

BP神经网络和SVM模型对施加生物炭 土壤水分预测的适用性

王彤彤¹, 翟军海³, 何欢⁴, 郑纪勇^{1,2}, 涂川⁵

(1. 西北农林科技大学 资源环境学院, 陕西 杨凌 712100; 2. 中国科学院 水利部 水土保持研究所
黄土高原土壤侵蚀与旱地农业国家重点实验室, 陕西 杨凌 712100; 3. 陕西省农业厅, 西安 710003;
4. 西北农林科技大学 理学院, 陕西 杨凌 712100; 5. 重庆邮电大学 计算机科学与技术学院, 重庆 400065)

摘要:生物炭作为土壤改良剂对半干旱区土壤水分有良好的吸持作用,为确定施加生物炭对土壤水分预测模型适用性的影响,依托黄土高原半干旱区固原生态站开展了小区定位试验。向土壤中施加不同种类及比例的生物炭,定期监测土壤水分含量;考虑土壤含水量的非线性特征以及生物炭对土壤水分的影响,选取BP神经网络和SVM支持向量机两种模型,建立施加生物炭土壤水分预测模型。计算预测值,并与实测值对比,分析相对误差;利用RMSE、MRE、MAE和 R^2 评估BP神经网络和SVM模型的精度。结果表明:BP神经网络预测值的平均相对误差为3.78%,最大误差为13.14%;SVM模型的平均相对误差为0.56%,最大误差为2.42%。SVM模型的RMSE、MRE、MAE值(分别为0.34~0.17,0.07,0.56~1.27)均小于BP神经网络的(分别为1.04~1.16,0.47~0.68,3.78~4.57),且决定系数 R^2 值SVM模型(0.96~0.99)大于BP神经网络(0.56~0.64)。BP神经网络和SVM模型均能很好地预测施加生物炭的土壤水分,但SVM模型预测结果更加稳定,精度较高,更适于施加生物炭土壤水分的预测。该研究可为半干旱地区生物炭还田土壤水分的预测及管理提供理论依据。

关键词:土壤水分;生物炭;模型预测;SVM模型;BP神经网络

中图分类号:S152.7

文献标识码:A

文章编号:1005-3409(2017)03-0086-06

Applicability of BP Neural Network Model and SVM Model to Predicting Soil Moisture Under incorporation of Biochar into Soils

WANG Tongtong¹, ZHAI Junhai³, HE Huan⁴, ZHENG Jiyong^{1,2}, TU Chuan⁵

(1. College of Natural Resources and Environment, Northwest A&F University, Yangling, Shaanxi 712100, China; 2. State Key Laboratory of Soil Erosion and Dryland Farming on the Loess Plateau, Institute of Soil and Water Conservation, CAS & MWR, Yangling, Shaanxi 712100, China; 3. Agriculture Department of Shaanxi Province, Xi'an 710003, China; 4. College of Science, Northwest A&F University, Yangling, Shaanxi 712100, China; 5. College of Computer Science and Technology, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: As a soil amendment, biochar has a good effect on the soil moisture in the semi-arid area. In order to know the effect of adding biochar on soil water content prediction model, a district positioning experiment was carried out in semi-arid Guyuan ecology research station on the Loess Plateau. In the experiment, different kinds and amounts of biochar were added to soil and the soil water contents were monitored regularly. In consideration of soil water nonlinear characteristic and random effect of adding biochar, BP Neural Network model and SVM (Support Vector Machine) model were selected to build water content prediction model for biochar-added soil and the applicability of the two models were finally evaluated according to the measured data and predicted data by using RMSE, MRE, MAE and R^2 to assess the precision. The results showed that the average relative error value of BP Neural Network model was 3.78% and the max relative error value was 13.14%, while the average relative error value of SVM model was 0.56% and the max relative error value

was 2.42%, respectively. The RMSE, MRE, MAE value of SVM model(0.34~0.17, 0.07 and 0.56~1.27, respectively) were less than BP Neural Network model(1.04~1.16, 0.47~0.68 and 3.78~4.57 respectively), and the R^2 value of SVM model (0.96~0.99) were greater than BP Neural Network model (0.56~0.64), respectively. BP Neural Network model and SVM model both performed well in predicting soil water content and the prediction results of SVM model were more steady and precise. So the SVM model is the appropriate model to predict water content in biochar-added soil. The reuslt can provide theoretical evidence for prediction and management of moisture in the biochar-added soil in the semi-arid area.

