

基于LM算法的土壤表层含水率遥感监测

许景辉^{1,2} 王雷² 王一琛² 赵钟声² 韩文霆³

(1. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100;

2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;

3. 西北农林科技大学中国旱区节水农业研究院, 陕西杨凌 712100)

摘要: 为探讨数据挖掘技术中LM(Levenberg-Marquardt)算法在土壤表层(约1 cm)含水率遥感监测中的应用,选取黄绵土、粘黄土、红土为试验材料,配制含水率分别为0.6%、10%、14%、18%、22%的土壤样本,在09:00—10:00和15:00—16:00时间段进行可见光采样,并对图像亮度进行梯度处理,以此模拟全天光线变化。采用样本实测含水率及图像RGB三阶颜色矩数据作为数据集,对上午、下午样本和两时间段混合样本采用LM算法建立含水率回归模型,并与BP(Back propagation)算法和分类回归树(Classification and regression trees, CART)算法进行比较。结果表明,基于土壤表层RGB颜色矩的LM算法具有较好的应用效果,混合样本不同土样回归模型决定系数 R^2 分别为0.958、0.943、0.949,均方根误差(RMSE)分别为1.6%、2.0%、1.9%,相对分析误差(RPD)分别为4.873、4.183、4.440。不同光照时的混合样品分析结果表明,LM算法适用于不同光线采集样品的土壤含水率监测,适用于土壤表层(约1 cm)含水率的监测。

关键词: 土壤含水率; 数据挖掘; LM算法; 遥感; 监测

中图分类号: S152.7; TP183 **文献标识码:** A **文章编号:** 1000-1298(2019)06-0233-08

Remote Sensing Monitoring of Soil Surface Moisture Content Based on LM Algorithm

XU Jinghui^{1,2} WANG Lei² WANG Yichen² ZHAO Zhongsheng² HAN Wenting³

(1. Key Laboratory of Agricultural Soil and Water Engineering in Arid Areas, Ministry of Education, Northwest A&F University, Yangling, Shaanxi 712100, China

2. College of Water Resources and Architectural Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China

3. Institute of Water-saving Agriculture in Arid Areas of China, Northwest A&F University, Yangling, Shaanxi 712100, China)

Abstract: Aiming to research the data mining technology in remote sensing monitoring. The LM algorithm was used in the soil surface layer (about 1 cm) of soil moisture measurement (soil moisture content, SMC). Three kinds of soil, including yellow spongy, loess and red clay were selected. The soil water content samples of 0.6%, 10%, 14%, 18% and 22% were prepared respectively. Visible light images were taken during 09:00—10:00 and 15:00—16:00, and image brightness was gradiently processed for simulating the change of light throughout the day. LM algorithm was compared with back propagation (BP) algorithm and classification and regression trees (CART) algorithm to verify the practical effect of LM. It was showed that the LM algorithm had a good application effect for the data mining based on the RGB color moment of soil pictures. The determination coefficient of the regression model for yellow spongy, loess and red clay was 0.958, 0.943 and 0.949, root mean square error (RMSE) was 1.6%, 2.0% and 1.9%, and the relative analysis error (RPD) was 4.873, 4.183 and 4.440, respectively. By the study of pictures at different intensities, LM algorithm can be used for monitoring soil moisture content of samples. It can be used for the soil surface (about 1 cm) moisture content measurement.

Key words: soil moisture content; data mining; LM algorithm; remote sensing; monitoring

收稿日期: 2018-12-07 修回日期: 2019-01-18

基金项目: 国家重点研发计划项目(2017YFC0403203)、陕西省水利科技计划项目(2014slkj-18)和中央高校基本科研业务费专项资金项目(2452015050)

作者简介: 许景辉(1978—),男,副教授,博士,主要从事农业电气化与农业智能化检测研究,E-mail: x36936@163.com

0 引言

基于无人机遥感反演的土壤含水率 (Soil moisture content, SMC) 监测能进行较大范围的土壤含水率测量,但目前其准确性和精度都还较低^[1]。土壤表层含水率是土壤侵蚀、蒸发蒸腾及作物耗水的重要影响因素,由于距地面较浅,无法应用各类介电传感器,其自动监测一直是相关领域的难题^[2]。近年来,无人机遥感技术发展迅速,基于无人机遥感的土壤含水率测量已成为国内外研究热点^[1,3-9]。李小昱等^[10]采用近红外光谱傅里叶变换特征提取方法检测土壤含水率,并取得了一定成果。但由于近红外光谱设备成本较高,土壤含水率相关研究的应用具有很大局限性。罗蔚然等^[11]通过可见光遥感进行了土壤含水率监测,但光线的干扰使得可见光遥感精度较差。张荣标等^[12]提出了中值滤波方法,但可见光影响因素众多,不能简单通过一种数学模型实现干扰信息过滤。数据挖掘技术能够很好地描述非线性模型,因此研究基于数据挖掘技术的可见光遥感技术,可有效降低成本,为无人机广域土壤含水率监测提供技术支持。

