

# MODIS 干旱监测指数结合 PSO\_RBFNN 反演甘肃省胡麻出苗期土壤湿度

杨慧,李玥,武凌,吴兵,高玉红,  
刘斌,周慧,唐洁,赵永伟

(甘肃农业大学信息科学技术学院,甘肃兰州730070)

**摘要:**针对目前单一的遥感干旱监测指数难以全面反映作物生长期土壤湿度的动态变化等问题,以甘肃省胡麻出苗期田间土壤相对湿度为研究对象,选取作物形态及绿度、冠层温度、冠层含水量等指标作为遥感干旱监测指数。利用 MODIS 遥感干旱监测指数和农田土壤相对湿度实测数据,结合经过粒子群优化的径向基函数神经网络(PSO\_RBFNN),构建了农田土壤相对湿度反演模型,并基于 BP\_NN、RBFNN、PSO\_RBFNN 人工神经网络和逻辑回归(LR)4种机器学习方法,利用土壤相对湿度实测数据对不同模型反演结果的精度进行了验证和对比分析。结果表明:与其他3种模型相对比,MODIS 遥感干旱监测指数与 PSO\_RBFNN 结合反演甘肃省胡麻出苗期的农田土壤相对湿度效果较好;模型对 10 cm 和 20 cm 深度土壤相对湿度的反演结果平均精度分别达到 89.91% 和 91.71%。与 RBFNN、LR 和 BP\_NN 模型相比,PSO\_RBFNN 模型 10 cm 土层平均预测精度分别提高 8.69 个百分点、4.94 个百分点、4.76 个百分点,20 cm 土层平均预测精度分别提高 6.91 个百分点、6.86 个百分点、9.32 个百分点。模型回归分析显示,相对于 1:1 斜线,PSO\_RBFNN 模型偏差最小,与 10 cm 和 20 cm 深度土壤相对湿度的相关系数分别达到 0.68 和 0.74,说明利用 PSO\_RBFNN 模型反演有效,可为区域农田土壤湿度遥感监测反演提供新的案例借鉴。

**关键词:**遥感;土壤湿度;干旱指数;中分辨率成像光谱仪;径向基函数神经网络;粒子群优化算法

**中图分类号:**S127; S152.7 **文献标志码:**A

## MODIS drought monitoring index combined with PSO\_RBFNN for soil moisture retrieval at the seedling stage of flax in Gansu Province

YANG Hui, LI Yue, WU Ling, WU Bing, GAO Yuhong,  
YAN Bin, ZHOU Hui, TANG Jie, ZHAO Yongwei

(College of Information Science and Technology, Gansu Agricultural University, Lanzhou, Gansu 730070, China)

**Abstract:** Given the limitations of a single remote sensing drought monitoring index in fully capturing the dynamic changes in soil moisture during crop growth, this study focuses on field soil relative moisture during the flax seedling stage in Gansu Province. The selected remote sensing drought monitoring indices include crop form and greenness, canopy temperature, and crop canopy water content. Utilizing the MODIS drought monitoring index and measured soil relative humidity data, combined with a radial basis function neural network (PSO\_RBFNN) optimized by particle swarm optimization, an inverse model of soil relative humidity in farmland was constructed. The accuracy of inversion results of different models—BP\_NN, RBFNN, PSO\_RBFNN artificial neural network, and logistic regression (LR)—was verified and compared using measured soil relative humidity data. The results indicated that the combination of the MODIS drought monitoring index and PSO\_RBFNN outperformed the other three models in retrieving the soil relative humidity at the flax seedling stage in Gansu Province. The average inversion

收稿日期:2024-04-29

修回日期:2024-06-27

基金项目:国家自然科学基金(32460443,32060437);甘肃省科技计划-自然科学基金重点项目(23JRRA1403)

作者简介:杨慧(1999-),女,甘肃庆阳人,硕士研究生,研究方向为遥感和深度学习。E-mail: 2369779565@qq.com

通信作者:李玥(1979-),女,甘肃永登人,教授,硕士生导师,主要从事智慧农业、人工智能和大数据分析挖掘研究。E-mail: liyue@gsau.

accuracy for soil relative humidity at 10 cm and 20 cm depths was 89.91% and 91.71%, respectively. Compared with the RBFNN, LR, and BP\_NN models, the average accuracy improved by 8.69, 4.94, 4.76 percentage points in 10 cm soil depth and 6.91, 6.86, 9.32 percentage points in 20 cm depths, respectively. Regression analysis showed minimal deviation relative to the 1 : 1 slash line, with correlation coefficients for soil relative humidity at 10 cm and 20 cm depths reaching 0.68 and 0.74, respectively. This study highlights the effectiveness of the PSO\_RBFNN model and offers a valuable reference for remote sensing monitoring and the inversion of regional farmland soil moisture.

**Keywords:** remote sensing; soil moisture; drought index; MODIS; RBFNN; PSO

胡麻(油用亚麻, *Linum usitatissimum* L.)是一种高营养作物,富含蛋白质、健康脂肪、维生素和矿物质,含抗氧化化合物,且耐旱、耐寒、耐贫瘠土壤。甘肃省是我国主要的胡麻生产区,也是干旱频发的区域<sup>[1-4]</sup>。土壤湿度对农作物生长和产量预测至关重要,是气候学、水文学和生态学领域衡量土壤干旱程度的重要指标,同时在模拟地表面过程和全球气候模型预测中扮演重要角色。土壤湿度不足将限制作物的正常生长,导致其生物量和产量下降,进而可能引发农业干旱<sup>[5-6]</sup>。监测土壤水分可以及时而准确地提供干旱预警信息,有助于及早采取有效的应对措施,减轻干旱对农业、生态系统和人类生活的影响。

传统的农业干旱监测主要依赖于监测站点的气象和水文数据,但由于站点分布不均和数量有限,难以实现对大范围地区的连续和有效监测<sup>[7]</sup>。农业干旱的遥感监测是一种间接评估方法,旨在通过遥感技术反演土壤和植被的水分状况<sup>[8-10]</sup>。此方法主要利用中、低空间分辨率的遥感影像数据,并结合可见光反演法和热红外反演法来进行分析。其中,可见光反演法包括直接法和间接法,而热红外反演法则涵盖经验法和热惯量法。通过这些综合技术手段,能够实现对农业干旱状况的准确监测和评估<sup>[11]</sup>。MODIS(中分辨率成像光谱仪)作为NASA发射的地球观测卫星 Terra 和 Aqua 上搭载的重要传感器之一,以其覆盖范围广、数据获取周期短、光谱分辨率高等特点,在干旱监测中展现出巨大潜力<sup>[12-14]</sup>。基于 MODIS 数据的干旱监测方法,通过提取植被指数、地表温度等关键信息,可以实现对地表干旱状况的定量评估。近年来,遥感技术的迅速发展为干旱监测提供了全新途径,学者们对土壤湿度遥感反演进行了大量探索和研究。张洁等<sup>[15]</sup>选用植被供水指数(VSWI)、E-VSWI、归一化多波段干旱指数(NMDI)进行冬小麦生长期(4—6月)的土壤湿度估算及早情监测,结果表明 VSWI 具有更好的稳定性和优异性;Carlson 等<sup>[16]</sup>提出的温度植被干旱指数(TVDI)结合归一化植被指数

(NDVI)和地表温度(LST),能够准确反映土壤湿度变化;李新尧等<sup>[17]</sup>研究表明,植被状态指数(VCI)在陕西省农业干旱监测中具有一定优势,该指数与降水相关;李华朋等<sup>[12]</sup>研究发现,植被水分指数(NDI17和NDI16)比植被绿度指数在农业干旱监测方面更有效;张红卫等<sup>[14]</sup>构建的NMDI指数在植被覆盖度较小时监测干旱效果更好;Jackson等<sup>[18]</sup>分析发现,冠层温度(TCI)升高可作为早期干旱预警信号。然而,利用MODIS遥感数据进行农田土壤水分监测的研究中,单独依赖某一种遥感干旱指数方法往往难以全面捕捉土壤湿度的动态变化,且不同农作物对遥感干旱监测指数的响应存在显著差异<sup>[19]</sup>。如NDVI是评估植被生长状况和营养健康的关键指标之一,提供关于植被覆盖和生长态势的重要信息,但其易受云层和大气条件、光照条件以及土壤背景的影响,且在裸露土地或低植被覆盖区域监测效果不佳<sup>[20-21]</sup>;相比之下,表观热惯量(ATI)能够较精确地反映裸露土壤或低植被覆盖区域地表的热性质,但在植被覆盖复杂或多样化的区域,其适用性会受到限制。因此,为更全面、准确地描述土壤干旱的严重程度,需结合多种变量和遥感指数综合评估土壤湿度和植被状况。

