegetation	分区后汇总 Combination result of soil salinity based on vegetation partitioning
无物候参数 Non-phenological indicators	RMSE	11.55	4.21	14.22	12.30
	ME	-0.88	0.92	-4.17	-2.46
	R^2	0.68	0.73	0.54	0.67
有物候参数 Including non-phenological indicators	RMSE	9.55	2.57	8.89	7.73
	ME	0.42	0.69	0.37	0.04
	R^2	0.79	0.8765	0.84	0.8787

从图 9 中可以得到以下结论: ①图 9 中有部分无值区, 这主要是因为对于无植被覆盖或分布极其稀疏的区域, 不能有效的提取物候参数所致。但是通过出野外的实际观测, 这些无值区一般都是重盐渍化区域。②绿洲内部农用地区域主要为非盐渍化地和轻盐渍化地, 占有效像元的比例达到 53.42%, 主要位于中海拔冲积扇平原、中海拔冲积洪积扇平原、低海拔冲积扇平原的地貌类型区。③位于研究区绿洲东部和东南部盐渍化程度最为严重, 集中于大于 16ms/m。整个研究区的重度盐渍化地比例为 32.87%, 主要位于低海拔固定草灌丛沙堆的地貌区域中。④研究区中度盐渍化比例为 13.71%, 主要零星分布于绿洲内部, 较为集中的分布在研究区东北部和绿洲最南端, 所处的地貌类型主要是低海拔固定草灌丛沙堆。从以上分析可以得出盐渍化程度受高程和地貌类型的影响显著, 高程较低的地区盐渍化程度普遍较重, 较高的区域盐渍化程度普遍较低。因此对研究区以主要地貌类型进行分区后, 用 BP-ANN 预测后的精度分析见表 5, 结果见图 10。

从表 5 可得: ①当物候参数参与反演时, 按地貌类型进行分区后的预测精度有了明显的提高, $RMSE$ 从 9.55 减小为 8.18, 大于按植被类型分区时的 7.73; R^2 从 0.79 增加为 0.85, 小于按植被类型分区时的 0.88; ME 绝对值从 0.42 减少为 0.11, 大于按植被类型分区时的 0.04, 偏离真实值的幅度较大。②在无物候参数参与反演时, 按地貌类型分区后的预测精度略微下降, $RMSE$ 从 11.55 增加为 13.52, R^2 从 0.68 减少为 0.60, ME 绝对值从 0.88 增加为 3.78。从图 10 中可以得出: 盐渍化与地貌类型呈高度对应的聚集分布。在较高海拔区的中海拔冲积扇平原和中海拔冲积洪积扇平原的盐渍化程度较低, 集中于 0—5.50ms/m。处于稀疏植被区和荒漠区的低海拔半固定草灌丛沙堆、低海拔固定草灌丛沙堆地貌类型的盐渍化程度较重, 主要位于研究区东北部、南部和西部绿洲边缘区, 电导率普遍大于 16.49ms/m。低海拔冲积扇平原是研究区主要的地貌类型, 盐渍化普遍较重, 集中于 5.50—16.49ms/m, 但位于研究区南部边的部分区域盐渍化较轻, 集中于 0—5.50ms/m。位于研究区南部和塔里木河北岸交界的低海拔冲积河漫滩盐渍化较重, 但集中于小于 34ms/m。综上分析可以得