Keywords: soil moisture; biochar; prediction model; SVM model; BP neural network model

土壤水分作为土壤的重要组成物质,同时也是影响土壤生产力的基本因素之一^[1],尤其在黄土高原干旱半干旱区域,土壤水分是生态农业建设的重要基础物质,也是决定该区生态系统结构和功能的关键因子^[2-3]。目前,国内外学者围绕着农田土壤水分转化与有效利用、土壤水分预测研究方面已做了大量的研究工作,土壤水分预测是农田水资源管理工作的基础,对于旱情预报有积极意义^[4-6]。土壤水分预测模型主要有:经验公式法、水量平衡法、土壤水动力学法、时间序列模型法、遥感监测法、人工神经网络、支持向量机等^[7-8]。其中,人工神经网络(ANNs)常用来模拟、处理影响因素多、关系复杂的系统,为高度非线性动态关系的时间序列预测提供了一条有效途径。人工神经网络固有的学习能力和适应能力,使其在土壤水分预测中得以应用^[9]。支持向量机(SVM)法对非线性函数可以精确逼近,具有全局最优、泛化能力强等优点,它在函数表达能力、推广能力和学习效率上都要优于传统的统计学方法,其在土壤水分预测方面已有相关报道^[10]。

生物炭(bio-char)是生物质在缺氧或无氧条件下经中高温热裂解得到的一类富含碳素的、稳定的、高度芳香化的固体产物^[11-13]。近年来,生物炭以其具有独特的结构和理化特性、丰富的材料来源被人们所关注,广泛应用于农业、环境和生态修复等领域^[14]。大量文献报道生物炭可以增大土壤对水的吸持能力,提高土壤田间持水量,减少土壤水的损失^[15-17]。施加生物炭对土壤水分有显著影响,而关于施加生物炭土壤水分预测模型

适用性却不多见。因此,本文以生物炭还田小区定位试验测定的水分数据为研究样本,考虑到土壤含水量的非线性特征以及施加生物炭的随机影响,选取 BP 神经网络和 SVM 支持向量机两种模型,预测施加生物炭土壤的水分,根据实测值评价模型优劣寻找最佳预测模型,以期为农田生态系统中生物炭改善土壤性能的适宜性评价提供一定的理论依据。

1 材料与方法

1.1 试验区概况

试验地点设在中国科学院固原生态试验站原州区站内的长期定位试验场(东经 106°26′—106°30′,北纬 35°59′—36°3′),属黄土高原宽谷梁状丘陵区。该区平均海拔 1 750 m,气候属温凉半干旱地带,冬春麦过渡区。年平均气温 6.2℃,最高月(7 月份)平均气温 18.9℃,最低月(1 月份)平均气温-8.3℃。极端最高气温 34.6℃,极端最低气温-28.1℃,>0℃积温 3 100℃,年均日照时数 2 518 h,年降雨量 472 mm,无霜期 152 d。土壤以黑垆土和壤黄土为主,植被由灌丛草原向半干旱典型草原过渡。

1.2 供试材料

本试验选取槐树皮、桐木锯末为原料制备生物炭。两种生物炭均由陕西亿鑫生物能源科技开发有限公司提供,生产时间为 2012 年 4 月,工艺流程为干燥除水—挤压成型—装釜加热至 550℃(6~8 h)—停火冷却。生物炭的基本理化性质见表 1。

表 1 生物炭的基本理化性质

类型	比表面积/ (m ² ·g ⁻¹)	pH	电导率/ (μS·cm ⁻¹)	阳离子交换量/ (cmol·kg ⁻¹)	有机质/ (g·kg ⁻¹)	全氮/ (g·kg ⁻¹)	硝态氮/ (mg·L ⁻¹)	铵态氮/ (mg·L ⁻¹)
锯末生物炭	0.0824	9.34	684.0	13.16	742.82	5.46	0.890	—
槐树皮生物炭	0.0949	9.52	808.0	20.14	866.25	8.77	1.140	—

注:“—”表示生物炭中不含铵态氮。

1.3 试验设计

锯末生物炭(JB)和槐树皮生物炭(HB)均设置 3 个添加比例(1%,3%,5%),共 6 个试验处理及 1 个空白对照(无生物炭添加),依次记为 1%JB、3%JB、5%