针对上述现状,本研究以甘肃地区胡麻出苗期田间土壤湿度为对象,利用MODIS遥感数据和农田土壤相对湿度实测数据,选取了作物形态及绿度、冠层温度、冠层含水量和土壤相对湿度等作为研究区域胡麻出苗关键期的干旱监测指标,并结合PSO\_RBFNN方法进行协同反演,以期构建一种MODIS遥感干旱指数结合PSO\_RBFNN的农地土壤湿度反演模型,通过监测土壤水分提供及时准确的干旱预警信息,对于采取有效的应对措施,减轻干旱对农业、生态系统和人类生活的影响具有重要意义。

## 1 材料与方法

### 1.1 研究区概况

如图1(见275页)所示,研究区甘肃省位于中国西北部(32°31'~42°57'N,92°23'~108°46'E),总

面积约 45.5 万 km<sup>2</sup>。甘肃省地形复杂多样,地势以临夏、定西、兰州为中心向周边地区逐渐升高,呈高原—山地—盆地交错分布。该地区气候类型多样,南部属于暖温带半湿润大陆性气候,北部属于温带半干旱干旱气候。受地理位置和地形条件影响,甘肃省的年平均降水量仅 300 mm,是全国平均水平的一半,干旱也成为甘肃省农业生产最主要的气象灾害,该地区每年农作物平均受旱面积 82.684 万 hm<sup>2</sup>,减产粮食 5~10 亿 kg<sup>[22]</sup>。干旱灾害的频繁发生,不仅影响农业生产,也对生态环境和社会经济造成了严重影响,粮食因干旱灾害减产是甘肃省面临的重要挑战。

## 1.2 数据来源及处理

研究数据源来自 MODIS,是从美国国家航空航天局 (<https://www.nasa.gov/>) 的地球观测卫星搭载的 Moderate Resolution Imaging Spectroradiometer (MODIS) 传感器获取数据源。本文采用 2010—2020 年 4 月的遥感数据,包括 MOD09A1 和 MOD11A2,该数据包括多个波段的地表观测信息(如可见光、红外线和微波等),覆盖了全球范围,具有较高的空间和时间分辨率<sup>[23]</sup>。

MOD09A1 是 Terra 卫星获取的 MODIS 地表反

射率产品,空间分辨率 500 m,8 d 合成产品,涵盖可见光、近红外和短波红外等共 7 个波段<sup>[24]</sup>。MOD11A2 是 MODIS 传感器观测到的地表温度产品之一,包含每天的地表温度和植被覆盖度数据,以 8 d 为一个周期发布。MOD11A2 是地表温度产品,包含多个波段的数据,比如温度波段 (*Band 31*) 和辐射波段 (*Band 32*)。温度波段的波长约为 11 μm,专门用于地表温度估计,具有较高的灵敏度;辐射波段的波长约为 12 μm,也可以用于地表温度的估计,与温度波段具有相关性。以上两个数据产品用于计算本文中所使用到的遥感干旱监测指数值。非遥感数据是指来自甘肃省行政区划矢量数据和农业气象观测站农田土壤相对湿度观测数据,其中,农田土壤相对湿度通过自动水分观测仪在 9 个气象站测定,测定土壤深度为 10 cm 和 20 cm,土壤相对湿度 = 土壤含水率 / 田间含水量。

本研究利用 Google Earth Engine (GEE) 平台对 MODIS 数据进行预处理,包括裁剪、拼接、波段选择、重采样、投影转换和剔除无效值等。另外,地表温度数据还需要采样到 500 m 以确保空间上具有一致的分辨率。对各个波段数据进行处理,根据表 1 中的指数算法进行运算,得到 8 种干旱遥感指数。

表 1 干旱监测参量及其 MODIS 遥感干旱监测指数计算方法

Table 1 The parameters for monitoring drought and the calculation method of MODIS drought monitoring index

干旱监测参量 Drought monitoring parameter	遥感干旱监测指数 Drought monitoring index using remote sensing technology	指数计算方法 Index calculation method
土壤含水量 Soil moisture content	表观热惯量 <i>ATI</i>	$ATI = \frac{1 - A}{T_d - T_n}$
	植被供水指数 <i>VSWI</i>	$VSWI = \frac{NDVI}{LST}$
作物形态及绿度 Crop morphology and greenness	归一化植被指数 <i>NDVI</i>	$NDVI = \frac{B_2 - B_1}{B_2 + B_1}$
	植被条件指数 <i>VCI</i>	$VCI = \frac{NDVI - NDVI_{\min}}{NDVI_{\max} - NDVI_{\min}}$
作物冠层含水量 Crop canopy water content	红外指数归一化差值 <i>NDIIB6</i>	$NDIIB6 = \frac{B_2 - B_6}{B_2 + B_6}$
	红外指数归一化差值 <i>NDIIB7</i>	$NDIIB7 = \frac{B_2 - B_7}{B_2 + B_7}$
作物冠层温度 Crop canopy temperature	归一化多波段干旱指数 <i>NMDI</i>	$NMDI = \frac{B_2 - (B_6 - B_7)}{B_2 + (B_6 - B_7)}$
	温度条件指数 <i>TCI</i>	$TCI = \frac{LST_{\max} - LST}{LST_{\max} - LST_{\min}}$

注:  $T_d$  为白天的温度,  $T_n$  为晚上的温度,  $A$  为全波段反照率;  $B_1$ 、 $B_2$ 、 $B_6$ 、 $B_7$  分别代表 MOD09A1 产品的 *Band 1*、*Band 2*、*Band 6*、*Band 7*;  $LST$  为地表温度,  $LST_{\min}$  和  $LST_{\max}$  分别为  $LST$  的最小值和最大值;  $NDVI$  为归一化植被指数,  $NDVI_{\min}$  和  $NDVI_{\max}$  分别为  $NDVI$  的最小值和最大值。

Note:  $T_d$  is the daytime temperature,  $T_n$  is the night temperature, and  $A$  is the all-band albedo.  $B_1$ ,  $B_2$ ,  $B_6$  and  $B_7$  represent *Band 1*, *Band 2*, *Band 6* and *Band 7* of MOD09A1 products respectively. The minimum and maximum values of  $LST$  are  $LST_{\min}$  and  $LST_{\max}$  respectively.  $NDVI$  is the normalized vegetation index.  $NDVI_{\min}$  and  $NDVI_{\max}$  are the minimum and maximum values of  $NDVI$ , respectively.

分析甘肃省胡麻出苗期的 MODIS 遥感干旱监测指数和土壤相对湿度相关性,构建 MODIS 遥感干旱监测指数集,基于 PSO\_RBFNN 模型,选取监测土壤含水量、作物形态和绿度、作物冠层温度和作物冠层含水量等参数作为综合评价指标。通过验证地面土壤相对湿度实测数据,从原始遥感干旱监测指数中筛选出了适宜的指标集为输入层,实测的土壤相对湿度为输出层,构建 PSO\_RBFNN 与胡麻出苗期的土壤相对湿度反演模型。

### 1.3 RBFNN 模型原理

径向基函数神经网络(RBFNN)是具有唯一最佳逼近(克服局部极小值问题)、训练简洁、学习收敛速度快等良好性能的前馈型神经网络,且 RBFNN 相对于反向传播神经网络 BP\_NN 在处理非线性问题、捕获局部特征、训练速度较快以及对异常值的鲁棒性等方面具有一系列优势<sup>[25]</sup>。其中 RBFNN 包含 3 层网络拓扑结构,如图 2 所示。

第一层为输入层,表示信源节点输入,该层输入适宜的遥感干旱监测指数数据集,记作  $m$  维向量  $x = \{x_1, x_2, \dots, x_a\}$ 。

第二层为隐藏层,由  $M$  个径向基神经元组成,使用 RBF 作为其激活函数。这些神经元负责将低维、非线性且难以划分的输入数据映射到高维、线性可分的空间。隐藏层节点的激活功能对输入做出局部反应,在接近基函数中心范围时会产生较大的输出;并且在输入远离中心点的情况下,输出会呈指数级衰减。这种设计有助于网络更好地捕捉数

