

张传波, 李卫国, 王 晶, 等. 波段反射率和植被指数结合的作物生长季农田土壤水分估测[J]. 江苏农业学报, 2022, 38(1): 111-118.

doi: 10.3969/j.issn.1000-4440.2022.01.013

波段反射率和植被指数结合的作物生长季农田土壤水分估测

张传波^{1,2}, 李卫国^{1,2}, 王 晶², 李 伟³, 马廷淮⁴

(1. 江苏大学农业工程学院, 江苏 镇江 212013; 2. 江苏省农业科学院农业信息研究所, 江苏 南京 210014; 3. 江苏大学流体机械工程技术研究中心, 江苏 镇江 212013; 4. 南京信息工程大学, 江苏 南京 210044)

摘要: 为了建立快速、有效的农田土壤水分含量(*SMCF*)遥感估测方法,在江苏省连云港市东海县、泰州市兴化市和盐城市大丰区布设 *SMCF* 遥感估测试验。在获取作物冠层近红外波段反射率(Near-infrared bandreflectance, R_{nir})、红光波段反射率(Red bandreflectance, R_{red})以及 *SMCF* 的基础上,通过分析波段反射率和植被指数多个遥感光谱特征指标与 *SMCF* 之间的相关性,构建基于 BP 神经网络的 *SMCF* 遥感估测模型,并与多元线性回归模型估测精度进行比较。结果表明, R_{nir} 、 R_{red} 、差值植被指数(*DVI*)和比值植被指数(*RVI*)与 *SMCF* 间呈正相关关系,归一化差值植被指数(*NDVI*)和 *SMCF* 间呈负相关关系,各指标与 *SMCF* 的相关性从高到低依次为 $R_{nir} > DVI > R_{red} > NDVI > RVI$, 其中 R_{nir} 与 *SMCF* 相关性最高,相关系数为 0.765。利用 BP 神经网络建立的 *SMCF* 估测模型的决定系数(R^2)为 0.928, 均方根误差(*RMSE*)为 3.61%, 平均相对误差(*ARE*)为 9.07%。利用多元线性回归方法建立的 *SMCF* 估测模型的 R^2 为 0.660, *RMSE* 为 7.65%, *ARE* 为 21.43%。二者相比可以看出, BP 神经网络 *SMCF* 估测模型的估测效果明显优于多元线性回归模型,说明将神经网络算法与波段反射率和植被指数结合建模,可以有效提高 *SMCF* 的估测精度。

关键词: 农田土壤水分含量; 作物生长; 多光谱波段反射率; 植被指数; 神经网络

中图分类号: S127 **文献标识码:** A **文章编号:** 1000-4440(2022)01-0111-08

Estimation of farmland soil moisture in crop growing season based on combination of band reflectance and vegetation index

ZHANG Chuan-bo^{1,2}, LI Wei-guo^{1,2}, WANG Jing², LI Wei³, MA Ting-huai⁴

(1. College of Agricultural Engineering, Jiangsu University, Zhenjiang 212013, China; 2. Institute of Agricultural Information, Jiangsu Academy of Agricultural Sciences, Nanjing 210014, China; 3. Fluid Machinery Engineering Technology Research Center, Jiangsu University, Zhenjiang 212013, China; 4. Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: To set up a fast and effective remote sensing estimation method for soil moisture content in farmland (*SMCF*), remote sensing estimation experiments of *SMCF* were designed in Donghai County of Lianyungang City, Xinghua City of Taizhou City and Dafeng District of Yancheng City, Jiangsu province. After acquisition of canopy near-infrared band reflectance (R_{nir}) and red band reflectance (R_{red}) of crops and *SMCF*, correlation between multiple indicators of remote

sensing spectral features such as band reflectance, vegetation index and *SMCF* were analyzed, and a remote sensing estimation model of *SMCF* based on back propagation (BP) neural network was constructed. Besides, the estimation accuracy was compared with multiple linear regression model. The results showed that, R_{nir} , R_{red} , difference vegetation index (*DVI*) and ratio vegetation in-

收稿日期: 2021-05-13

基金项目: 国家重点研发计划项目(2021YFE0104400); 江苏省农业科技自主创新资金项目[CX(20)2037]

作者简介: 张传波(1993-), 男, 安徽蚌埠人, 硕士研究生, 研究方向为农业遥感应用研究。(E-mail) 1003176295@qq.com

通讯作者: 李卫国, (E-mail) jaaslw@126.com

dex (RVI) were in positive relationships with $SMCF$. The correlation coefficients between different indexes and $SMCF$ were sequenced as follows: $R_{nir} > DVI > R_{red} > NDVI > RVI$. Among them, R_{nir} had the highest correlation with $SMCF$, with a correlation coefficient of 0.765. The determination coefficient (R^2) of $SMCF$ estimation model established by BP neural network was 0.928, the root mean square error ($RMSE$) was 3.61%, and the average relative error (ARE) was 9.07%. R^2 , $RMSE$ and ARE of the $SMCF$ estimation model established by multiple linear regression method were 0.660, 7.65% and 21.43%, respectively. By comparing the two models, it can be seen that the estimation effect of BP neural network model on $SMCF$ is obviously better than multiple linear regression model, which shows that the estimation accuracy of $SMCF$ can be effectively improved by combining the neural network algorithm with band reflectivity and vegetation index.