光谱的定量反演大多以线性回归模型进行,但模型训练及筛选均基于偏最小二乘回归法^[5]、光谱变换^[13]等简单方法。如何定量表达光谱特性和 SMC 的相关性、提高模型鲁棒性、降低模型过程冗余度,仍有待优化。数据挖掘能综合考虑 SMC 光谱响应,降低干扰项影响,提高测量精度。数据挖掘技术中,LM 神经网络是基于 LM (Levenberg - Marquardt) 算法的一种神经网络,其在解析非线性问题时表现能力较好,所构建模型具有很好的自适应性和鲁棒性,在建模反演中被广泛应用^[14-15]。但在基于 RGB 颜色矩的土壤含水率监测研究应用还在探索。

本文以 3 种土壤(黄绵土、粘黄土、红土)为研究对象,通过野外土壤采样、室内理化分析、RGB 真彩色图像采集与处理等工作,尝试采用 LM 神经网络构建 3 种土壤的可见光 SMC 计算模型,并对模型进行精度评定。采用 BP 算法^[16-20]和 CART 算法^[21-22]与之对比,比较分析 3 种算法在 SMC 监测中的效果,以实现精度高、稳定性好的无人机机载 SMC 测量与监测。

1 材料与方法

1.1 试验材料

选用不同类型的 3 种土壤作为试验用土,分别为我国延安地区的黄绵土、陕西杨凌地区的粘黄土

和江西地区红土。测得 3 种土壤干容重 ρ_d 为 1.25、1.3、1.5 g/cm³。将 3 种土样晒干、粉碎并过 2 mm 筛网制成试验土样。分别取 330 g 土样装入塑料密封袋中,配成土壤含水率 θ 分别为 0%、6%、10%、14%、18%、22% 的土样,密封放置 24 h,使水分在土壤均匀扩散。随后将配置好的土样装入预先准备好的样品盒中(高度 1.3 cm),每种土样样品共 60 个。配制好后用精度为 0.01 g 的 LT3002T 型电子天平称取每一个样本的质量,供后续测量土壤样本真实含水率。

1.2 图像获取

为了调控干扰因素,便于检验模型的抗干扰性,试验在实验室内进行,采用相机(Canon EOS 500D)拍照采样,每幅图像分辨率为 2 304 像素 × 3 456 像素。用三脚架固定数码相机,并调至合适高度,并保证土样置于图像中央。09:00—10:00 对每种土样进行自然光线拍摄,完毕后将土壤用密封袋保存,待 15:00—16:00 再次拍摄完毕后,立即将样本放入干燥箱,在 105℃ 恒温条件下干燥 10 h,以获取其实际含水率。为减少偶然因素影响,每个样品取样 3 幅图像。为了模拟不同工作时段自然光线的影响,利用 Photoshop 将采集的图像进行处理,将上午样本图像亮度分别降低 10%、增高 15%、增高 30%;下午样本图像亮度分别增高 10%、降低 15%、降低 30%。由此,上午、下午样本各 720 个,土样图像样本总数为 1 440 个。

1.3 图像预处理与特征提取

1.3.1 图像切割

采集的土样图像包含盛土容器,容器颜色与土样的颜色差距较大,同时土体位于图像中央,为提取土壤颜色特征,提取土样图像中央 101 像素 × 101 像素的图像。实现原理^[23]为:设原始图像的像素大小是 $M \times N$,则截取宽从第 $fix\left(\frac{M}{2}\right) - 50$ 个像素点到第 $fix\left(\frac{M}{2}\right) + 50$ 个像素点,长从第 $fix\left(\frac{N}{2}\right) - 50$ 个像素点到第 $fix\left(\frac{N}{2}\right) + 50$ 个像素点的子图像。切割前后土样图像如图 1 所示。

1.3.2 RGB 颜色矩提取

颜色矩包含各个颜色通道的一阶矩、二阶矩和三阶矩,对于一幅具有 RGB 颜色空间的图像,具有 R、G 和 B 3 个颜色通道,则共有 9 个分量。各阶颜色矩的计算公式如下^[23]:

(1) 一阶颜色矩

一阶颜色矩采用一阶原点矩,反映了图像的整




图 1 土样图像

Fig. 1 Images of soil sample

体明暗程度,计算公式为

$$E_i = \frac{1}{N} \sum_{j=1}^N p_{ij} \quad (i = 1, 2, 3) \quad (1)$$

式中 E_i ——第 i 个颜色通道的一阶颜色矩,对应于 RGB 颜色空间的图像

p_{ij} ——第 j 个像素的第 i 个颜色通道颜色值

(2) 二阶颜色矩

二阶颜色矩采用二阶中心矩的平方根,反映了图像颜色的分布范围,计算公式为

$$s_i = \sqrt{\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^2} \quad (i = 1, 2, 3) \quad (2)$$