据的非线性特征,并在高维空间内实现更优的线性可分性。其中高斯函数作为径向基函数为 RBFNN 神经网络充当传递函数,其公式为:

$$\phi(\|x - \mu_i\|) = \exp\left(-\frac{\|x - \mu_i\|^2}{2\sigma_i^2}\right) \quad (1)$$

式中,  $\phi$  表示高斯函数;  $x$  代表选定的 MODIS 遥感干旱监测指标数据集;  $\mu_i$  为隐藏层第  $i$  个节点的高斯函数中心点;  $\sigma_i$  为第  $i$  个节点的宽度参数或方差,用于控制函数的径向作用范围<sup>[26]</sup>。

第三层为输出层,含有  $p$  个线性神经元(激活函数为线性函数),最终的输出是隐藏层神经元输出的线性加权。计算公式为:

$$y_j = \sum_{i=1}^M w_{ij} \phi(\|x - \mu_i\|), \quad j = 1, 2, \dots, p \quad (2)$$

式中,  $w_{ij}$  为从隐藏层到输出层的权值;  $y_j$  为与输入样本对应的网络的第  $j$  个输出结点的实际输出。

### 1.4 粒子群优化(PSO)算法

粒子群优化算法(particle swarm optimization, PSO)是一种智能优化算法,最初由 Eberhart 和 Kennedy 提出<sup>[27]</sup>。PSO 算法将问题的每个潜在解看作是一个“粒子”,这些粒子在解空间中飞行,每个粒子有一个位置和速度。粒子通过调整自身的速度和位置来搜索解空间,并根据其自身的历史搜索经验以及周围粒子的行为来调整飞行方向和速度,通过多次迭代,粒子群逐渐接近问题的最优解。

粒子群优化算法的速度和位置更新公式<sup>[28]</sup>如下:

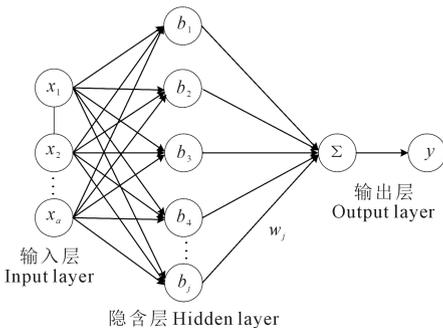
速度更新公式:

$$v_{zd}^{k+1} = \omega v_{zd}^k + c_1 r_1 (p_{zd,pbest}^k - x_{zd}^k) + c_2 r_2 (p_{zd,gbest}^k - x_{zd}^k) \quad (3)$$

位置更新公式:

$$x_{zd}^{k+1} = x_{zd}^k + v_{zd}^{k+1} \quad (4)$$

式中,  $z, d, k, \omega$  分别表示粒子序号、维度序号、迭代次数以及惯性权重,其中,  $z = 1, 2, \dots, N, d = 1, 2, \dots, N$ ;  $c_1, c_2$  分别表示个体和群体学习因子;  $r_1, r_2$  为区间  $[0, 1]$  内的随机数,增加搜索的随机性;  $v_{zd}^k, v_{zd}^{k+1}$  分别表示粒子  $z$  在第  $k, k+1$  次迭代中第  $d$  维的速度;  $x_{zd}^k$  表示粒子  $z$  在第  $k$  次迭代中第  $d$  维的位置;  $x_{zd}^{k+1}$  表示粒子  $z$  在第  $k+1$  次迭代后在维度  $d$  上的新位置,这个位置是根据粒子当前位置  $x_{zd}^k$  和更新后的速度  $v_{zd}^{k+1}$  计算得到的;  $p_{zd,pbest}^k, p_{zd,gbest}^k$  表示粒子  $z$  或群体在第  $k$  次迭代中第  $d$  维的历史最优位置,即在本次迭代后,第  $z$  个粒子或群体搜索到的最优解。



注:  $x_1, x_2, \dots, x_a$  表示共有  $a$  个输入节点;  $b_1, b_2, \dots, b_j$  表示存在  $j$  个隐节点;  $w_1, w_2, \dots, w_j$  表示从隐层到输出层存在  $j$  个线性连接权值;  $y$  代表农田土壤相对湿度。

Note:  $x_1, x_2, \dots, x_a$  indicate that there is  $a$  total of input nodes.  $b_1, b_2, \dots, b_j$  means there are  $j$  hidden nodes;  $w_1, w_2, \dots, w_j$  indicate that there are  $j$  linear connection weights from the hidden layer to the output layer, and  $y$  represents the relative humidity of farmland soil.

图 2 RBFNN 拓扑结构

Fig.2 RBFNN architecture

### 1.5 基于 PSO-RBFNN 构建土壤相对湿度反演模型

2010—2020 年获取的 MODIS 干旱监测指数和土壤相对湿度共 86 组样本数据中,将 2016、2017 年和 2018 年共 25 组数据作为预测样本,其余 61 组数据作为训练样本。基于这些样本,对反映甘肃省胡麻出苗期的土壤相对湿度的输入与输出参数进行了详细的统计分析,结果如表 2 所示。

针对甘肃省胡麻出苗期,以 2010—2020 年获取的 MODIS 遥感干旱监测指数作为输入层数据,实测的农田土壤相对湿度作为输出层数据,运用粒子群优化(PSO)算法对径向基函数神经网络(RBFNN)的关键参数进行优化,包括中间层神经元数量、学习率及训练迭代次数,构建基于 PSO\_RBFNN 的农地土壤相对湿度反演模型(图 3),模型的详细构建步骤如下:

(1)将遥感干旱指数与土壤相对湿度数据集进行划分,并对所有数据进行归一化处理。

(2)初始化 RBF 神经网络参数,包括隐含层中的神经元数量(35)、学习速率(0.01)以及迭代训练次数(500)。网络权重应随机初始化,初始时中心点与参数  $\beta$  均不赋予实际值(即设为 None)。同时,对粒子群进行初始化设置,随机确定粒子的初始速度和位置,将 RBFNN 神经网络的 3 个关键参数组成一个粒子向量。

(3)为衡量粒子的适应性,制定了以 PSO\_RBFNN 输出结果的均方误差(MSE)作为标准的适应度评价函数。通过计算粒子群内每个个体在初始时刻的适应度值,并采用均方误差公式进行评估,其计算公式如下:

$$MSE = \frac{\sum_{i=1}^N (z_i - z_j)^2}{N} \quad (5)$$

式中, $MSE$  为均方误差; $N$  为样本数; $z_i$  为土壤相对湿度的真实值; $z_j$  为土壤相对湿度的预测值。

(4)通过对粒子适应度值的比较,确定更新粒子个体的最佳位置和整体的最佳位置,指导粒子群在搜索空间中朝着更优的方向移动。

(5)通过对粒子的速度和位置进行调整,根据公式(3)和公式(4)重复计算适应度值,并更新粒子的个体最优位置和全局最优位置,以推动粒子群在搜索空间中不断优化。

(6)判断迭代次数是否达到最大或适应度收敛,若没有,则继续迭代,否则输出满足 PSO\_RBFNN 反演农地土壤相对湿度模型的全局最优参数。

(7)利用粒子群优化算法得到的全局最优参数来构建 PSO\_RBFNN 反演农地土壤相对湿度模型,进行胡麻生长关键期的土壤相对湿度反演。

## 2 结果与分析

### 2.1 MODIS 遥感干旱监测指数与农田土壤相对湿度相关性分析

通过研究甘肃省 8 种遥感干旱监测指数与土壤相对湿度的相关性发现,各种遥感干旱监测指数与不同深度土壤相对湿度的实测数据的相关性表现出明显差异。如表 3 所示,对于 10 cm 土层深度,反映土壤含水量的指数  $NMDI$  在榆中、临夏、麦积 3 个地区反演效果较好,相关系数分别为 0.4、0.2 和 0.4 左右;反映土壤含水量的指数  $ATI$  和  $VSWI$  在定西、

表 2 反演土壤相对湿度模型的输入和输出参数

Table 2 Inversion of the input and output parameters of the soil relative humidity model