出基于地貌类型分区后的整体预测精度比根据植被分区低,但显著高于不分区时的精度,在以后的分析中以植被分区来作为依据更为适宜。

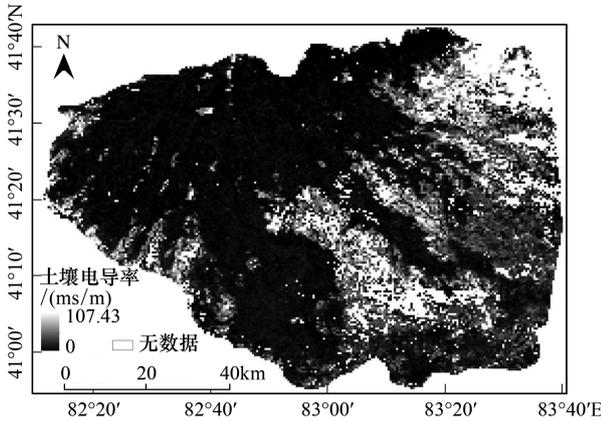


图 9 基于植被类型分区的盐渍化组合结果图

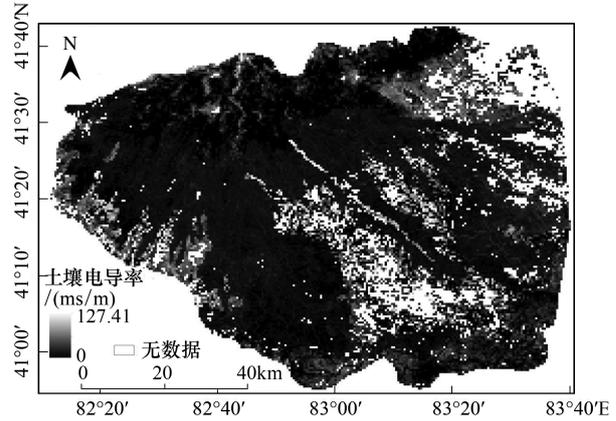


图 10 基于地貌类型分区的盐渍化组合结果图

Fig. 9 Combination inversion result of soil salinity based on vegetation partitioning

Fig.10 Combination result based on geomorphological partitioning

表 5 通过地貌类型分区后不同结果反演的精度比较

Table 5 Comparing different precision results through inversion soil salinity based on geomorphological partitioning

参数 Parameters	指标 Indicators	所有样点 (不分区) Whole sample (non-partitioning)	低海拔固定 草灌丛沙堆 Low altitude fixed grass brush sand pile	低海拔冲 积扇平原 Low-lying alluvial fan plain	中海拔冲 积扇平原 The middle elevation of alluvial fan plain	分区后汇总 Combination result of soil salinity based on geomorphological partitioning
无物候参数 Non-phenological indicators	RMSE ME R ²	11.55 -0.88 0.68	28.84 21.25 0.60	4.07 1.24 0.84	3.45 0.43 0.52	13.52 3.78 0.60
有物候参数 Included phenological indicators	RMSE ME R ²	9.55 0.42 0.79	12.94 -1.59 0.93	2.75 -0.42 0.94	3.44 1.95 0.77	8.18 -0.11 0.85

改为斜体

RMSE
ME
R²
RMSE
ME
R²

4 结论与讨论

通过反演得到 10 种物候参数和计算得到植被指数、盐渍化指数、地形参数等 12 种非物候参数作为 BP-ANN 模型的输入因子,把野外实测的电导率数据作为输出数值,最后反演得到盐渍化信息空间分布图,得到以下结论:

在实验室

(1) 盐渍化的形成受多种因素的影响,与物候参数大多呈非线性关系,不能单纯的以某拟合公式来进行表达,需借助人神经网络超强的非线性拟合能力来反演盐渍化信息。

(2) 代表生物累积量的 LSI 和 SSI 最能显著的表征盐渍化的变化情况。

(3) 通过深挖植被多方面的信息,在融入物候参数后的盐渍化反演精度显著提高,可决系数从 0.68 增加为 0.79,但是仅依据植被方面的信息不足以来精确反演盐渍化信息,需要加入地形、影像数据和土壤水分空间分布情况等方面的信息。

(4) 按照植被类型分区后的盐渍化信息预测精度进一步提升,R²达到了 0.88。极可能是因为通过植被分区研究后能够用 BP-ANN 模型拟合得到对应最佳局部的拟合方程,因此十分有必要按照植被类型进行分区

来反演盐渍化信息。

改为斜体

(5) 按照地貌类型分区后的预测精度相比于不分区时有显著的增加, **RMSE** 从 9.55 减小为 8.18, R^2 从 0.79 增加为 0.85, 但综合预测精度比按照植被类型时偏低。

(6) 研究区非盐渍化和轻度盐渍化、中度盐渍化和重度盐渍化地比例分别为 53.42%、13.71% 和 32.87%, 盐渍化地普遍存在, 研究区东部和东南部盐渍化最为严重。高程和地貌类型对盐渍化分布影响显著。