式中 s_i ——第 i 个颜色通道的二阶颜色矩

(3) 三阶颜色矩

三阶颜色矩采用三阶中心矩的立方根,反映了图像颜色分布的对称性,计算公式为

$$r_i = \sqrt[3]{\frac{1}{N} \sum_{j=1}^N (p_{ij} - E_i)^3} \quad (i = 1, 2, 3) \quad (3)$$

式中 r_i ——第 i 个颜色通道的三阶颜色矩

对切割后的图像提取颜色矩,以作为图像的颜色特征。提取部分结果(红土)如表 1 所示。

1.4 模型构建

对提取特征值后的样本进行抽样,从各自总样

表 1 土样颜色特征与相应土样实测含水率部分数据

Tab. 1 Partial data of soil color characteristics and measured soil moisture content of corresponding soil samples

实测土壤 含水率/%	一阶矩			二阶矩			三阶矩		
	R 通道	G 通道	B 通道	R 通道	G 通道	B 通道	R 通道	G 通道	B 通道
4.44	0.628 6	0.409 8	0.282 9	0.015 3	0.018 3	0.017 9	-0.006 6	-0.008 1	-0.002 8
4.48	0.637 4	0.419 2	0.287 3	0.016 1	0.017 3	0.017 8	0.007 3	0.009 7	0.010 5
4.39	0.588 0	0.374 3	0.255 7	0.016 6	0.016 4	0.017 3	-0.005 8	-0.006 7	-0.002 1
4.47	0.683 5	0.467 5	0.321 4	0.018 1	0.021 0	0.020 1	0.004 0	-0.010 0	0.007 4
4.45	0.679 8	0.464 7	0.320 0	0.016 7	0.020 7	0.021 0	-0.009 4	0.004 5	0.009 1
4.47	0.684 9	0.472 6	0.326 0	0.017 7	0.019 5	0.018 9	0.006 3	-0.009 4	-0.010 3
4.48	0.638 3	0.415 0	0.284 0	0.021 7	0.025 7	0.023 9	-0.016 1	-0.012 8	-0.010 6
4.49	0.662 4	0.439 3	0.301 9	0.020 8	0.024 3	0.021 2	-0.015 2	-0.019 3	-0.013 2
4.39	0.669 9	0.451 8	0.312 3	0.020 5	0.024 6	0.023 5	-0.015 8	-0.013 1	0.010 5

本中抽取 80% 作为训练样本,20% 作为测试样本,以检验模型的测量精度。

LM 算法属于二阶算法,当误差曲面的梯度较小时,LM 算法类似于最速梯度法;当误差曲面的梯度较大时,LM 算法类似于高斯-牛顿法^[24-26]。由

于 LM 算法能够根据 Hessian 矩阵估计误差曲面各个梯度方向上的学习率,与一阶算法相比,LM 算法是目前训练神经网络最有效的算法^[27]。LM 算法理论如下^[15,28-29]：

神经网络的误差指标函数为

$$E(x) = \frac{1}{2} \sum_{i=1}^N \| Y_i - \hat{Y}_i \|^2 = \frac{1}{2} \sum_{i=1}^N e_i^2(x) \quad (4)$$

式中 Y_i ——预期的网络输出向量
 \hat{Y}_i ——实际的网络输出向量
 e_i ——当前误差

设 x_k 为第 k 次迭代的网络权值向量, 维数为 M , 牛顿算法新的权值向量 x_{k+1} 为

$$x_{k+1} = x_k + \Delta x_k = x_k - H_k^{-1} g_k \quad (5)$$

其中 $g_k = \nabla E(x) |_{x=x(k)} = J^T(x) e(x) \quad (6)$

$$x_{k+1} = x_k - [J^T(x_k) J(x_k)]^{-1} J^T(x_k) e(x_k) = x_k - H^{-1}(x_k) J^T(x_k) e(x_k)$$

$$H = J^T J$$

式中 J ——雅可比矩阵
 H ——Hessian 矩阵
 H_k ——Hessian 矩阵
 g_k ——当前梯度

然而矩阵 H 不一定可逆, 为了解决这个问题, 考虑引入系数 λ_k , 更新权值的 LM 算法为

$$x_{k+1} = x_k - [J^T(x_k) J(x_k) + \lambda_k I]^{-1} J^T(x_k) e(x_k) \quad (7)$$

当 λ_k 很大时, LM 算法近似于梯度下降法; 当 λ_k 很小时, 则是高斯-牛顿算法。

其算法流程为: ①给出训练的允许误差 ε , 初始权值向量 $x, k=0$ 。②计算网络的输出及误差向量 $E(x)$ 。③计算误差向量对网络权值的梯度值并形成雅可比矩阵。④训练完成后, 更新选择。⑤如果网络收敛则停止, 否则返回步骤②。