参数 Parameter	状态 Status	最小值 Minimum	最大值 Maximum	25%分位数 25% quantile	50%中位数 50% median	75%分位数 75% quantile	标准差 Standard deviation
$NDVI$	输入 Input	0.2609	0.5113	0.3074	0.3487	0.4094	0.0635
$VCI$	输入 Input	0.1318	0.6057	0.2563	0.3220	0.4392	0.0228
$NDIIB7$	输入 Input	0.0432	0.3436	0.1085	0.1437	0.2129	0.0715
$NMDI$	输入 Input	0.4502	0.6218	0.5183	0.5505	0.5786	0.0434
$TCI$	输入 Input	0.1810	0.8019	0.4468	0.5566	0.6027	0.1161
$VSWI$	输入 Input	0.0133	0.0403	0.0191	0.0215	0.0263	0.0058
10 cm 土层土壤 相对湿度 Soil relative humidity of 10 cm layer	输出 Output	0.2200	0.9600	0.5600	0.6400	0.7600	0.1439
20 cm 土层土壤 相对湿度 Soil relative humidity of 20 cm layer	输出 Output	0.4200	0.9800	0.6700	0.7600	0.8300	0.1260

西峰和岷县 3 个地区的反演效果较优,相关系数约为 0.3 和 0.2。对于定西地区,ATI 指数与不同深度土壤相对湿度的差异性较大,而 NDVI 指数在 20 cm 土层深度的反演效果较好,相关系数为 0.2 左右。VSWI、ATI、NDIIB7 和 NDIIB6 指数的反演效果在西峰地区较稳定,与 10 cm 和 20 cm 深度土壤相对湿度的相关系数绝对值均大于 0.2。对于武威地区,反映作物形态及绿度的指数 VCI 反演效果较好,与 10 cm 和 20 cm 土壤深度的相关系数分别约为 0.1 和

0.4。反映作物冠层含水量的指数 NDIIB6 在东乡地区反演效果较好,与 10 cm 和 20 cm 深度土壤相对湿度的相关系数分别约为 0.5 和 0.2。对于麦积地区,8 种遥感干旱监测指数与土壤相对湿度的相关性基本保持一致。

综上,通过分析 8 种 MODIS 干旱监测指数与 10 cm 和 20 cm 深度土壤相对湿度的相关性表现,选取了 VSWI、NDVI、VCI、NDIIB7、NMDI、TCI 作为农田土壤相对湿度反演模型的评价指标集。

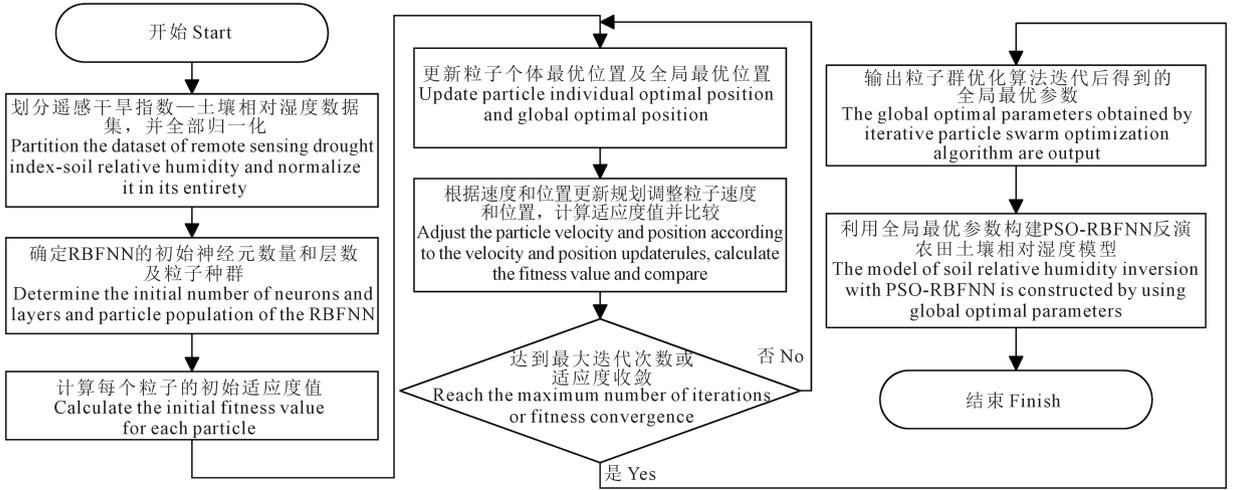


图 3 PSO-RBFNN 土壤相对湿度反演模型流程图

Fig.3 PSO-RBFNN flow chart of soil relative humidity inversion model

表 3 土壤相对湿度与干旱监测指数的相关性表现

Table 3 Correlation between soil relative humidity and drought monitoring index

地区 Area	土层深度 Soil depth /cm	相关性表现 The expression of correlation
榆中 Yuzhong	10	NMDI>ATI>VCI>VSWI>TCI>NDIIB6>NDVI>NDIIB7
	20	ATI>NMDI>NDIIB6>NDVI>NDIIB7>VCI>TCI>VSWI
定西 Dingxi	10	ATI>VSWI>NDIIB7>NDVI>VCI>NDIIB6>NMDI>TCI
	20	NDVI>VCI>NDIIB6>NMDI>NDIIB7>VSWI>TCI>ATI
西峰 Xifeng	10	VSWI>ATI>NDIIB7>NDIIB6>NDVI>VCI>NMDI>TCI
	20	VSWI>ATI>NDIIB7>NDIIB6>VCI>NMDI>NDVI>TCI
武威 Wuwei	10	VCI>ATI>TCI>NMDI>VSWI>NDVI>NDIIB7>NDIIB6
	20	VCI>NMDI>NDVI>NDIIB6>NDIIB7>VSWI>TCI>ATI
平凉 Pingliang	10	TCI>NMDI>NDVI>NDIIB6>NDIIB7>VCI>VSWI>ATI
	20	NMDI>NDVI>VSWI>VCI>ATI>NDIIB7>TCI>NDIIB6
临夏 Linxia	10	NMDI>NDVI>VCI>NDIIB7>NDIIB6>VSWI>TCI>ATI
	20	VSWI>VCI>NDVI>NDIIB7>NDIIB6>ATI>NMDI>TCI
东乡 Dongxiang	10	NDIIB6>NMDI>TCI>NDIIB7>NDVI>ATI>VCI>VSWI
	20	NDIIB6>NDIIB7>NDVI>TCI>VCI>NMDI>VSWI>ATI
岷县 Minxian	10	ATI>VSWI>NMDI>TCI>VCI>NDVI>NDIIB7>NDIIB6
	20	VSWI>ATI>VCI>NDVI>NMDI>NDIIB7>NDIIB6>TCI
麦积 Maiji	10	NMDI>VSWI>ATI>VCI>TCI>NDVI>NDIIB7>NDIIB6
	20	NMDI>VSWI>ATI>TCI>VCI>NDVI>NDIIB7>NDIIB6

2.2 土壤相对湿度反演模型测试及对比分析

为验证甘肃省胡麻出苗期不同深度土壤湿度的反演效果,将获得 2016、2017 年以及 2018 年各地区 10 cm 和 20 cm 深度的实测土壤相对湿度,共计 25 组样本作为验证数据集。基于建立的 RBFNN 和 PSO\_RBFNN 模型进行预测。为验证农田土壤相对湿度反演模型的精度与准确度,评价指标选择了均方误差 (MSE) 和模型精度 (P)。为验证甘肃省胡麻苗期不同深度的土壤湿度反演效果,建立不同的模型 (LR、BP\_NN、RBFNN、PSO\_RBFNN) 来反演农田土壤相对湿度,分析 RBFNN 和 PSO\_RBFNN 模型预测结果的精度与误差,通过与 LR 模型和 BP\_NN 模型的精度和误差进行比较,计算均方误差和模型精度来评价模型反演效果, MSE 是预测误差平方值的平均数,它衡量了“平均误差”的平方,因此可以更好地反映模型预测值与真实值之间的偏差。MSE 的值越小,表示模型对数据的拟合效果越好,模型预测的准确性也就越高;反之,模型反演效果越差。其中模型反演精度计算公式为:

$$P = 1 - \frac{(PV - AV)}{AV} \times 100\% \quad (6)$$

式中,  $AV$  为实测值;  $PV$  为预测值;  $P$  为模型预测精度(%)。MSE 的计算公式如公式 5 所示。

由表 4 可知, PSO\_RBFNN 模型在 2016 年对于 10 cm 深度土壤相对湿度的反演效果以平凉和麦积地区较好 ( $P_{平凉} = 99.96\%$ ,  $P_{麦积} = 95.89\%$ ); 而武威和定西在 20 cm 深度土壤相对湿度的反演效果较好 ( $P_{武威} = 99.82\%$ ,  $P_{定西} = 97.48\%$ )。由表 5 可知, 2017 年 PSO\_RBFNN 模型在 10 cm 和 20 cm 深度土壤相