综上分析可得出融合物候特征和按照植被类型或地貌类型分区后盐渍化的反演精度显著提高。但本文的采样点较少, 只有 87 个样点, 在建立 BP-ANN 神经网络模型时数据量略显不足, 但是渭库绿洲本身绿洲-荒漠形态的界限鲜明, 在绿洲农用地区、绿洲荒漠交错带和荒漠对应区域的同质性较强, 因此野外实测的样点虽较少, 但是均匀分布在了这 3 个大区域中, 所以文中分析的结果基本符合实际情况。因此本文侧重点在于介绍一种结合物候与非物候参数来进行反演盐渍化信息的方法, 以及按照植被类型和地貌类型分区进行预测盐渍化信息的思维模式。物候参数代表盐渍化长期受影响的因素, 非物候参数主要代表短期内的影响因素, 通过探讨结合长期和短期内的影响因子来反演盐渍化信息, 最后得出这种结合方法的预测精度较高, 具有较高的应用潜力。以后应该要针对研究区多采集样点, 以更好的挖掘物候参数在预测盐渍化信息空间分布的能力, 并进一步探讨如同时考虑按植被和地貌分区后的预测精度, 以及按照植被和地貌类型分区后对于预测结果的影响机理。

参考文献 (References):

- [1] 塔西甫拉提·特依拜, 吐尔逊·艾山, 海米提·司马义, 丁建丽. 土壤盐渍化遥感监测研究进展综述. 新疆大学学报: 自然科学版, 2008, 25(1): 1-7.
- [2] Gorji T, Tanik A, Sertel E. Soil salinity prediction, monitoring and mapping using modern technologies. *Procedia Earth and Planetary Science*, 2015, 15: 507-512.
- [3] Metternicht G I, Zinck J A. Remote sensing of soil salinity: potentials and constraints. *Remote sensing of Environment*, 2003, 85(1): 1-20.
- [4] 候春玲. 基于 BP 神经网络的黄河三角洲典型盐渍区遥感监测研究[D]. 青岛: 中国石油大学, 2010.
- [5] 刘勤, 王宏卫, 丁建丽, 柴春梅. 干旱区区域土壤盐渍化监测研究进展及其未来热点. 新疆大学学报: 自然科学版, 2014, 31(1): 108-115.
- [6] 姚远, 丁建丽, 雷磊, 江红南, 张芳, 牛涛. 干湿季节下基于遥感和电磁感应技术的塔里木盆地北缘绿洲土壤盐分的空间变异性. *生态学报*, 2013, 33(17): 5308-5319.
- [7] 丁建丽, 瞿娟, 孙永猛, 张永福. 基于 MSAVI-WI 特征空间的新疆渭干河—库车河流域绿洲土壤盐渍化研究. *地理研究*, 2013, 32(2): 223-232.
- [8] 丁建丽, 姚远, 王飞. 干旱区土壤盐渍化特征空间建模. *生态学报*, 2014, 34(16): 4620-4631.
- [9] 丁建丽, 伍漫春, 刘海霞, 李争光. 基于综合高光谱指数的区域土壤盐渍化监测研究. *光谱学与光谱分析*, 2012, 32(7): 1918-1922.
- [10] 赵振亮, 塔西甫拉提·特依拜, 张飞, 买买提·沙吾提, 雷磊, 桂东伟. 塔里木河中游典型绿洲土壤含盐量的光谱特征. *自然灾害学报*, 2012, 21(5): 72-78.
- [11] 张芳, 熊黑钢, 安方舟, 夏倩柔. 基于盐(碱)植被盖度的土壤碱化分级. *土壤学报*, 2012, 49(4): 665-672.
- [12] Yin C H, Feng G, Zhang F S, Tian C Y, Tang C X. Enrichment of soil fertility and salinity by tamarisk in saline soils on the northern edge of the Taklamakan Desert. *Agricultural Water Management*, 2010, 97(12): 1978-1986.
- [13] Taghizadeh-Mehrjardi R, Minasny B, Sarmadian F, Malone B P. Digital mapping of soil salinity in Ardakan region, central Iran. *Geoderma*, 2014, 213(213): 15-28.
- [14] Lobell D B, Lesch S M, Corwin D L, Ulmer M G, Anderson K A, Potts D J, Doolittle J A, Matos M R, Baltes M J. Regional-scale soil salinity in the Red River Valley using multi-year MODIS EVI and NDVI. *Journal of Environmental Quality*, 2010, 39(1): 1-11.
- [15] Zhang T T, Qi J G, Gao Y, Ouyang Z T, Zeng S L, Zhao B. Detecting soil salinity with MODIS time series VI data. *Ecological Modelling*, 2012, 243: 480-489.
- [16] 牛增懿, 丁建丽, 李艳华, 王爽, 王璐, 马成霞. 基于高分一号影像的土壤盐渍化信息提取方法. *干旱区地理*, 2016, 39(1): 171-181.
- [17] Douaoui A E K, Nicolas H, Walter C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data. *Geoderma*, 2006, 134(1/2): 217-230.
- [18] Wiegand C, Anderson G, Lingle S, Escobar D. Soil salinity effects on crop growth and yield-Illustration of an analysis and mapping methodology for sugarcane. *Journal of Plant Physiology*, 1996, 148(3/4): 418-424.
- [19] Madrigal L P, Wiegand C L, Meraz J G, Rubio B D R, Estrada X C, Ramirez O L. Soil salinity and its effect on crop yield: A study using satellite imagery in three irrigation districts. *Ingeniería Hidráulica en México*, 2003, 18: 83-97.