1.5 模型精度评价

为了量化基于 LM 神经网络、BP 神经网络和 CART 决策树的实测土壤含水率和回归值的建模效果和性能, 选用决定系数 (R^2)、均方根误差 (RMSE) 和相对分析误差 (RPD) 来进行模型的评价。 R^2 越大, 表明建模精度越高; RMSE 越小, 表明模型的预测精度越高。RPD 已广泛应用于度量评估土壤属性回归模型的准确性。当 $RPD \geq 2.5$ 时, 表明模型

具有极好的回归能力, 当 $2.0 \leq RPD < 2.5$ 时, 表明模型具有很好的定量回归能力; 当 $1.8 \leq RPD < 2.0$ 时, 表明模型具有较好的定量回归能力; 当 $1.4 \leq RPD < 1.8$ 时, 表明模型具有定量回归能力; 当 $1.0 \leq RPD < 1.4$ 时, 表明模型具有区别高值和低值的能力; 当 $RPD < 1.0$ 时, 表明模型不具备回归能力^[1]。

2 结果与分析

2.1 样品土壤含水率

表 2 为上午样本和下午样本各土壤类型 SMC 的统计特征。其中黄绵土的建模集与验证集所对应的均值分别是 13.21% 和 13.12%, 变异系数分别为 56.18% 和 60.49%。而黄绵土全样本的 SMC 的均值为 13.19%, 变异系数为 57.02%。可见, 全样本的均值和变异系数均介于建模集和验证集之间。其他两种土样具有相同试验结果, 全样本的均值和变异系数均介于建模集和验证集之间。为了验证模型对自然环境影响的适应性, 除了进行上午样本和下午样本训练外, 还将上午、下午样本进行混合, 通过混合样本来验证模型的适应性。表 3 为混合样本的 SMC 统计特征。

2.2 土壤含水率回归模型及验证

根据各土壤实测含水率以及其相应的 RGB 颜色矩数据, 构建基于 LM 神经网络、BP 神经网络和 CART 决策树的 3 种回归 SMC 模型, 分别简称为 LM 模型、BP 模型和 DT 模型。各模型对于不同土壤的 SMC 回归结果如表 4 所示。表 4 为上午样本不同模型下土壤含水率的模型评价及回归评价结果; 表 5 为下午样本不同模型下各土壤含水率的模型评价及回归评价结果; 表 6 为混合样本不同模型下各土壤含水率的模型评价及回归评价结果。

由表 4 可以看出, LM 模型的 RPD 值均大于 2.5, 而 BP 模型和 DT 模型的 RPD 值相对较低, 但都大于 1.4, 因此均适合 3 种土壤的 SMC 建模。在 3 种算法所构建的 SMC 模型中, LM 神经网络模型

表 2 被测土壤样品 SMC 统计特征

Tab. 2 SMC statistical characteristics of sample soil samples

土壤种类	样本类型	样本数	最小值/%	最大值/%	平均值/%	标准偏差/%	变异系数/%
黄绵土	总体样本	720	1.30	26.52	13.19	7.52	57.02
	建模样本	582	1.30	26.52	13.21	7.42	56.18
	验证样本	138	1.30	26.52	13.12	7.94	60.49
粘黄土	总体样本	720	3.84	27.03	16.19	7.70	47.56
	建模样本	582	3.84	27.03	16.21	7.59	46.83
	验证样本	138	3.84	27.03	16.12	8.15	50.57
红土	总体样本	720	4.39	28.23	16.93	7.86	46.42
	建模样本	582	4.39	28.23	16.94	7.75	45.71
	验证样本	138	4.39	28.07	16.85	8.31	49.33

表 3 混合样本土壤样品 SMC 统计特征

Tab. 3 SMC statistical characteristics of mixed sample soil samples

土壤种类	样本类型	样本数	最小值/%	最大值/%	平均值/%	标准偏差/%	变异系数/%
黄绵土	总体样本	1 440	1.30	26.52	13.19	7.52	57.02
	建模样本	1 171	1.30	26.52	13.11	7.41	56.50
	验证样本	269	1.30	26.52	13.54	7.99	59.03
粘黄土	总体样本	1 440	3.84	27.03	16.19	7.70	47.56
	建模样本	1 171	3.84	27.03	16.11	7.59	47.11
	验证样本	269	3.84	27.03	16.54	8.16	49.29
红土	总体样本	1 440	4.39	28.23	16.93	7.86	46.42
	建模样本	1 171	4.39	28.23	16.86	7.75	45.99
	验证样本	269	4.39	28.23	17.23	8.29	48.12

表 4 上午样本不同模型下各土壤含水率的模型评价及回归评价结果

Tab. 4 Model evaluation and prediction evaluation results of soil moisture content under different models for AM sample