Key words: soil moisture content in farmland; crop growth; multi-spectral band reflectance; vegetation index; neural network

作物的生长发育与农田土壤水分含量($SMCF$)息息相关,有效估测 $SMCF$,及时调整灌溉措施,有利于促进作物生长发育与产量形成^[1-6]。 $SMCF$ 受到较多因素影响,如气候、环境、土壤类型及种植作物种类等,且 $SMCF$ 与个别影响因素之间存在复杂的非线性关系。 $SMCF$ 估测一直是国内外农业遥感研究的重要选题,早在 20 世纪 60 年代,国外学者就展开了有关环境因子和 $SMCF$ 间相关性的研究,并运用统计方法建立了 $SMCF$ 动态预测模型^[7-8]。20 世纪 80 年代以来,国内学者也展开了 $SMCF$ 的估测研究,并取得一定成果^[9-10]。传统的 $SMCF$ 估测方法主要分为 2 类:一是经验法,将气象因素、作物要素和 $SMCF$ 进行相关性分析,利用统计方法对 $SMCF$ 进行估测^[11-13]。二是机理法,以土壤水分平衡方程和土壤水动力学原理为基础对 $SMCF$ 进行分析^[11,14-15]。传统的 $SMCF$ 估测模型需要大量的统计数据建模,经验性较强,不适用大范围 $SMCF$ 的估测。随着农业遥感技术的发展,一些学者利用遥感技术展开 $SMCF$ 估测研究,并取得较多研究成果^[16-18]。区别于传统 $SMCF$ 估测方法,利用农业遥感技术估测 $SMCF$ 具有快速、便捷、高效和检测范围大的特点,可以节省人力物力,及时获取大面积 $SMCF$ 情况。

近年来,随着人工智能技术的发展,神经网络方法被较多应用于农业生产领域,因其优秀的学习能力、容错性及自适应性,在作物生长监测、病虫害估测方面已有较多研究,除此之外,有些学者利用神经网络进行 $SMCF$ 的估测研究。如刘洪斌等^[19]利用时间序列预测方法建立神经网络的 $SMCF$ 估测模型,取得较好预测效果。尚松浩等^[20]以预测时段末对应的时间、预测时段长、阶段降水灌水总量、阶段平均气温、预测时段初贮水量作为输入变量,建立了

土壤贮水量预测的神经网络模型。Elshorbagy 等^[21]以降水、气温、净辐射和地温作为输入变量, $SMCF$ 作为输出变量,建立神经网络模型,研究了不同深度 $SMCF$ 。Adeyemi 等^[22]利用农田土壤湿度、降水量、气候估测值和农田土壤体积含水量建立神经网络模型,提前一天预测了农田土壤体积含水量。神经网络具有较好的非线性拟合能力,能够将不同的影响因素和 $SMCF$ 进行拟合,在探索两者之间复杂的线性关系前提下进行 $SMCF$ 估测,将波段反射率和植被指数多个遥感光谱特征指标与神经网络结合估测 $SMCF$ 的研究鲜有报道。

本研究在江苏省连云港市东海县、泰州市兴化市和盐城市大丰区布设 $SMCF$ 遥感估测试验,在获取作物冠层近红外光谱反射率(R_{nir})、红光光谱反射率(R_{red})以及 $SMCF$ 的基础上,通过分析波段反射率和植被指数多个遥感光谱特征指标与 $SMCF$ 之间的相关关系,综合相关性较好的遥感光谱特征指标建立基于 BP 神经网络的 $SMCF$ 估测模型,并与回归统计模型进行比较,以形成快速、高效的县域 $SMCF$ 遥感估测方法,旨在为作物灌溉措施调整提供技术参考。

1 材料与方法

1.1 试验区选择和数据获取

2020 年 10 月 10 日-13 日,在江苏省连云港市东海县、泰州市兴化市和盐城市大丰区布设 $SMCF$ 估测试验,用 Juno ST(美国)手持全球定位系统(GPS)仪定位选择 60 个试验样点,东海县、兴化市和大丰区各 20 个试验样点,每个试验样点间隔 1~2 km(图 1),试验样点田块面积至少 200 m×200 m,选择的田块距离道路、房屋和水体 100 m 以上,田间作物长势均匀。在每个试验样点田块中间位置采用梅