请在此逗号后面添加一个空格, 以保持全文的格式统一

- [20] Tilley D R, Ahmed M, Son J H, Badrinarayanan H. Hyperspectral reflectance response of freshwater macrophytes to salinity in a brackish subtropical marsh. *Journal of Environmental Quality*, 2007, 36(3): 780-789.
- [21] Zhang T T, Zeng S L, Gao Y, Ouyang Z T, Li B, Fang C M, Zhao B. Using hyperspectral vegetation indices as a proxy to monitor soil salinity. *Ecological Indicators*, 2011, 11(6): 1552-1562.
- [22] Dehaan R L, Taylor G R. Field-derived spectra of salinized soils and vegetation as indicators of irrigation-induced soil salinization. *Remote Sensing of Environment*, 2002, 80(3): 406-417.
- [23] 江红南, 丁建丽, 塔西甫拉提·特依拜, 赵睿, 张飞. 基于 ETM+数据的干旱区盐渍化土壤信息提取研究. *土壤学报*, 2008, 45(2): 222-228.
- [24] 尼格拉·塔西甫拉提. 渭干河—库车河三角绿洲土壤盐渍化遥感与近感协同监测方法研究[D]. 乌鲁木齐: 新疆大学, 2014.
- [25] 高婷婷, 丁建丽, 哈学萍, 张飞, 王飞. 基于流域尺度的土壤盐分空间变异特征——以渭干河-库车河流域三角洲绿洲为例. *生态学报*, 2010, 30(10): 2695-2705.
- [26] Eklundh L, Jönsson P. *Timesat 3.1 Software Manual*. Lund, Sweden; Lund University, 2011.
- [27] Khan N M, Rastokuev V V, Sato Y, Shiozawa S. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators. *Agricultural Water Management*, 2005, 77(1/3): 96-109.
- [28] 王飞, 丁建丽, 伍漫春. 基于 NDVI-SI 特征空间的土壤盐渍化遥感模型. *农业工程学报*, 2010, 26(8): 168-173.
- [29] Deering D W, Rouse J W Jr, Haas R H, Schell J A. Measuring "Forage Production" of grazing units from Landsat MSS Data//10th International Symposium on Remote Sensing of Environment. ERIM, Ann Arbor, 1975: 1169-1179.
- [30] Baret F, Guyot G, Major D J. TSAVI: A Vegetation Index which minimizes soil brightness effects on LAI And APAR estimation. *Quantitative remote sensing: an economic tool for the nineties // IGARSS '89: 12th Canadian symposium on remote sensing*. Vancouver, Canada, 1989: 1355-1358.
- [31] Qi J, Huete A R, Moran M S, Chehbouni A, Jackson R D. Interpretation of vegetation indices derived from multi-temporal SPOT images. *Remote Sensing of Environment*, 1993, 44(1): 89-101.
- [32] Sandholt I, Rasmussen K, Andersen, J. A simple interpretation of the surface temperature/vegetation index space for assessment of surface moisture status. *Remote Sensing of Environment*, 2002, 79(2/3): 213-224.
- [33] 秦承志, 杨琳, 朱阿兴, 李宝林, 裴韬, 周成虎. 平缓地区地形湿度指数的计算方法. *地理科学进展*, 2006, 25(6): 87-93.