土壤类型	模型	模型评价			回归评价		
		R^2	RMSE/%	RPD	R^2	RMSE/%	RPD
黄绵土	LM 模型	0.980	1.0	7.133	0.972	1.3	5.964
	BP 模型	0.822	3.1	2.373	0.830	3.3	2.432
	DT 模型	0.793	3.4	2.197	0.723	4.2	1.906
粘黄土	LM 模型	0.973	1.2	6.140	0.972	1.4	5.971
	BP 模型	0.939	1.9	4.053	0.944	1.9	4.233
	DT 模型	0.861	2.8	2.684	0.863	3.0	2.711
红土	LM 模型	0.976	1.2	6.456	0.974	1.3	6.278
	BP 模型	0.929	2.1	3.744	0.909	2.5	3.328
	DT 模型	0.805	3.4	2.268	0.657	4.9	1.713

表 5 下午样本不同模型下各土壤含水率的模型评价及回归评价结果

Tab. 5 Model evaluation and prediction evaluation results of soil moisture content under different models for PM sample

土壤类型	模型	模型评价			回归评价		
		R^2	RMSE/%	RPD	R^2	RMSE/%	RPD
黄绵土	LM 模型	0.982	1.0	7.402	0.977	1.2	6.576
	BP 模型	0.885	2.5	2.947	0.881	2.7	2.904
	DT 模型	0.864	2.7	2.717	0.737	4.1	1.957
粘黄土	LM 模型	0.968	1.4	5.630	0.922	2.3	3.596
	BP 模型	0.882	2.6	2.908	0.842	3.2	2.525
	DT 模型	0.712	4.1	1.865	0.548	5.5	1.493
红土	LM 模型	0.975	1.2	6.300	0.912	2.5	3.390
	BP 模型	0.929	2.1	3.376	0.898	2.7	3.135
	DT 模型	0.800	3.5	2.236	0.551	5.6	1.498

在 3 种土壤中均表现最佳,最佳表现土壤种类为黄绵土,模型评价参数 R^2 为 0.980、RMSE 为 1.0%、RPD 为 7.133,回归评价参数 R^2 为 0.972、RMSE 为 1.3%、RPD 为 5.964。由此可见,3 种算法构建的模型回归能力由大到小为 LM 神经网络、BP 神经网络、CART 决策树,各模型对于 3 种土壤的适应表现能力黄绵土最强,粘黄土和红土相对较差。图 2 为上午样本各土壤 LM 模型 SMC 回归值与实测值。

表 6 混合样本不同模型下各土壤含水率的模型评价及回归评价结果

Tab. 6 Model evaluation and prediction evaluation results of soil moisture content under different models of mixed samples

土壤类型	模型	模型评价			回归评价		
		R^2	RMSE/%	RPD	R^2	RMSE/%	RPD
黄绵土	LM 模型	0.966	1.4	5.426	0.958	1.6	4.873
	BP 模型	0.842	2.9	2.519	0.836	3.2	2.473
	DT 模型	0.704	4.0	1.838	0.521	5.5	1.448
粘黄土	LM 模型	0.964	1.4	5.303	0.943	2.0	4.183
	BP 模型	0.851	2.9	2.292	0.860	3.1	2.680
	DT 模型	0.728	4.0	1.918	0.686	4.6	1.787
红土	LM 模型	0.953	1.7	4.623	0.949	1.9	4.440
	BP 模型	0.894	2.5	3.066	0.901	2.6	3.191
	DT 模型	0.711	4.2	1.859	0.569	5.4	1.526

络、CART 决策树,各模型对于 3 种土壤的适应表现能力黄绵土最强,粘黄土和红土相对较差。图 2 为上午样本各土壤 LM 模型 SMC 回归值与实测值。

由表 5 可以看出,LM 神经网络和 BP 神经网络模型 RPD 均大于 2.5,适合 3 种土壤的 SMC 建模。而 DT 模型对于 3 种土壤其 RPD 小于 2.5,尤其对于粘黄土和红土其 RPD 小于 1.8,因此 DT 模型对于红土的 SMC 建模能力较低。同样,在 3 种算法所构建的 SMC 模型中,LM 神经网络模型在 3 种土壤中的 3 个参数均表现最佳,最佳表现土壤种类为黄绵土,模型评价参数 R^2 为 0.982、RMSE 为 1.0%、RPD 为 7.402,回归评价参数 R^2 为 0.977、RMSE 为 1.2%、RPD 为 6.576。由此可见,3 种算法构建的模型回归能力由大到小为 LM 神经网络、BP 神经网络、CART 决策树,各模型对于 3 种土壤的适应表现能力黄绵土最强,粘黄土和红土相对较差。图 3 为下午样本各土壤 LM 模型 SMC 回归值与实测值。