花对角线法(或5点采样法)用 GreenSeeker(美国)光谱仪分别测量作物(水稻)冠层 R_{nir} 和 R_{red} , 测量作物冠层光谱信息前用白板标定光谱仪, 测量时光谱仪距作物冠层 1 m, 测量时间为 10:00–14:00, 测量 5 次后取平均值作为单个试验样点的光谱信息数据。与光谱测量方法类似, 在测量冠层光谱对应位置, 用 DELTA-T(英国)土壤水分仪测量 5 次 $SMCF$, 并计算 5 次平均值作为每个试验样点的 $SMCF$ 数据(试验测量的 $SMCF$ 为农田土壤水分的体积含量, 计算单位为%)。

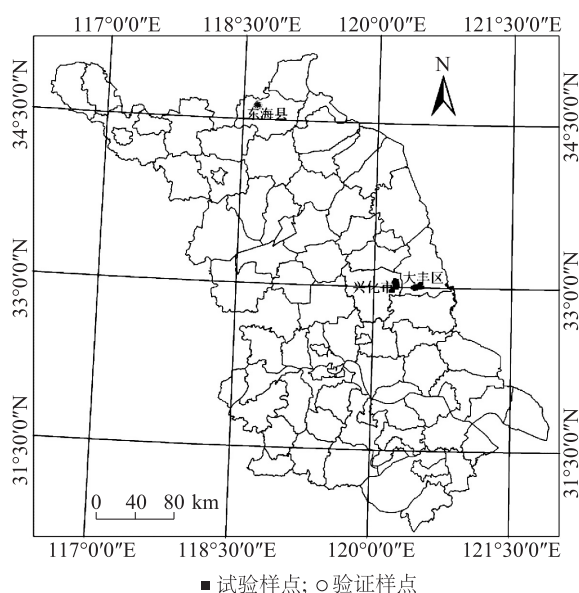


图1 江苏省行政边界和试验样点分布概况

Fig.1 Administrative boundary of Jiangsu province and general situation distribution of test sites

1.2 植被指数计算

利用 GreenSeeker 光谱仪测得的 R_{nir} 和 R_{red} 计算 $NDVI$ (归一化差值植被指数)、 DVI (差值植被指数)和 RVI (比值植被指数)^[23-26], 计算公式如下:

$$NDVI = (R_{nir} - R_{red}) / (R_{nir} + R_{red}) \quad (1)$$

$$DVI = R_{nir} - R_{red} \quad (2)$$

$$RVI = R_{nir} / R_{red} \quad (3)$$

1.3 BP 神经网络

BP 神经网络由输入层、隐含层和输出层(图2)组成, 隐含层可以是单层或多层。前一层神经元将信号传递给后一层神经元且与后一层的所有神经元相连接, 同层神经元之间无连接且不进行信号传递。进行网络训练时, 先将输入数据进行归一化处理, 处

理后的数据经输入层运算后传递至隐含层, 隐含层再次运算后将数据传递至输出层, 若输出层的数值未到达期望输出数值, 计算输出层的误差变化值后, 将误差进行反向传播, 同时调整每一层的权值和阈值, 直到输出数值满足期望输出数值后, 再通过反归一化处理, 将模型估测值输出。本研究通过构建 3 层 BP 神经网络对 $SMCF$ 进行估测。

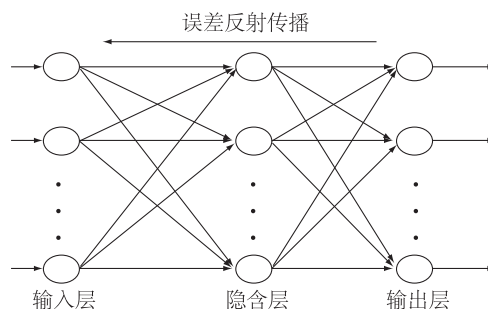


图2 BP 神经网络结构

Fig.2 Structure of back propagation (BP) neural network

选择合适的隐含层节点数可以有效提高估测精度。隐含层节点数采用如下经验公式^[27]计算:

$$z = \sqrt{a+b} + c \quad (4)$$

式(4)中 z 为隐含层节点数, a 为输入层节点数, b 为输出层节点数, c 为 0~10 之间的常数, 每次增加 1 个步长确定隐含层节点数取值。

为避免输入变量数据出现奇异数据, 增加训练时间, 导致网络无法收敛, 在进行神经网络训练时利用归一化函数 mapminmax 对输入数据和输出数据进行归一化处理, 将数据压缩到 (0, 1) 范围内, 计算公式如下^[28]:

$$y = (x - \min) / (\max - \min) \quad (5)$$

式(5)中 x 为输入变量数据(多个遥感光谱特征指标), \max 、 \min 分别为多个遥感光谱特征指标数据中的最大值、最小值。

1.4 农田土壤水分含量估测模型建立与验证

泰州市兴化市和盐城市大丰区 40 个试验样点数据用于模型建立, 连云港市东海县 20 个试验区样点数据用于模型验证。

在 Excel 软件中对兴化市和大丰区 40 个试验样点的光谱数据(包括 R_{nir} 、 R_{red} 、 $NDVI$ 、 DVI 和 RVI)与相应的 $SMCF$ 进行相关性分析, 依据分析结果选择与 $SMCF$ 相关性较好的遥感光谱特征指标作为建立 $SMCF$ 估测模型的输入样本。在 MATLAB 软件中分