对湿度反演结果中麦积和临夏地区均具有较好的表现 ( $P_{10\text{ cm}麦积} = 99.01\%$ ,  $P_{10\text{ cm}临夏} = 95.98\%$ ;  $P_{20\text{ cm}麦积} = 98.25\%$ ,  $P_{20\text{ cm}临夏} = 98.00\%$ ); 此外, PSO\_RBFNN 模型对 10 cm 土层土壤相对湿度的反演结果在榆中地区表现较好 ( $P_{榆中} = 95.38\%$ ), 对 20 cm 土层深度反演在东乡地区效果最好 ( $P_{东乡} = 96.71\%$ )。由表 6 可知, 2018 年中 PSO\_RBFNN 模型在 10 cm 和 20 cm 深度土壤相对湿度反演效果较佳的分别是东乡和榆中 ( $P_{10\text{ cm}东乡} = 94.79$ ,  $P_{20\text{ cm}榆中} = 96.24\%$ )。由表 7 可以看出, 利用 MODIS 遥感干旱监测指数与 PSO\_RBFNN 结

表 4 2016 年不同深度土壤相对湿度模型测试结果比较

Table 4 Comparative analysis of soil relative humidity models of varying depths in 2016

地区 Area	土层深度 Soil depth /cm	实测值 Actual value AV	预测值 Predicted value PV				预测精度 Prediction accuracy P/%			
			LR	BP_NN	RBFNN	PSO_RBFNN	LR	BP_NN	RBFNN	PSO_RBFNN
定西	10	0.61	0.6064	0.6099	0.5134	0.5512	99.41	99.98	84.16	90.37
Dingxi	20	0.52	0.6755	0.6776	0.5087	0.5331	70.09	69.68	97.82	97.48
西峰	10	0.69	0.5990	0.6578	0.5895	0.5506	86.81	95.33	85.44	80.67
Xifeng	20	0.63	0.6672	0.7557	0.6837	0.6487	94.09	81.63	91.50	97.03
武威	10	0.61	0.6504	0.6604	0.7614	0.7016	93.38	91.37	75.18	84.99
Wuwei	20	0.83	0.7433	0.7485	0.8899	0.8315	89.55	90.18	92.87	99.82
平凉	10	0.70	0.5951	0.6566	0.7641	0.7003	85.01	93.81	90.85	99.96
Pingliang	20	0.63	0.6557	0.7502	0.8823	0.7915	95.92	80.93	59.95	74.36
临夏	10	0.77	0.6847	0.6579	0.6972	0.7049	88.92	85.44	90.54	91.55
Linxia	20	0.79	0.8113	0.7531	0.8339	0.8566	97.31	95.33	94.45	91.57
东乡	10	0.48	0.6395	0.6372	0.6800	0.5588	66.78	67.25	58.33	83.58
Dongxiang	20	0.61	0.7054	0.6984	0.6873	0.5661	84.35	85.51	87.32	92.81
岷县	10	0.56	0.5875	0.6809	0.5369	0.6052	95.10	78.41	95.87	91.93
Minxian	20	0.62	0.6827	0.7860	0.5625	0.6983	89.88	73.22	90.72	87.37
麦积	10	0.58	0.6644	0.6792	0.7509	0.6039	85.44	82.89	70.54	95.89
Maiji	20	0.73	0.7985	0.7878	0.8922	0.7084	90.62	92.09	77.79	97.04

表 5 2017 年不同土壤相对湿度模型测试结果比较

Table 5 Comparative analysis of soil relative humidity models of varying depths in 2017

地区 Area	土层深度 Soil depth /cm	实测值 Actual value AV	预测值 Predicted value PV				预测精度 Prediction accuracy P/%			
			LR	BP_NN	RBFNN	PSO_RBFNN	LR	BP_NN	RBFNN	PSO_RBFNN
榆中	10	0.56	0.6693	0.6743	0.6274	0.5859	80.49	79.59	87.97	95.38
Yuzhong	20	0.68	0.7430	0.7217	0.6448	0.6359	90.73	93.87	94.83	93.52
定西	10	0.53	0.6384	0.6370	0.5918	0.5933	79.55	79.82	88.33	88.07
Dingxi	20	0.50	0.7082	0.7022	0.6338	0.5925	58.37	59.57	73.25	81.50
西峰	10	0.48	0.6054	0.6732	0.4625	0.4449	73.87	59.76	96.36	92.69
Xifeng	20	0.44	0.6538	0.7386	0.5041	0.4799	51.41	32.13	85.44	90.93
武威	10	0.58	0.6486	0.6714	0.6632	0.6265	88.17	84.24	85.66	91.98
Wuwei	20	0.68	0.7390	0.7382	0.7557	0.7173	91.33	91.45	88.86	94.51
平凉	10	0.46	0.5942	0.6289	0.5420	0.5529	70.82	63.28	82.18	79.80
Pingliang	20	0.53	0.6353	0.7052	0.5888	0.5876	80.13	66.94	88.91	89.14
临夏	10	0.74	0.6617	0.6927	0.7016	0.7103	89.42	93.61	94.82	95.98
Linxia	20	0.88	0.7756	0.7825	0.8470	0.8624	88.14	88.92	96.25	98.00
东乡	10	0.68	0.5992	0.6582	0.4956	0.4970	88.12	96.80	72.88	73.09
Dongxiang	20	0.56	0.7147	0.7194	0.4984	0.5416	72.37	71.53	88.99	96.71
岷县	10	0.68	0.6321	0.6988	0.6673	0.6570	92.96	97.24	98.14	96.61
Minxian	20	0.91	0.7222	0.8000	0.7439	0.7479	79.37	87.91	81.74	82.19
麦积	10	0.63	0.6528	0.6659	0.6662	0.6362	96.39	94.31	94.25	99.01
Maiji	20	0.80	0.7685	0.7607	0.7882	0.7860	96.06	95.09	98.52	98.25

表 6 2018 年不同深度土壤相对湿度模型测试结果比较

Table 6 Comparative analysis of soil relative humidity models of varying depths in 2018

地区 Area	土层深度 Soil depth /cm	实测值 Actual value AV	预测值 Predicted value PV				预测精度 Prediction accuracy P/%			
			LR	BP_NN	RBFNN	PSO_RBFNN	LR	BP_NN	RBFNN	PSO_RBFNN
榆中 Yuzhong	10	0.71	0.7109	0.6090	0.7694	0.7892	99.87	85.77	91.63	88.84
	20	0.78	0.8036	0.6694	0.8372	0.8094	96.98	85.82	92.67	96.24
定西 Dingxi	10	0.54	0.6847	0.6142	0.6719	0.6043	73.20	86.27	75.58	88.10
	20	0.63	0.7878	0.7042	0.7352	0.6655	74.95	88.23	83.28	94.36
西峰 Xifeng	10	0.50	0.6157	0.6762	0.5989	0.4440	76.86	64.76	80.23	88.79
	20	0.65	0.6583	0.7782	0.6757	0.5899	98.72	80.27	96.04	90.75
武威 Wuwei	10	0.60	0.6916	0.6375	0.8095	0.6896	84.74	93.75	65.09	85.07
	20	0.80	0.8013	0.7186	0.9639	0.8450	99.84	89.83	79.51	94.37
东乡 Dongxiang	10	0.64	0.7259	0.6245	0.8191	0.6733	86.57	97.58	72.01	94.79
	20	0.72	0.8637	0.7083	0.8991	0.7667	80.04	98.38	75.12	93.52
岷县 Minxian	10	0.80	0.5980	0.6899	0.6578	0.7559	74.75	86.24	82.23	94.49
	20	0.96	0.6838	0.8011	0.7795	0.7672	71.23	83.45	81.20	79.92
麦积 Maiji	10	0.78	0.6569	0.6507	0.3650	0.6777	84.22	83.43	46.80	86.89
	20	0.91	0.7890	0.7695	0.4321	0.8192	86.71	84.56	47.48	90.02

表 7 不同深度土壤相对湿度模型测试结果均值比较

Table 7 Comparison of mean values of soil relative humidity model test results of different depths