由表 6 可以看出,LM 神经网络模型 RPD 大于 2.5,适合 3 种土壤的 SMC 建模。而 BP 模型 RPD 值仅在黄绵土中略小于 2.5,另两种土中均大于

2.5,表明BP模型适用于3种土壤的SMC建模。其DT模型RPD均小于1.8,因此DT模型在混合样本中对于3种土壤的SMC建模能力较低。同样,在3种算法所构建的SMC模型中,LM神经网络模型在3种土壤中的3个参数均表现最佳,最佳表现土壤种类为黄绵土,模型评价参数 R^2 为0.966、RMSE

为1.4%、RPD为5.426,回归评价参数 R^2 为0.958、RMSE为1.6%、RPD为4.873。由此可见,3种算法构建的模型回归能力由大到小为LM神经网络、BP神经网络、CART决策树,各模型对于3种土壤的适应能力表现能力黄绵土最强,粘黄土和红土相对较差。图4为混合样本各土壤LM模型SMC回归值与实测值。




图2 上午样本LM模型SMC回归值与实测值

Fig. 2 SMC predicted and measured values of LM model for AM sample




图3 下午样本LM模型SMC回归值与实测值

Fig. 3 SMC predicted and measured values of LM model for PM sample




图4 混合样本LM模型SMC回归值与实测值

Fig. 4 SMC predicted and measured values of LM model for mixed sample

综上所述,在SMC回归模型的建模效果和回归效果中LM模型表现最佳,BP模型回归能力相对较差,DT模型回归能力最差,因此,3种模型中LM模型回归能力和模型精度都高于其他两者,即LM模型最优,适用于土壤表层(约1 cm)的土壤水分回归。对比3种模型在各土壤的适应情况,可以看出,各模型均在黄绵土表现最佳,粘黄土和红土相对较差,可见土壤自身的颜色对于模型的回归有一定的影响。

3 讨论

研究结果表明,LM神经网络能通过大量数据训练,消除自然条件下的综合影响因素,提高基于土壤RGB颜色矩的土壤含水率识别精度。土壤可见光- RGB颜色矩与土壤含水率之间存在较好的相关性,其建模集和回归集的建模回归决定系数 R^2 最高分别可达0.982和0.977。为通过遥感技术实现农田土壤墒情的快速检测技术提供了一定的理论基

础。同时,通过对比3种算法在不同土壤类型的SMC建模回归的结果分析,得出LM神经网络建立的SMC回归模型最优,其模型决定系数 R^2 均大于0.9。BP神经网络回归模型相对LM模型较差,DT模型相对前两种模型表现最差,在下午样本红土中其决定系数 R^2 为0.551,基本没有回归能力。由于红土自身颜色较重,土壤含水率增加后其颜色变化敏感度较低,因此对于模型回归有一定影响,而LM算法模型能够较好地克服这一影响因素,表现了其算法的优越性。通过统计学理论分析可知,3种SMC模型在回归不同土壤含水率时,LM模型的回归效果具有较强的相关性。相较于传统线性回归模型,LM算法构建的神经网络回归模型具有显著的优越性,它不仅训练误差较小,回归能力更为精准,而且模型鲁棒性强,具有很好的非线性解译建模能力。

4 结论

(1)基于LM算法的SMC回归模型表现最优,

其建模精度和回归能力最好,在下午黄绵土样本中,建模集 R^2 为0.982、RMSE为1.0%、RPD为7.402,回归集 R^2 为0.977、RMSE为1.2%、RPD为6.576。混合样本不同土样(黄绵土、粘黄土、红土)回归模型决定系数(R^2)分别为0.958、0.943、0.949,均方根误差(RMSE)分别为1.6%、2.0%、1.9%,相对分析误差(RPD)分别为4.873、4.183、4.440。

(2)LM算法模型在黄绵土中均表现最佳,在粘黄土和红土中相对较差。由此可见,土壤自身颜色对于本研究SMC回归模型具有一定的影响。通过比较上午样本、下午样本和混合样本可知,外界光线对于LM算法的建模影响很小,说明基于LM算法的SMC回归模型具体较好的适应能力。

(3)通过分析LM模型算法建模集和回归集评价参数可知,LM算法建立的回归模型更为稳定,其回归集和建模集的决定系数(R^2)均稳定在0.9以上,说明基于LM算法的SMC回归模型具有较好的稳定性。