别建立 BP 神经网络的 *SMCF* 估测模型和多元线性回归的 *SMCF* 估测模型。将东海县 20 个试验区样点数据输入 BP 神经网络的 *SMCF* 估测模型和多元线性回归的 *SMCF* 估测模型中计算得到东海县 *SMCF* 估测值。将东海县 *SMCF* 估测值与对应试验样点的 *SMCF* 实测值进行线性拟合,用 R^2 、*RMSE* 和 *ARE* 对 BP 神经网络的 *SMCF* 估测模型和多元线性回归 *SMCF* 估测模型的估测精度进行验证, R^2 值越大、*RMSE* 和 *ARE* 值越小,说明 *SMCF* 估测模型的估测精度越高^[29]。 R^2 、*RMSE* 和 *ARE* 的计算公式如下:

$$R^2 = \frac{\sum_{i=1}^n (P_i - \bar{Q})^2}{\sum_{i=1}^n (Q_i - \bar{Q})^2} \quad (6)$$

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

$$ARE = \frac{1}{n} \sum_{i=1}^n \frac{|P_i - Q_i|}{P_i} \times 100\% \quad (8)$$

式(6)、(7)和(8)中 P_i 为东海县 20 个验证试验区样点 *SMCF* 估测模型的估测值, Q_i 为 20 个验证试验区样点 *SMCF* 实测值, \bar{Q} 为 20 个验证试验区样点 *SMCF* 实测值的平均值, n 为验证试验区样点数。

2 结果与分析

2.1 遥感光谱特征指标与农田土壤水分含量间的关系

对兴化市和大丰区 40 个试验样点遥感光谱特征指标 (R_{nir} 、 R_{red} 、*NDVI*、*DVI* 和 *RVI*) 与 *SMCF* 进行相关性分析,结果如表 1 所示。

表 1 遥感光谱特征指标和农田土壤水分含量 (*SMCF*) 间的相关系数

Table 1 Correlation coefficients between remote sensing spectral feature indexes and soil moisture content in farmland (*SMCF*)

指标	R_{nir}	R_{red}	<i>NDVI</i>	<i>DVI</i>	<i>RVI</i>	<i>SMCF</i>
R_{nir}	1.000					
R_{red}	0.453	1.000				
<i>NDVI</i>	0.093	-0.448	1.000			
<i>DVI</i>	0.980 **	0.311	0.152	1.000		
<i>RVI</i>	0.197	-0.414	0.985 **	0.260	1.000	
<i>SMCF</i>	0.765 **	0.589 *	-0.465 **	0.732 **	-0.357	1.000

* 表示在 0.05 水平上显著相关, ** 表示在 0.01 水平上显著相关。 R_{nir} : 近红外光谱反射率; R_{red} : 红光光谱反射率; *NDVI*: 归一化差值植被指数; *DVI*: 差值植被指数; *RVI*: 比值植被指数; *SMCF*: 农田土壤水分含量。

从表 1 可知,不同遥感光谱特征指标间存在不

同程度的相关性。 R_{nir} 与 R_{red} 、*NDVI*、*DVI* 和 *RVI* 呈正相关关系,且与 *DVI* 的相关关系达极显著水平。 R_{red} 与 *NDVI* 和 *RVI* 为负相关关系,与 *DVI* 为正相关关系。*NDVI* 与 *RVI* 之间存在明显的正相关性,相关系数为 0.985。依据不同遥感光谱特征指标之间的明显相关性,进行相互间转换或估算。不同遥感光谱特征指标与 *SMCF* 间的相关性各有不相同,其相关性由强到弱依次为 $R_{nir} > DVI > R_{red} > NDVI > RVI$ 。 R_{nir} 与 *DVI*、*SMCF* 之间为正相关关系,达极显著水平。 R_{red} 与 *SMCF* 之间为显著正相关关系。*NDVI*、*RVI* 与 *SMCF* 之间呈现负相关关系。综合以上分析结果,选择 R_{nir} 、 R_{red} 、*NDVI* 和 *DVI* 作为建立 BP 神经网络的 *SMCF* 估测模型的输入变量和多元线性回归的 *SMCF* 估测模型的自变量。

2.2 农田土壤水分含量估测模型的建立

兴化市和大丰区 40 个试验样点遥感光谱特征指标 (R_{nir} 、 R_{red} 、*NDVI* 和 *DVI*) 和 *SMCF* 实测值分布区间差异较大,其中 R_{nir} 、 R_{red} 、*NDVI*、*DVI* 和 *SMCF* 最小值分别为 0.189、0.026、0.662、0.163 和 11.8,最大值分别为 0.899、0.091、0.816、0.594 和 54.9。5 个模型变量 (R_{nir} 、 R_{red} 、*NDVI*、*DVI* 和 *SMCF*) 实测值区间变化较大,在进行 BP 神经网络数据训练前,首先根据公式(5)对 R_{nir} 、 R_{red} 、*NDVI*、*DVI* 和 *SMCF* 数值进行归一化处理使模型变量数值分布在 0~1 范围内。