- [34] Moore I D, Grayson R B, Ladson A R. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. *Hydrological Processes*, 1991, 5(1): 3-30.
- [35] 田苗, 王鹏新, 孙威. 基于地表温度与植被指数特征空间反演地表参数的研究进展. *地球科学进展*, 2010, 25(7): 698-705.
- [36] 张飞, 塔西甫拉提·特依拜, 丁建丽, 买买提·沙吾提, 桂东伟, 韩桂红, 孙倩. 塔里木河流域中游渭干河-库车河绿洲盐渍土盐信息光谱特征研究. *地理与地理信息科学*, 2012, 28(1): 65-70.
- [37] 陈斌, 张学霞, 华开, 徐珂. 温度植被干旱指数(TVDI)在草原干旱监测中的应用研究. *干旱区地理*, 2013, 36(5): 930-937.
- [38] 刘立文, 张吴平, 段永红, 邢立新, 陈圣波, 赵敏. TVDI 模型的农业旱情时空变化遥感应用. *生态学报*, 2014, 34(13): 3704-3711.
- [39] Gu D, Gillespie A. Topographic normalization of Landsat TM images of forest based on subpixel sun-canopy-sensor geometry. *Remote Sensing of Environment*, 1998, 64(2): 166-175.
- [40] Soenen S A, Peddle D R, Coburn C A. SCS+C: A modified sun-canopy-sensor topographic correction in forested terrain. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, 43(9): 2148-2159.
- [41] 王光华, 刘琪璟, 李俊清. 确定 SCS+C 地形校正模型经验参数 C 的不同抽样方法的比较. *计算机应用研究*, 2013, 31(10): 310-313.
- [42] Allbed A, Kumar L. Soil salinity mapping and monitoring in arid and semi-arid regions using remote sensing. *International Journal of Remote Sensing*, 2013, 2(4): 373-385. Advances (原单词少了一个s) view. Advance in
- [43] Jönsson P, Eklundh L. TIMESAT—a program for analyzing time-series of satellite sensor data. *Computers and Geosciences*, 2004, 30(8): 833-845.
- [44] 马新萍, 白红英, 贺映娜, 秦进. 基于 NDVI 的秦岭山地植被遥感物候及其与气温的响应关系——以陕西境内为例. *地理科学*, 2015, 35(12): 1616-1621.
- [45] 马勇刚, 张弛, 塔西甫拉提·特依拜. 中亚区域陆表植被物候时空变化特征分析. *干旱区地理*, 2014, 37(2): 310-317.
- [46] 朴世龙, 方精云. 1982-1999 年我国陆地植被活动对气候变化响应的季节差异. *地理学报*, 2003, 58(1): 119-125.
- [47] 侯学会, 牛铮, 高帅, 黄妮. 基于 SPOT-VGT NDVI 时间序列的农牧交错带植被物候监测. *农业工程学报*, 2013, 29(1): 142-150.
- [48] 叶鑫, 周华坤, 刘国华, 姚步青, 赵新全. 高寒矮生高草草甸主要植物物候特征对养分和水分添加的响应. *植物生态学报*, 2014, 38(2): 147-158.
- [49] 王静, 刘湘南, 黄方, 唐吉龙, 赵冷冰. 基于 ANN 技术和高光谱遥感的盐渍土盐分预测. *农业工程学报*, 2009, 25(12): 161-166.
- [50] 乔纪纲, 邹春洋. 基于神经网络的元胞自动机与土地利用演化模拟——以广州市白云区为例. *测绘与空间地理信息*, 2012, 35(7): 17-20.
- [51] 路春燕, 卫海燕, 白俊燕. 基于 BP 神经网络的城市化发展生态环境压力响应研究——以延安市为例. *干旱区资源与环境*, 2012, 26(4): 61-66.
- [52] 黎夏, 叶嘉安. 基于神经网络的元胞自动机及模拟复杂土地利用系统. *地理研究*, 2005, 24(1): 19-27.
- [53] 刘海霞. 基于 Bp Adaboost 预测器的土壤盐渍化预警研究[D]. 乌鲁木齐: 新疆大学, 2012.