土层深度 Soil depth/cm	预测精度 Prediction accuracy P/%			
	LR	BP_NN	RBFNN	PSO_RBFNN
10	84.97	85.15	81.22	89.91
20	84.85	82.39	84.80	91.71

合反演 10 cm 土层深度的农田土壤相对湿度时表现较好,模型的平均反演精度达到 89.91%;传统的 LR 模型平均反演精度为 84.97%,BP\_NN 以及 RBFNN 模型精度分别为 85.15%和 81.22%;PSO\_RBFNN 模型相对于 LR、BP\_NN 和 RBFNN 模型的预测精度分别提高 4.94 个百分点、4.76 个百分点和 8.69 个百分点。对 20 cm 深度的农田土壤相对湿度反演模型中,RBFNN 模型的平均反演精度为 84.80%,LR 和 BP\_NN 模型的平均预测精度分别为 84.85%和 82.39%;PSO\_RBFNN 模型的反演效果最佳,平均反演精度达到 91.71%,相较于 RBFNN、LR 和 BP\_NN 模型分别提高 6.91 个百分点、6.86 个百分点和 9.32 个百分点。

### 2.3 农田土壤相对湿度反演模型的有效性验证

为进一步证实农田反演土壤相对湿度 PSO\_RBFNN 模型的有效性,分别基于 PSO\_RBFNN 和 RBFNN 模型,利用相关系数  $r$  和均方误差  $MSE$  对 2017 年甘肃胡麻出苗期土壤相对湿度进行反演分

析,以检验模型的有效性。模型预测值与实测值的回归分析结果如图 4 和图 5 所示。

由图 4 和图 5 可知,PSO\_RBFNN 模型在反演 10 cm 和 20 cm 土层深度模型时的均方误差值 ( $MSE$ ) 均小于 RBFNN 模型。 $MSE$  值越小,表示模型的预测值与真实值之间的差异越小,即预测精度越高。从相关系数来看,PSO\_RBFNN 模型的相关系数 ( $r_{10\text{ cm}} = 0.68, r_{20\text{ cm}} = 0.74$ ) 优于 RBFNN 模型 ( $r_{10\text{ cm}} = 0.51, r_{20\text{ cm}} = 0.64$ )。总之,MODIS 干旱监测指数与 PSO\_RBFNN 模型的结合反演结果表明其对不同深度土壤相对湿度有良好的反演效果。

### 2.4 甘肃省胡麻出苗期土壤监测反演图像

本研究利用 GEE 平台计算了 6 个遥感干旱监测指数值,并基于这些指数利用 Python 软件得出了 2017 年研究区域的 RBFNN 和 PSO\_RBFNN 土壤相对湿度预测值。在 ArcGIS 中采用反距离权重法对预测值进行插值,反演得到 2017 年胡麻出苗期(4 月份)的土壤相对湿度空间分布图<sup>[29]</sup>。如图 6 所示,研究区 2017 年胡麻出苗期农田主要为轻旱和中旱,定西、麦积、榆中和武威地区土壤相对湿度介于 50%~60%之间,属于轻旱;中旱则在西峰、平凉以及临夏地区,土壤相对湿度介于 40%~50%之间。与实测土壤相对湿度结果相比,RBFNN 和 PSO\_RBFNN 模型的预测结果基本接近于实测值。综上所述,本研究模型反演结果有效。

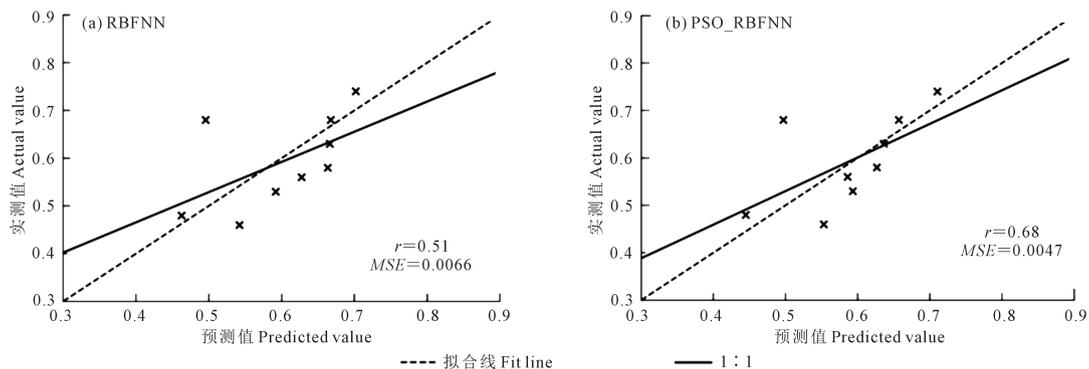


图 4 2017 年胡麻关键生长期不同模型的 10 cm 深度土壤相对湿度反演结果

Fig.4 Inversion results of soil relative humidity in 10 cm depth from different models at key growth stages of flax in 2017

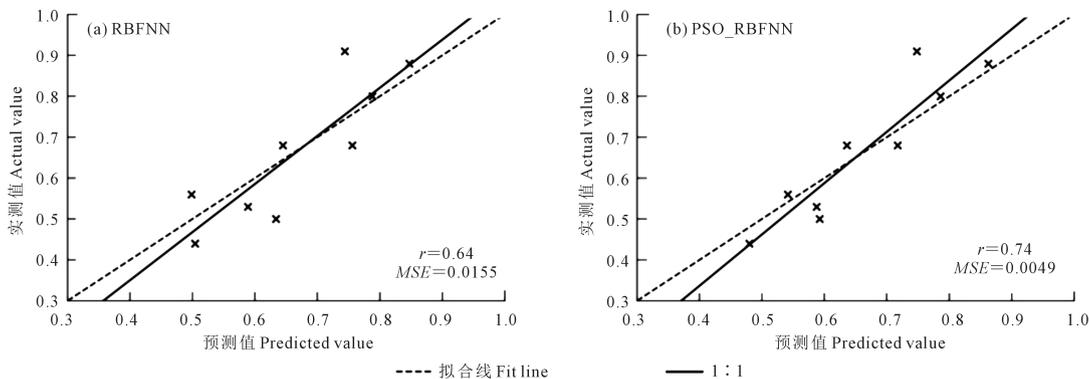


图 5 2017 年胡麻关键生长期不同模型的 20 cm 深度土壤相对湿度反演结果

Fig.5 Inversion results of soil relative humidity in 20 cm depth from different models at key growth stages of flax in 2017

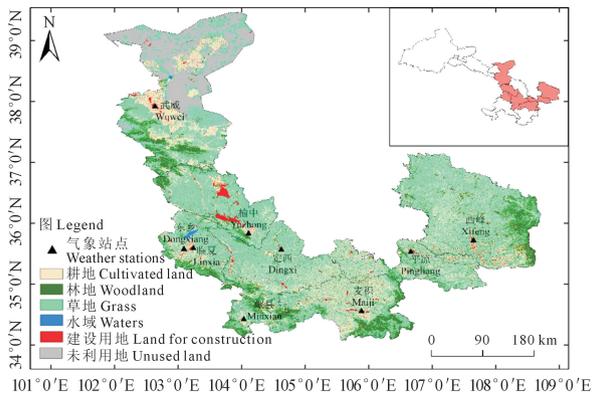


图 1 甘肃省研究区域概况图

Fig.1 Map of study area in Gansu Province

### 3 讨论与结论

土壤湿度是农作物生长发育的关键因素,直接影响作物的水分供应情况。研究表明,土壤湿度过低会限制作物生长,导致干旱应激,影响产量和品质;而土壤湿度过高可能造成根系缺氧,降低植物的抗病能力,甚至引发根部病害<sup>[30]</sup>。因此,适宜的土壤湿度能够保证作物顺利吸收养分和水分,维持正常的生理活动,对于保障农业生产至关重要。本研究提出一种基于 MODIS 遥感干旱监测指数与 PSO\_RBFNN 结合反演甘肃省胡麻出苗期的农田土壤相对湿度,通过对 8 种 MODIS 遥感干旱监测指数