分别选择 trainlm、tansig 和 purelin 作为 BP 神经网络 *SMCF* 估测模型的训练函数、隐含层传递函数和输出层函数。神经网络模型建立过程中可能发生过拟合,如果神经网络模型训练样本数据的拟合效果较好,但验证样本数据的拟合效果较差则认为神经网络模型产生了过拟合^[30]。为了避免神经网络模型过拟合造成估测效果较差,本研究结合文献[31]中的提前停止法训练神经网络模型,防止神经网络模型建立过程中出现过拟合。由公式(4)可知,隐含层以 3 作为第 1 个节点数,每次增加 1 个步长设置不同的节点数。选择不同隐含层节点数,利用 40 个试验区样点数据建立的 BP 神经网络 *SMCF* 估测模型对 20 个验证样点 *SMCF* 估测的 R^2 和 *RMSE* 如表 2 所示。根据隐含层不同节点数的 BP 神经网络 *SMCF* 估测模型的 R^2 和 *RMSE* 选择合适的节点数,当 R^2 最大且 *RMSE* 最小时,对应的为合适节点数。

由表 2 可知,当隐含层节点数为 6 时,BP 神经网络 $SMCF$ 估测模型 R^2 最大,为 0.928, $RMSE$ 最小,为 3.61%。当隐含层节点数为 13 时,BP 神经网络 $SMCF$ 估测模型 R^2 最小,为 0.001, $RMSE$ 最大,为 19.08%。由此可见,隐含层节点数的改变对 BP 神经网络 $SMCF$ 估测模型精度和拟合效果都有较大影响,选择合适的隐含层节点数可以有效地提高 $SMCF$ 估测模型的精度。根据 $SMCF$ 估测精度结果建立的 BP 神经网络 $SMCF$ 估测模型结构为(4,6,1)(4 表示 BP 神经网络 $SMCF$ 估测模型输入变量 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI ,6 表示 BP 神经网络 $SMCF$ 估测模型隐含层节点数,1 表示 BP 神经网络 $SMCF$ 估测模型输出变量 $SMCF$),选取的隐含层节点数为 6 时的 BP 神经网络 $SMCF$ 估测模型和估测 $SMCF$ 拟合公式隐含层权重、偏差分别见表 3 和表 4。

表 3 BP 神经网络的 $SMCF$ 估测模型Table 3 Soil moisture content in farmland ($SMCF$) estimation model of BP neural network

输入变量	输出变量	BP 神经网络模型
R_{nir}	$SMCF_{BP}$	$X_i = W_{1i} \cdot R_{nir} + W_{2i} \cdot R_{red} + W_{3i} \cdot NDVI + W_{4i} \cdot DVI$
R_{red}	$SMCF_{BP}$	$Y_i = 2 / (1 + e^{-2x_i}) - 1, i = 1, 2, 3, 4, 5, 6$
$NDVI$	$SMCF_{BP}$	$SMCF_{BP} = -0.155 \ 6Y_1 - 0.250 \ 6Y_2 - 1.157 \ 7Y_3 + 0.243 \ 3Y_4 - 0.486 \ 5Y_5 - 1.085 \ 5Y_6 - 0.397 \ 7$
DVI	$SMCF_{BP}$	

R_{nir} 、 R_{red} 、 $NDVI$ 、 DVI 、 $SMCF$ 见表 1 注。 X_i 为隐含层第 i 个神经元的输入, Y_i 为隐含层第 i 个神经元的输出, W_{ni} 为输入层第 n 个神经元与隐含层第 i 个神经元的连接权重, $n=1,2,3,4$ 。

表 4 BP 神经网络模型农田土壤水分含量 ($SMCF$) 拟合公式的权重和偏差Table 4 Weight and deviation of soil moisture content in farmland ($SMCF$) fitting formula of BP neural network model

输出变量	隐含层节点数 (i)	权重				偏差 (b_i)
		W_{1i}	W_{2i}	W_{3i}	W_{4i}	
$SMCF_{BP}$	1	0.461 7	-1.759 1	-0.647 3	0.994 0	-2.289 7
	2	-0.585 0	-1.135 6	-1.528 6	0.876 9	1.376 3
	3	-1.173 1	-0.072 6	1.318 4	-1.131 5	-0.466 0
	4	-0.749 9	-1.574 4	-0.655 4	-1.598 8	-0.232 0
	5	-1.585 7	0.254 9	-1.295 3	0.228 0	-1.159 5
	6	-1.366 0	-0.232 9	0.333 0	-0.722 4	-2.403 0