参 考 文 献

- [1] 张智韬,王海峰,韩文霆,等. 基于无人机多光谱遥感的土壤含水率反演研究[J/OL]. 农业机械学报, 2018, 49(2): 173-181. ZHANG Zhitao, WANG Haifeng, HAN Wenting, et al. Inversion of soil moisture content based on multispectral remote sensing of UAVs[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 173-181. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180223&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.02.023. (in Chinese)
- [2] 陈仲新,任建强,唐华俊,等. 农业遥感研究应用进展与展望[J]. 遥感学报, 2016, 20(5): 748-767. CHEN Zhongxin, REN Jianqiang, TANG Huajun, et al. Progress and perspectives on agricultural remote sensing research and applications in China[J]. Journal of Remote Sensing, 2016, 20(5): 748-767. (in Chinese)
- [3] KUMAR S V, DIMEYER P A, PETERS-LIDARD C D, et al. Information theoretic evaluation of satellite soil moisture retrievals[J]. Remote Sensing of Environment, 2018, 204: 392-400.
- [4] 殷超,周忠发,谭玮颀,等. 基于微波与光学遥感的石漠化地区土壤剖面含水率反演模型研究[J]. 红外与毫米波学报, 2018, 37(3): 360-370. YIN Chao, ZHOU Zhongfa, TAN Weiyi, et al. Inversion model of soil profile moisture content in rocky desertification area based on microwave and optical remote sensing[J]. Journal of Infrared and Millimeter Waves, 2018, 37(3): 360-370. (in Chinese)
- [5] 张智韬,王海峰,KARNIELI A,等. 基于岭回归的土壤含水率高光谱反演研究[J/OL]. 农业机械学报, 2018, 49(5): 240-248. ZHANG Zhitao, WANG Haifeng, KARNIELI A, et al. Hyperspectral inversion of soil water content based on ridge regression[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(5): 240-248. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20180528&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2018.05.028. (in Chinese)
- [6] 杨曦光,于颖. 基于试验反射光谱数据的土壤含水率遥感反演[J]. 农业工程学报, 2017, 33(22): 195-199. YANG Xiguang, YU Ying. Remote sensing inversion of soil moisture content based on experimental reflectance spectral data[J]. Transactions of the CSAE, 2017, 33(22): 195-199. (in Chinese)
- [7] 李明泽,高元科,邸雪颖,等. 基于微波遥感技术探测森林地表土壤含水率[J]. 应用生态学报, 2016, 27(3): 785-793. LI Mingze, GAO Yuanke, DI Xueying, et al. Detecting the moisture content of forest surface soil based on the microwave remote sensing technology[J]. Chinese Journal of Applied Ecology, 2016, 27(3): 785-793. (in Chinese)
- [8] PETROPOULOS G P, IRELAND G, BARRETT B. Surface soil moisture retrievals from remote sensing: current status, products & future trends[J]. Physics and Chemistry of the Earth, Parts A/B/C, 2015, 83-84: 36-56.
- [9] 殷哲,雷廷武,陈展鹏,等. 近红外传感器测量不同种类土壤含水率的适应性研究[J/OL]. 农业机械学报, 2014, 45(3): 148-151. YIN Zhe, LEI Tingwu, CHEN Zhanpeng, et al. Adaptability of near-infrared sensor for moisture measurement of different soils[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(3): 148-151. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20140325&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2014.03.025. (in Chinese)
- [10] 李小昱,肖武,李培武,等. 基于近红外傅里叶特征提取方法的土壤含水率检测[J]. 农业机械学报, 2009, 40(5): 64-67. LI Xiaoyu, XIAO Wu, LI Peiwu, et al. Soil moisture content detection based on near-infrared Fourier feature extraction