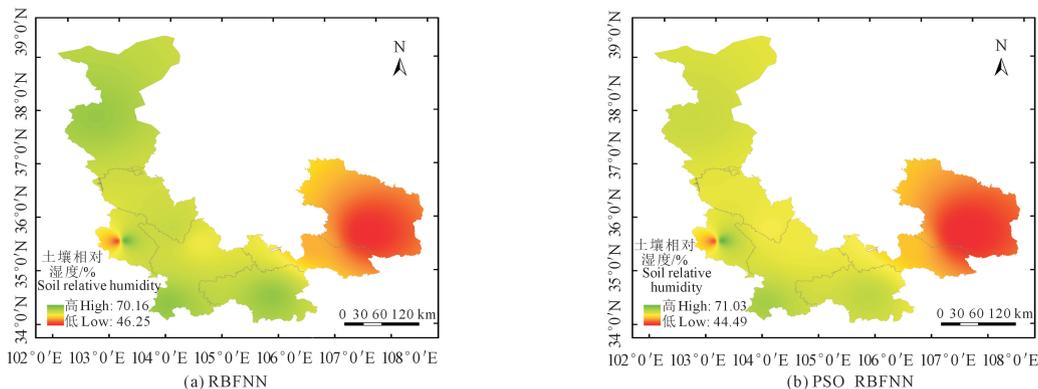


图 6 2017 年 4 月农田 10 cm 深度土壤相对湿度的反演结果

Fig.6 Results of the inversion of 10 cm soil relative humidity in farmland in April 2017

与土壤相对湿度关联度的分析,针对甘肃省胡麻出苗期,筛选出 6 个与该地区情况相适应的遥感干旱监测指数 ( $VSWI$ 、 $NDVI$ 、 $VCI$ 、 $NDIIB7$ 、 $NMDI$  和  $TCI$ ) 来构建土壤相对湿度的反演模型评价指标体系。这 6 项指数综合运用了多种遥感监测指标,使反演模型能够综合利用多个数据通道的信息,更准确地反映土壤湿度变化,包括土壤含水量、作物需水形态变化、植被冠层含水量以及植被冠层温度等。不同于黄友昕等<sup>[26]</sup>在 MODIS 干旱指数结合 RBFNN 反演冬小麦返青期土壤湿度时选用的  $VSWI$ 、 $EVI$ 、 $NDIIB7$ 、 $NMDI$  与  $TCI$  等 6 种遥感干旱监测指数,本研究在遥感干旱监测指数的选取上更侧重于考虑作物对干旱胁迫的特定响应。正如韩东等<sup>[7]</sup>在农业干旱卫星遥感监测与预测研究进展中指出,农业干旱程度不仅取决于降水和土壤水分的状况,更与作物对干旱胁迫的反应紧密相关。由于不同作物对干旱的敏感度和耐受性各异,且同一作物在其生长周期的不同阶段对干旱的反应也呈现差异化,因此本研究将作物需水作为核心考量因素分析胡麻出苗期对干旱胁迫的响应,从而更加精准地监测和预测农业干旱状况<sup>[7]</sup>。此外,还利用实测的土壤相对湿度数据来对不同模型的反演结果进行精度验证和比较分析。

研究表明,人工神经网络解决了传统方法在复杂问题上的局限性,具备非线性建模和自动特征提取能力,提高了计算效率和鲁棒性;同时通过正则化等技术提升了泛化能力,优化的训练策略加快了训练速度和收敛性能。RBFNN 本身具有结构简单、学习速度快和泛化能力强的特点,其结构包括输入层、隐藏层和输出层,其中隐藏层采用径向基函数作为激活函数,使其在处理非线性问题时具有出色的性能<sup>[29]</sup>。PSO\_RBFNN 在继承 RBFNN 这些优点的同时,引入了智能优化机制,减少了人工调参的工作量,提升了模型的稳定性和鲁棒性,利用 PSO 算法对 RBFNN 的关键参数进行优化,包括中间层神经元数量、学习率及训练迭代次数,构建基于 PSO\_RBFNN 的农地土壤相对湿度反演模型,解决了遥感干旱监测指数与作物生长期土壤相对湿度之间的非线性问题,与 LR 和 BP 等模型相比,PSO\_RBFNN 避免了 BP 算法容易陷入局部最优和对初始权重敏感的问题。此外,RBFNN 作为一种非线性模型,能够更好地捕捉数据中的复杂关系,提高模型的表达能力,利用 PSO 的全局优化能力,提高参数选择的效率和质量,避免了局部最优问题<sup>[26]</sup>。本研究中,基于 PSO\_RBFNN 土壤相对湿度模型反演干旱平均准确率能够达到 90% 以上,比其他模型反演的准确率提高 4.76%~9.32%。因此,利用 PSO\_RBFNN 模型,通过

智能算法的集成和优化,能够充分发挥各算法的优势,基本实现区域旱情监测的高效性和精确性,在农地土壤湿度反演和旱情监测中表现出较好的效果。

本研究对甘肃省胡麻出苗期进行土壤相对湿度反演时,选取该时期 MODIS 遥感干旱监测指数与农地土壤相对湿度作为模型反演的指标集,通过对比 PSO\_RBFNN、RBFNN、LR 和 BP\_NN 这 4 种模型及其与 6 种遥感干旱监测指数的反演效果发现,PSO\_RBFNN 模型在土壤相对湿度反演精度方面显著优于 LR、BP\_NN 和 RBFNN 模型,该模型 10 cm 和 20 cm 土层深度的土壤相对湿度平均预测精度分别达到 89.91% 和 91.71%,在 10 cm 土层较 RBFNN、LR 和 BP\_NN 模型分别提高 8.69 个百分点、4.94 个百分点和 4.76 个百分点,在 20 cm 土层分别提高 6.91 个百分点、6.86 个百分点和 9.32 个百分点。模型回归分析显示,相对于 1:1 斜线,PSO\_RBFNN 模型偏差最小,其与 10 cm 和 20 cm 土层相对湿度相关系数分别达到 0.68 和 0.74。总体来看,PSO\_RBFNN 模型反演土壤相对湿度的效果较好,说明基于 MODIS 遥感干旱监测指数与 PSO\_RBFNN 结合反演土壤相对湿度的模型有效。

#### 参考文献:

- [1] 王伟,陈军,叶春雷,等.甘肃胡麻地方及育成品种农艺性状分析及评价[J].中国种业,2022,(12):75-81.  
WANG W, CHEN J, YEC L, et al. Analysis and evaluation of agronomic characters of local and bred linseed varieties in Gansu Province [J]. China Seed Industry, 2022, (12): 75-81.
- [2] 余新成.甘肃胡麻生产现状及产业化发展建议[J].甘肃农业科技,2001,(7):11-13.  
SHE X C. Production status and industrialization development suggestions of flax in Gansu Province [J]. Gansu Agricultural Science and Technology, 2001, (7): 11-13.
- [3] 欧巧明,叶春雷,李进京,等.胡麻种质资源成株期抗旱性综合评价及其指标筛选[J].干旱区研究,2017,34(5):1083-1092.  
OU Q M, YE C L, LI J J, et al. Comprehensive valuation and screening of drought resistance of flax germplasm [J]. Arid Zone Research, 2017, 34(5): 1083-1092.
- [4] 张瑞兰,武万里,王淑丽.气候变化条件下宁南山区旱地胡麻土壤水分变化特征及对发育期和产量的影响[J].农业与技术,2022,42(21):69-72.  
ZHANG R L, WU W L, WANG S L. Soil moisture variation characteristics and its effects on growth stage and yield of flax in mountainous area of southern Ningxia under climate change [J]. Agriculture & Technology, 2022, 42(21): 69-72.
- [5] 魏浩翰,张强,沈飞.基于熵值法轨迹聚类多特征参数融合的 GNSS-IR 土壤湿度反演方法[J/OL].武汉大学学报(信息科学版):1-21.(2024-02-28)[2024-03-10].<https://doi.org/10.13203/j.whugis.20230419>.  
WEI H H, ZHANG Q, SHEN F. GNSS-IR soil moisture estimation based on track clustering and multi characteristic parameter fusion using entropy method [J]. Geomatics and Information Science of Wuhan University: 1-21. (2024-02-28) [2024-03-10]. <https://doi.org/10.13203/j.whugis.20230419>.
- [6] WAN W, LIU Z, LI K J, et al. Drought monitoring of the maize planting