W_{1i} 、 W_{2i} 、 W_{3i} 、 W_{4i} 见表 3 注。

利用 BP 神经网络 $SMCF$ 估测模型估测 $SMCF$ 后得到的 $SMCF$ 估测值为标准归一化结果,其值分布在 0~1 之间,其中最小值为 0.090 6,最大值为 0.959 0。通过对估测得到的 $SMCF$ 值进行去归一化处理得到真实的 $SMCF$ 估测结果。

表 2 不同隐含层节点数的 BP 神经网络模型对农田土壤水分含量 ($SMCF$) 的估测精度Table 2 Estimation accuracy of BP neural network model for soil moisture content in farmland ($SMCF$) when the number of hidden layer nodes is different

隐含层节点数	R^2	$RMSE$ (%)
3	0.151	11.18
4	0.004	18.33
5	0.096	13.64
6	0.928	3.61
7	0.685	6.86
8	0.819	6.47
9	0.844	4.79
10	0.786	7.53
11	0.138	17.98
12	0.808	5.69
13	0.001	19.08

R^2 : 决定系数; $RMSE$: 均方根误差。

利用与 BP 神经网络 $SMCF$ 估测模型相同的 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI 的 40 个试验区样点数据作为多元线性回归 $SMCF$ 估测模型的自变量,对应试验区样点 $SMCF$ 实测值作为模型因变量,建立多元线性回归 $SMCF$ 估测模型($SMCF_{hg}$),具体公式如下:

$$SMCF_{hg} = 180.8419 R_{nir} - 147.3835 NDVI - 101.0973 DVI + 103.3571 \quad (9)$$

2.3 农田土壤水分含量估测模型精度评价

将东海县 20 个试验区样点的 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI 数据分别代入 BP 神经网络 $SMCF$ 估测模型和多元线性回归 $SMCF$ 估测模型中计算 $SMCF$ ，将 2 种模型的 $SMCF$ 估测值分别和对应试验区样点的 $SMCF$ 实测值进行统计回归分析，结果如图 3 所示。

由图 3 可知，20 个试验区验证样点 $SMCF$ 实测值为 17.3%~52.3%，多数样点 $SMCF$ 集中在 27.7%~51.0%。图 3a 中 BP 神经网络 $SMCF$ 估测模型样点 $SMCF$ 估测值为 19.8%~52.84%，多数集中在 28.98%~50.38%。图 3b 中多元线性回归 $SMCF$ 估测模型样点 $SMCF$ 估测值为 14.61%~45.87%，多数集中在 29.2%~44.76%。从 $SMCF$ 估

测结果可以看出，BP 神经网络 $SMCF$ 估测模型的估测结果更接近 $SMCF$ 的实测值。BP 神经网络 $SMCF$ 估测模型的 $SMCF$ 估测值和实测值之间的 R^2 为 0.928，图 3a 中多数样点均匀集中在 1:1 关系线附近， $RMSE$ 为 3.61%， ARE 为 9.07%。多元线性回归 $SMCF$ 估测模型的 $SMCF$ 估测值和实测值之间的 R^2 为 0.660，图 3b 中样点较为分散地分布在 1:1 关系线两侧， $RMSE$ 为 7.65%， ARE 为 21.43%。对比可知，BP 神经网络 $SMCF$ 估测模型的精度高于多元线性回归 $SMCF$ 估测模型。用 BP 神经网络法构建模型时通过梯度下降搜索方式不断更新权值和阈值，逐渐减小输出值误差直到满足期望输出后进行输出，而用多元线性回归法建立模型时采用简单的线性拟合方法获得输出值，故 BP 神经网络有效地提高了 $SMCF$ 的估测精度。

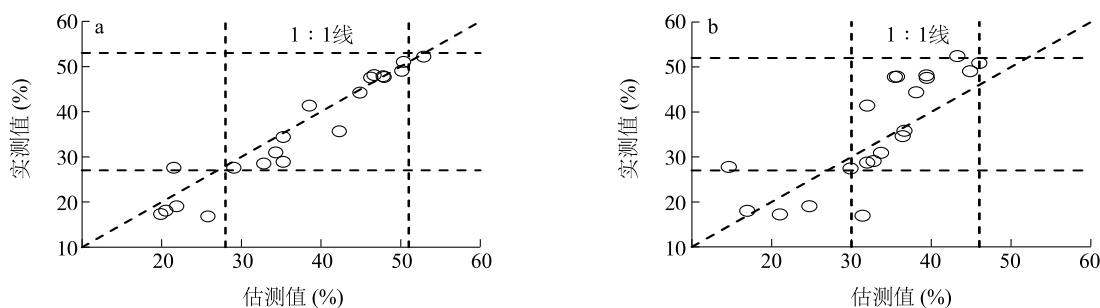


图 3 BP 神经网络 (a) 和多元线性回归 (b) $SMCF$ 估测值和实测值比较

Fig.3 Comparison of soil moisture content in farmland ($SMCF$) estimated value and measured value by BP neural network (a) and multiple linear regression (b)