JB、1%HB、3%HB、5%HB 和 CK,重复 3 次。添加比例按照生物炭与土壤的质量百分比进行控制。共设 21 个试验小区,每个小区规格为 2.4 m×2.4 m。为消除系统误差,各小区采用完全随机区组设计,每个

小区内打钻布设 Trime-TDR 测管 1 个,以便利用时域反射仪(TDR)法监测地表以下 2 m 土层的土壤相对含水量。仪器为德国产 IMKO-PICO-BT。生物炭采用完全混合方式添加,即分别将表层 20 cm 深的土壤剥离,将生物炭按照设定的添加比例与剥离的土壤分别充分混合,然后将混合后的土壤回填到原位。所有小区于 2012 年 5 月底建设完毕,然后在自然条件下冻融干湿交替,不做其他干预处理,陈化 3 年,在 2015 年 1 月和 6 月初测定土壤水分。

2 水分预测模型构建

2.1 BP 神经网络模型

BP 神经网络因简单易行,准确度高的特点已经成为最常用的 ANNs 算法。BP(Back Propagation)神经网络是一种误差反向传播的多层前馈神经网络^[18]。它由输入层、隐含层和输出层组成,层与层之间多采用全互连接方式,同一层神经元之间不存在相互连接。BP 神经网络的实现步骤包括网络构建、训练和预测 3 步;可以利用 matlab 2014 中神经网络工具箱提供的 newff 函数、train 函数、sim 函数实现上述过程。本文采用 3 层神经网络,由于训练过程包含 5 个层面的土壤水分值,可确定输入层节点数(m)为 5,由期望输出维数可确定输出层节点数(n)为 1,隐含层可由经验公式 $l = \sqrt{m+n} + a$,其中 a 取属于 0~10 的整数,本文取隐含层节点数为 5。其他设置详见如下代码:

```
[x11,x12]=mapminmax(x1,0,1);
[y11,y12]=mapminmax(y1,0,1);
x21=mapminmax('apply',x2,x12);
net=newff(x11,y11,5,{'tansig','purelin'});
net.trainParam.epochs=100 000;
net.trainParam.lr=0.05;
net.trainParam.goal=0.000 01;
[net,tr]=train(net,x11,y11);
y=sim(net,x21);
yy=mapminmax('reverse',y,y12);
```

其中: $x1$ 为已知输入数据; $y1$ 为已知输出数据; $x2$ 为需要预测数据; yy 为预测输出结果。

将原始数据、训练样本、测试样本等作归一化处理,本文采用 mapminmax 函数将数据归一化到 [0,1]。训练过程每次选取 5 个土层深度的土壤水分值作为已知输入,紧接着的下个土层土壤水分值作为已知输出,迭代训练,构建网络。按照已定的学习算法和训练参数,用实际测量的土壤水分历史统计数据作为教师信号训练这个网络,使不同的输入向量得到相应的输出量。当计算输出值与教师信号之间的误差小于设定的允许值时,训练结束。通过实际训练得出网络的收敛曲线。训练完毕之后,保存训练好的 BP 神经网络结构和参数,将需要预测的样本输入网络,即可得出结果,并反归一化结果。综上,BP 神经网络的建模流程见图 1。