- method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2009, 40(5): 64–67. (in Chinese)
- [11] 罗蔚然,张成才,闫超德,等. 基于微波和可见光遥感的冬小麦土壤墒情反演[J]. 水利信息化, 2017(5): 46–50.
LUO Weiran, ZHANG Chengcai, YAN Chaode, et al. Winter wheat soil moisture inversion based on microwave and visible light remote sensing[J]. Water Conservancy Information, 2017(5): 46–50. (in Chinese)
- [12] 张荣标,何加祥,吴涛,等. 基于图像处理的土壤表层含水率在线检测方法研究[J]. 农业工程学报, 2007, 23(10): 57–61.
ZHANG Rongbiao, HE Jiexiang, WU Tao, et al. On-line detection method of soil surface moisture content based on image processing[J]. Transactions of the CSAE, 2007, 23(10): 57–61. (in Chinese)
- [13] ZHANG Xianlong, ZHANG Fei, ZHANG Haiwei, et al. Optimization of soil salt inversion model based on spectral transformation from hyperspectral index[J]. Transactions of CSAE, 2018, 34(1): 110–117.
- [14] JEBUR A A, ATHERTON W, AL KHADDAR R M, et al. Settlement prediction of model piles embedded in sandy soil using the Levenberg–Marquardt (LM) training algorithm[J]. Geotechnical and Geological Engineering, 2018, 36(5): 2893–2906.
- [15] 李明河,周磊,王健. 基于LM算法的溶解氧神经网络预测控制[J/OL]. 农业机械学报, 2016, 47(6): 297–302.
LI Minghe, ZHOU Lei, WANG Jian. Predictive control of dissolved oxygen neural network based on LM algorithm[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(6): 297–302. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20160639&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2016.06.039. (in Chinese)
- [16] 刘振华,范宏运,朱宇泽,等. 基于BP神经网络的溶洞规模预测及应用[J]. 中国岩溶, 2018, 37(1): 139–145.
LIU Zhenhua, FAN Hongyun, ZHU Yuze, et al. Prediction model for the scale of karst cave based on back propagation artificial neural network and its application[J]. Carsologica Sinica, 2018, 37(1): 139–145. (in Chinese)
- [17] 高斌,赵鹏飞,卢昱欣,等. 基于BP神经网络的血液荧光光谱识别分类研究[J]. 光谱学与光谱分析, 2018, 38(10): 3136–3143.
GAO Bin, ZHAO Pengfei, LU Yuxin, et al. Study on recognition and classification of blood fluorescence spectrum with BP neural network[J]. Spectroscopy and Spectral Analysis, 2018, 38(10): 3136–3143. (in Chinese)
- [18] JIA Zhenyi, ZHOU Shenglu, SU Quanlong, et al. Comparison study on the estimation of the spatial distribution of regional soil metal(loid)s pollution based on Kriging interpolation and BP neural network[J]. International Journal of Environmental Research & Public Health, 2018, 15(1): 34.
- [19] 郭澎涛,苏艺,茶正早,等. 基于BP神经网络的橡胶苗叶片磷含量高光谱预测[J]. 农业工程学报, 2016, 32(增刊1): 177–183.
GUO Pengtao, SU Yi, CHA Zhengzao, et al. Hyperspectral prediction of phosphorus content in rubber seedling leaves based on BP neural network[J]. Transactions of the CSAE, 2016, 32(Supp. 1): 177–183. (in Chinese)
- [20] 刘雪,李亚妹,刘娇,等. 基于BP神经网络的鲜鸡蛋货架期预测模型[J/OL]. 农业机械学报, 2015, 46(10): 328–334.
LIU Xue, LI Yamei, LIU Jiao, et al. Prediction model of shelf life of fresh eggs based on BP neural network[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(10): 328–334. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20151044&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.10.044. (in Chinese)
- [21] HAN Jiaqi, MAO Kebiao, XU Tongren, et al. A soil moisture estimation framework based on the CART algorithm and its application in China[J]. Journal of Hydrology, 2018, 563: 65–75.
- [22] 吕利利,颀耀文,黄晓君,等. 基于CART决策树分类的沙漠化信息提取方法研究[J]. 遥感技术与应用, 2017, 32(3): 499–506.
LÜ Lili, JIE Yaowen, HUANG Xiaojun, et al. Research on desertification information extraction method based on CART decision tree classification[J]. Remote Sensing Technology and Application, 2017, 32(3): 499–506. (in Chinese)
- [23] 张良均,杨坦,肖刚,等. MATLAB数据分析与挖掘实战[M]. 北京:机械工业出版社, 2015.
- [24] 张海辉,陶彦蓉,胡瑾. 融合叶绿素含量的黄瓜幼苗光合速率预测模型[J/OL]. 农业机械学报, 2015, 46(8): 259–263.
ZHANG Haihui, TAO Yanrong, HU Jin. Photosynthetic rate prediction model of cucumber seedlings with chlorophyll content[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(8): 259–263. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=20150836&journal_id=jcsam. DOI:10.6041/j.issn.1000-1298.2015.08.036. (in Chinese)
- [25] 韩敏,穆大芸. 回声状态网络LM算法及混沌时间序列预测[J]. 控制与决策, 2011, 26(10): 1469–1472.
HAN Min, MU Dayun. Echo state network LM algorithm and chaotic time series prediction[J]. Control and Decision, 2011, 26(10): 1469–1472. (in Chinese)
- [26] LEVENBERG K. A method for the solution of certain non-linear problems in least squares[J]. Quarterly of Applied Mathematics, 1944, 2(4): 436–438.
- [27] WILAMOWSKI B M, YU Hao. Improved computation for Levenberg–Marquardt training[J]. IEEE Transactions on Neural Networks, 2010, 21(6): 930–937.
- [28] JEFFREY K C F, TSAI W L, SU T L, et al. Application of an LM-neural network for establishing a prediction system of quality characteristics for the LGP manufactured by CO₂ laser[J]. Optics & Laser Technology, 2011, 43(3): 529–536.
- [29] 赵弘,周瑞祥,林廷圻. 基于Levenberg–Marquardt算法的神经网络监督控制[J]. 西安交通大学学报, 2002, 36(5): 523–527.
ZHAO Hong, ZHOU Ruixiang, LIN Tingqi. Neural network supervision and control based on Levenberg–Marquardt algorithm[J]. Journal of Xi'an Jiaotong University, 2002, 36(5): 523–527. (in Chinese)