- areas in Northeast and North China Plain[J]. *Agricultural Water Management*, 2021, 245: 106636.
- [7] 韩东, 王鹏新, 张悦, 等. 农业干旱卫星遥感监测与预测研究进展[J]. *智慧农业(中英文)*, 2021, 3(2): 1-14.  
HAN D, WANG P X, ZHANG Y, et al. Progress of agricultural drought monitoring and forecasting using satellite remote sensing[J]. *Smart Agriculture*, 2021, 3(2): 1-14.
- [8] WANG Q, ZHAO L, WANG M L, et al. A random forest model for drought: monitoring and validation for grassland drought based on multi-source remote sensing data[J]. *Remote Sensing*, 2022, 14(19): 4981.
- [9] LI Y, DONG Y, YIN D Q, et al. Evaluation of drought monitoring effect of winter wheat in Henan Province of China based on multi-source data[J]. *Sustainability*, 2020, 12(7):2801.
- [10] CHEN Y X, YANG J J, XU Y Y, et al. Remote-sensing drought monitoring in Sichuan Province from 2001 to 2020 based on MODIS data[J]. *Atmosphere*, 2022, 13(12): 1970.
- [11] 张有智, 解文欢, 吴黎, 等. 农业干旱灾害研究进展[J]. *中国农业资源与区划*, 2020, 41(9): 182-188.  
ZHANG Y Z, XIE W H, WU L, et al. Research progress on agriculture drought disaster[J]. *Chinese Journal of Agricultural Resources and Regional Planning*, 2020, 41(9): 182-188.
- [12] 李华朋, 张树清, 高自强, 等. MODIS 植被指数监测农业干旱的适宜性评价[J]. *光谱学与光谱分析*, 2013, 33(3): 756-761.  
LI H P, ZHANG S Q, GAO Z Q, et al. Evaluating the utility of MODIS vegetation index for monitoring agricultural drought[J]. *Spectroscopy and Spectral Analysis*, 2013, 33(3): 756-761.
- [13] 陈立伟. 基于 MODIS 数据的干旱遥感监测方法研究[J]. *地矿测绘*, 2023, 39(1): 29-32.  
CHEN L W. Study on remote sensing monitoring method of drought based on MODIS data[J]. *Surveying and Mapping of Geology and Mineral Resources*, 2023, 39(1): 29-32.
- [14] 张红卫, 陈怀亮, 周官辉, 等. 归一化多波段干旱指数在农田干旱监测中的应用[J]. *科技导报*, 2009, 27(11): 23-26.  
ZHANG H W, CHEN H L, ZHOU G H, et al. Application of normalized multi-band drought index method in cropland drought monitoring[J]. *Science & Technology Review*, 2009, 27(11): 23-26.
- [15] 张洁, 武建军, 周磊, 等. 基于 MODIS 数据的农业干旱监测方法对比分析[J]. *遥感信息*, 2012, 27(5): 48-54.  
ZHANG J, WU J J, ZHOU L, et al. Comparative study on remotely sensed methods of monitoring agricultural drought based on MODIS data[J]. *Remote Sensing Information*, 2012, 27(5): 48-54.
- [16] CARLSON T N, GILLIES R R, PERRY E M. A method to make use of thermal infrared temperature and NDVI measurements to infer surface soil water content and fractional vegetation cover[J]. *Remote Sensing Reviews*, 1994, 9(1/2): 161-173.
- [17] 李新尧, 杨联安, 聂红梅, 等. 基于植被状态指数的陕西省农业干旱时空动态[J]. *生态学杂志*, 2018, 37(4): 1172-1180.  
LI X Y, YANG L A, NIE H M, et al. Assessment of temporal and spatial dynamics of agricultural drought in Shaanxi Province based on vegetation condition index[J]. *Chinese Journal of Ecology*, 2018, 37(4): 1172-1180.
- [18] JACKSON R D, IDSO S B, REGINATO R J, et al. Canopy temperature as a crop water stress indicator[J]. *Water Resources Research*, 1981, 17(4): 1133-1138.
- [19] SHEN R P, HUANG A Q, LI B L, et al. Construction of a drought monitoring model using deep learning based on multi-source remote sensing data[J]. *International Journal of Applied Earth Observation and Geoinformation*, 2019, 79: 48-57.
- [20] 沙莎, 胡蝶, 王丽娟, 等. 河南省土壤水分遥感监测方法研究[J]. *气象与环境科学*, 2023, 46(1): 91-99.  
SHA S, HU D, WANG L J, et al. Study on remote sensing monitoring method of soil moisture in Henan Province[J]. *Meteorological and Environmental Sciences*, 2023, 46(1): 91-99.
- [21] 李毅, 陈新国, 赵会超, 等. 土壤干旱遥感监测的最新研究进展[J]. *水利与建筑工程学报*, 2021, 19(1): 1-7.  
LI Y, CHEN X G, ZHAO H C, et al. Latest advances of soil drought and its monitoring based on remote sensing[J]. *Journal of Water Resources and Architectural Engineering*, 2021, 19(1): 1-7.
- [22] 韩兰英, 张强, 赵红岩, 等. 甘肃省农业干旱灾害损失特征及其对气候变暖的响应[J]. *中国沙漠*, 2016, 36(3): 767-776.  
HAN L Y, ZHANG Q, ZHAO H Y, et al. The characteristics of agricultural drought disaster loss and response to climate warming in Gansu, China[J]. *Journal of Desert Research*, 2016, 36(3): 767-776.
- [23] 谭德宝, 刘良明, 鄢俊洁, 等. MODIS 数据的干旱监测模型研究[J]. *长江科学院院报*, 2004, 21(3): 11-15.  
TAN D B, LIU L M, YAN J J, et al. Research on drought monitoring model based on MODIS data[J]. *Journal of Yangtze River Scientific Research Institute*, 2004, 21(3): 11-15.
- [24] 陈少丹, 张利平, 郭梦瑶, 等. TRMM 卫星降水数据在区域干旱监测中的适用性分析[J]. *农业工程学报*, 2018, 34(15): 126-132.  
CHEN S D, ZHANG L P, GUO M Y, et al. Suitability analysis of TRMM satellite precipitation data in regional drought monitoring[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2018, 34(15): 126-132.
- [25] 李菁, 任义方, 戴竹君, 等. 基于 MODIS 干旱指数与 RBFNN 方法的江苏冬小麦需水关键期土壤水分遥感监测应用[J]. *干旱地区农业研究*, 2022, 40(6): 251-257.  
LI J, REN Y F, DAI Z J, et al. Retrieval of soil moisture at critical period of water demand of winter wheat in Jiangsu Province using MODIS drought index and RBFNN[J]. *Agricultural Research in the Arid Areas*, 2022, 40(6): 251-257.
- [26] 黄友昕, 胡茂胜, 沈永林, 等. MODIS 干旱指数结合 RBFNN 反演冬小麦返青期土壤湿度[J]. *农业工程学报*, 2019, 35(12): 81-88.  
HUANG Y X, HU M S, SHEN Y L, et al. Retrieval of soil moisture at returning green stage of winter wheat using MODIS drought index and RBFNN[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2019, 35(12): 81-88.
- [27] 李爱国, 覃征, 鲍复民, 等. 粒子群优化算法[J]. *计算机工程与应用*, 2002, 38(21): 1-3, 17.  
LI A G, QIN Z, BAO F M, et al. Particle swarm optimization algorithms[J]. *Computer Engineering and Applications*, 2002, 38(21): 1-3, 17.
- [28] 张鑫, 邹德旋, 肖鹏, 等. 自适应简化粒子群优化算法及其应用[J]. *计算机工程与应用*, 2019, 55(8): 250-263.  
ZHANG X, ZOU D X, XIAO P, et al. Self-adjusted simplified particle swarm optimization algorithm and its application[J]. *Computer Engineering and Applications*, 2019, 55(8): 250-263.
- [29] 王岩, 王敬宜, 冯锐, 等. 基于 FY-3D/MERSI 数据的东北地区干旱监测方法研究[J]. *干旱地区农业研究*, 2023, 41(4): 289-297, 317.  
WANG Y, WANG J Y, FENG R, et al. Drought monitoring method in Northeast China based on FY-3D/MERSI data[J]. *Agricultural Research in the Arid Areas*, 2023, 41(4): 289-297, 317.
- [30] 王思楠. 融合多源遥感和机器学习算法的土壤水分反演和干旱监测及植被响应研究[D]. 呼和浩特: 内蒙古农业大学, 2022.  
WANG S N. Soil moisture retrieval and drought monitoring and vegetation response based on multi-source remote sensing and machine learning algorithm[D]. Hohhot: Inner Mongolia Agricultural University, 2022.