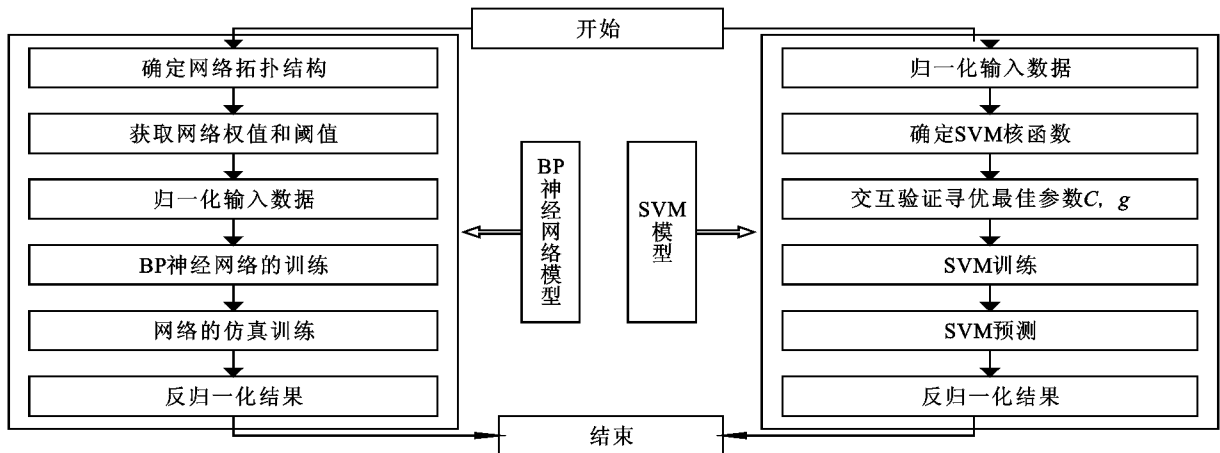


图 1 BP 神经网络和 SVM 模型的建模流程

2.2 SVM 模型

支持向量机(Support Vector Machine)是 Cortes 和 Vapnik 于 1995 年首先提出的,主要思想是建立一个分类超平面作为决策曲面,使得正例与反例之间的间隔最大化,不同于人工神经网络(ANNs)使用经验最小化准则,它使用结构风险最小化准则以及 VC 维数理论,这使得它在解决小样本、非线性及高维模式识别中表现出许多特有的优势^[19-21]。

支持向量机方法最初用来解决模式识别问题,在 1998 年 Vapnik 提出支持向量回归(SVR)方法用来解决函数拟合的问题^[22-23]。支持向量机从功能上分为分类和回归两类,本研究中土壤水分预测模型即以其回归功能为基础。控制支持向量机回归的参数主要有惩罚系数 C 、不灵敏损失函数 ϵ 、核函数类型和核函数参数。惩罚系数 C 越大,表示经验风险越小,即模型越复杂,泛化能力越差;惩罚系数 C 越小,模型

越简单,泛化能力增强,但可能以模型的模拟能力为代价^[23]。 ϵ 主要控制支持向量的个数, ϵ 越小,支持向量机个数越多,模型越复杂。已经有研究证明,与其他核函数相比,径向基核函数在土壤水分预测模型中效果更好^[24]。因此,文中选择径向基(RBF)作为核函数,其表达式为:

$$K(x_i, x) = \exp \left\{ -\frac{\|x - x_i\|^2}{2\sigma^2} \right\}$$

式中: σ 为核函数参数。

随着对 SVM 研究的深入,许多研究人员通过增加和改变函数项、变量或系数等方法使公式变形,产生出有某方面优势或一定应用范围的变形算法^[25]。LIBSVM 是台湾大学林智仁(Lin Chih-Jen)教授等开发设计的一个简单、易于使用和快速有效的 SVM 模式识别与回归的软件包,他不但提供了编译好的可在 Windows 系统的执行文件,还提供了源代码,方便改进、修改以及在其他操作系统上应用。该软件对 SVM 所涉及的参数调节相对比较少,提供了很多的默认参数,利用这些默认参数可以解决很多问题,并提供交互检验(Cross Validation)的功能^[26]。

LIBSVM 于 2011 年创建,最新版本为 3.21,更新于 2015 年 12 月 14 日。本文基于 matlab 2014,使用 libsvm-mat 工具包。关于 LIBSVM 更详细的介绍与参数学习,可以访问网址^[27]。本文通过 libsvm-mat 的网格参数寻优函数的调用,对惩罚系数 C 和核函数系数 g 进行最优值寻找,其中 C, g 值的搜索范围设置为 $10^{-5} \sim 10^5$,迭代步长设为 0.5。原始数据的输入、训练过程和测试样本与 BP 神经网络的设置相同。综上,SVM 的建模流程见图 1。

3 结果与分析

3.1 BP 神经网络和 SVM 模型对施加生物炭土壤水分预测

本文选择 2015 年 1 月份采样数据,作为样本,进行仿真训练,预测深层土壤水分,以每个处理的 0—

180 cm 土层监测的土壤水分数据作为训练集,预测 190 cm 和 200 cm 处土壤含水量(单位 %),以期对比分析两种模型对于施加生物炭土壤的水分预测适用性研究。以 CK 处理为代表,来说明两种模型的预测过程,其他试验处理预测过程类似;图 2 为 BP 神经网络模型均方误差变化曲线,图 3 为 SVM 模型参数 C, g 寻优等高线图。表 2 为两种模型预测结果,其中相对误差正值说明预测值大于实测值,负值说明预测值小于实测值。