3 讨论

前人建立的农田土壤水分含量 ($SMCF$) 估测模型有热惯量模型^[32-33]、特征空间模型^[34-35]和微波遥感模型等^[36-37]，这些模型主要用在植被覆盖率低的区域。依据 R_{nir} 、 R_{red} 和微波波段与 $SMCF$ 的相关性进行建模，虽然具有小范围适用与便捷的优势，但由于建模时难以消除植被覆盖度对 $SMCF$ 估测的影响，因此所建立的 $SMCF$ 估测模型精度与普适性较难保证。利用作物多个遥感光谱特征指标和神经网络方法对 $SMCF$ 进行估测的研究报道不多见，本研究通过对多个遥感光谱特征指标 (R_{nir} 、 R_{red} 、 $NDVI$ 、

DVI 和 RVI) 与 $SMCF$ 间的关系进行分析，在明晰多个遥感光谱特征指标之间存在不同程度相关性的基础上，选择相关性较好的 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI 建立了 BP 神经网络 $SMCF$ 估测模型 ($SMCF_{BP}$)，模型的估测精度达到 90.93%。用 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI 遥感光谱特征指标建立的多元线性回归 $SMCF$ 估测模型的估测精度为 78.57%，比 $SMCF_{BP}$ 模型估测精度低 12.36 个百分点，因此选择用 R_{nir} 、 R_{red} 、 $NDVI$ 和 DVI 建立的 $SMCF_{BP}$ 模型可以实现对 $SMCF$ 的有效估测。在作物生长的不同阶段，生理生态特征变化明显，作物冠层遥感光谱信息变化差异较大，给多个生长时期农田土壤水分估测通用模型建立带来较大

不确定性,本研究初步选择作物单个关键生长期(即作物灌浆期)的农田土壤水分含量进行遥感估测研究。

卫星遥感影像可以快速、大范围地获取作物的光谱信息,在作物生长监测、种植面积提取和病虫害估测方面已有广泛应用^[38]。实现从试验样点到大田大面积的 $SMCF$ 遥感估测,可以通过获取卫星遥感影像,提取相关遥感光谱特征指标数据,与 $SMCF_{BP}$ 模型结合进行大面积 $SMCF$ 遥感估测。前人研究结果表明, $SMCF$ 和气象因素(如降雨量、日照、气温)具有较高相关性,今后将考虑结合气象因素对 $SMCF_{BP}$ 模型进行修订与完善,以提高 $SMCF_{BP}$ 模型的精确性和适用性。

参考文献:

- [1] 刘 凯,张 耗,张慎风,等. 结实期土壤水分和灌溉方式对水稻产量与品质的影响及其生理原因[J]. 作物学报,2008,34(2):268-276.
- [2] 陈 超,李 荣,李 芬,等.不同沟垄覆盖下土壤水热效应对旱作马铃薯生长及产量的影响[J].排灌机械工程学报,2020,38(11):1160-1166.
- [3] 王 斌,何文寿,耿世杰.粉垄耕作对土壤水分利用效率和马铃薯产量的影响[J].江苏农业科学,2020,48(21):93-96.
- [4] 高 佳,张宏斌,张恒嘉,等.绿洲灌区膜下滴灌调亏对辣椒品质及产量的影响[J].排灌机械工程学报,2021,39(4):404-409.
- [5] 王唯道,刘小军,田永超,等.不同土壤水分处理对水稻光合特性及产量的影响[J].生态学报,2012,32(22):7053-7060.
- [6] 赵嘉涛,马玉诏,范艳丽,等.生物可降解地膜对棉花产量及水分利用效率的影响[J].排灌机械工程学报,2021,39(1):96-101.
- [7] MANABE S, SMAGORINSKY J, STRICKLER R F. Simulated climatology of a general circulation model with a hydrologic CYCLE1 [J]. Monthly Weather Review, 1965, 93(12):155-169.
- [8] BAIER W, ROBERTSON G W. A new versatile soil moisture budget[J]. Canadian Journal of Plant Science, 1966, 46(3):299-315.
- [9] 徐 梅,隋吉东,刘振忠.土壤水分含量的理论分析及预测模型[J].生物数学学报,1999,14(1):95-99.
- [10] 邵晓梅,严昌荣,徐振剑.土壤水分监测与模拟研究进展[J].地理科学进展,2004(3):58-66.
- [11] 尹健康,陈昌华,邢小军,等.基于BP神经网络的烟田土壤水分预测[J].电子科技大学学报,2010,39(6):891-895.
- [12] 刘建栋,王馥棠,于 强,等.华北地区冬小麦叶片光合作用模型在农业干旱预测中的应用研究[J].应用气象学报,2003,14(4):469-478.
- [13] ARMAND R, WAMBEKE V. The Newhall simulation model for estimating soil moisture & temperature regimes [D]. New York: Cornell University, Ithaca, 2000.
- [14] 尚松浩,雷志栋,杨诗秀.冬小麦田间墒情预报的经验模型[J].农业工程学报,2000,16(5):31-33.
- [15] GONG Y S, CAO Q H, SUN Z J. The effects of soil bulk density, clay content and temperature on soil water content measurement using time-domain reflectometry [J]. Hydrological Processes, 2003, 17(18):3601-3614.
- [16] 熊世为,李卫国,贾天山,等.基于HJ卫星数据的土壤含水量反演及其旱情预测[J].江苏农业学报,2014,30(5):1044-1050.
- [17] WHALLEY W R, LEEDS-HARRISON P B, BOWMAN G E. Estimation of soil moisture status using near infrared reflectance [J]. Hydrological Processes, 1991, 5(3):321-327.
- [18] HOSSEINI M, SARADJIAN M R. Multi-index-based soil moisture estimation using MODIS images [J]. International Journal of Remote Sensing, 2011, 32(21):6799-6809.
- [19] 刘洪斌,武 伟,魏朝富.基于神经网络的土壤水分预测建模研究[J].水土保持学报,2003,17(5):59-62.
- [20] 尚松浩,毛晓敏,雷志栋,等.冬小麦田间墒情预报的BP神经网络模型[J].水利学报,2002,33(4):60-63.
- [21] ELSHORBAGY A, PARASURAMAN K. On the relevance of using artificial neural networks for estimating soil moisture content [J]. Journal of Hydrology, 2008, 362(1/2):1-18.
- [22] ADEYEMI O, GROVE I, PEETS S, et al. Dynamic neural network modelling of soil moisture content for predictive irrigation scheduling [J]. Sensors, 2018, 18(10):1-22.
- [23] LI W G, LIU Y, CHEN H, et al. Estimation model of winter wheat disease based on meteorological factors and spectral information [J]. Food Production Processing and Nutrition, 2020, 2(1):77-82.
- [24] 李卫国,王纪华,赵春江,等.冬小麦抽穗期长势遥感监测的初步研究[J].江苏农业学报,2007,23(5):499-500.
- [25] JORDAN C F. Derivation of leaf - area index from quality of light on the forest floor [J]. Ecology, 1969, 50(4):663-666.
- [26] 林子晶,李卫国,申双和,等. HJ 星和 GF1 号数据在水稻种植面积提取中的应用 [J]. 江苏农业学报, 2016, 32(1):111-117.
- [27] 王嵘冰,徐红艳,李 波,等. BP 神经网络隐含层节点数确定方法研究 [J]. 计算机技术与发展, 2018, 28(4):31-35.
- [28] 汪四水,张孝羲.基于神经网络的稻纵卷叶螟长期预测 [J]. 植物保护学报, 2000, 27(4):313-316.
- [29] 李卫国,黄文江,董莹莹,等.基于温湿度与遥感植被指数的冬小麦赤霉病估测 [J]. 农业工程学报, 2017, 33(23):203-210.

- [30] 刘平. 人工神经网络用于化学数据解析的研究(I):逼近规律与过拟合[J]. 高等学校化学学报, 1996, 20(6):861-865.
- [31] 李俭川, 秦国军, 温熙森, 等. 神经网络学习算法的过拟合问题及解决方法[J]. 振动, 测试与诊断, 2002(4):16-20, 76.
- [32] ZHANG R H, SUN X M, ZHU Z L, et al. A remote sensing model for monitoring soil evaporation based on differential thermal inertia and its validation[J]. Science in China. Series D, Earth sciences, 2003, 46(4):342-355.
- [33] 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.
- [34] GOWARD S N, XUE Y, CZAJKOWSKI K P. Evaluating land surface moisture conditions from the remotely sensed temperature/vegetation index measurements; an exploration with the simplified simple biosphere model[J]. Remote Sensing of Environment, 2002, 79(2/3):225-242.
- [35] MALLICK K, BHATTACHARYA B K, PATEL N K. Estimating volumetric surface moisture content for cropped soils using a soil wetness index based on surface temperature and NDVI[J]. Agricultural & Forest Meteorology, 2009, 149(8):1327-1342.
- [36] WIGNERON J P, WALDTEUFEL P, CHANZY A, et al. Two-dimensional microwave interferometer retrieval capabilities over land surfaces (SMOS Mission) [J]. Remote Sensing of Environment, 2017, 73(3):270-282.
- [37] NOTARNICOLA C, ANGIULLI M, POSA F. Soil moisture retrieval from remotely sensed data: neural network approach versus Bayesian method[J]. IEEE Transactions on Geoscience & Remote Sensing, 2008, 46(2):547-557.
- [38] 张坤, 刘永强, 阿依尼格尔·亚力坤, 等. 塔克拉玛干沙漠腹地土壤热通量的陆面过程与卫星遥感研究[J]. 江苏农业科学, 2020, 48(20):256-264.

(责任编辑:张震林)