从图 2 可以看出,CK 处理的 BP 神经网络模型经过 17 步仿真,训练、测试和验证数据均达到设定的目标值以下,最佳验证集均方误差为 3.2437×10^{-5} ,网络训练由于检验集均方误差达到极小值而结束。从图 3 可以看出,CK 处理的 SVM 模型参数 C, g 寻找范围为 0~10,经过网格寻优得到最佳的参数 $C=1.8661, g=3.249$,输出拟合精度为 98.88%;其他处理的参数寻优结果见表 2。由此可知,不论 BP 神经网络还是 SVM 模型,输出误差基本趋向稳定,模型收敛性好,均达到最佳训练效果。




图 2 BP 神经网络均方误差变化曲线




图 3 SVM 模型参数寻优结果

表 2 BP 神经网络和 SVM 模型预测结果

处理	原始数据		BP 神经网络				SVM 模型					
	190 cm	200 cm	190 cm	相对误差/%	200 cm	相对误差/%	参数 C	参数 g	190 cm	相对误差/%	200 cm	相对误差/%
CK	24.45	24.28	24.0400	-1.68	22.5317	-7.20	1.9	3.2	24.4050	-0.18	24.4274	0.61
1%Jb	19.12	18.15	21.6315	13.14	18.5062	1.96	0.7	0.2	18.7335	-2.02	18.5889	2.42
3%Jb	22.01	21.78	21.3622	-2.94	22.3293	2.52	0.9	0.1	21.9235	-0.39	21.8759	0.44
5%Jb	22.62	22.58	23.6307	4.47	22.7801	0.89	46.3	0.1	22.6125	-0.03	22.5874	0.03
1%Hb	21.35	20.91	21.4825	0.62	19.7203	-5.69	28.7	0.1	21.3072	-0.20	21.0079	0.47
3%Hb	22.7	22.56	23.7653	4.69	22.0256	-2.37	0.7	0.2	22.6215	-0.35	22.6025	0.19
5%Hb	23.99	23.85	23.1953	-3.31	24.2062	1.49	6.1	0.1	23.9356	-0.23	23.9066	0.24

分析表 2 可知,BP 神经网络对 7 种处理预测值相对误差的绝对值最大为 13.14%,最小为 0.62%,平均相对误差为 3.78%,说明 BP 神经网络能够较好地预测施加生物炭土壤的深层水分。SVM 模型对 190 cm 土层深度的土壤水分预测均低于实测值,而对 200 cm 土层深度的土壤水分预测均高于实测值;对 7 种处理预测值相对误差的绝对值最大为 2.42%,最小为 0.03%,平均相对误差为 0.56%,说明 SVM 模型能够很好地预测施加生物炭土壤的深层水分。对比 BP 神经网络和 SVM 模型的预测结果,可以明显看出,BP 神经网络预测的相对误差较 SVM 模型较大。且 BP 神经网络模型对同一处理或同一深度预测结果较为不稳定,波动较大,故而造成较大的预测偏差;而 SVM 模型对同一深度预测结果相对误差同为负(190 cm)或正(200 cm),对相同处理的预测结果偏于稳定,波动较小,据此可以得知,对于施加生物炭土壤的深层水分预测,SVM 模型要稍好于 BP 神经网络模型。

3.2 土壤水分预测模型对比

模拟 2015 年 6 月份土壤 190 cm 和 200 cm 深处的土壤水分数据,将 1 月和 6 月份数据整合,对比分析 SVM 模型和 BP 神经网络模型的预测结果,见图 4。从大量数据统计显示,SVM 模型预测结果更靠近真实值直线,而 BP 神经网络模型预测结果较真实值直线偏离,这说明 SVM 模型预测结果优于 BP 神经网络,更适于施加生物炭土壤水分的预测研究。




图 4 BP 神经网络和 SVM 模型预测结果对比

使用均方根误差(RMSE)、平均相对误差(MRE)、平均绝对误差(MAE)、决定系数(R^2)来衡量两种预测模型的精度,见表 3。RMSE, MRE 和 MAE 均反映了预测数据偏离真实值的程度,其值越小,表示预测精度越高;因此可以明显看出,无论 1 月份或 6 月份取样数据,SVM 模型的 RMSE, MRE 和 MAE 值比 BP 神经网络的值小,说明 SVM 模型预测精度明显高于 BP 神经网络模型。决定系数(R^2)越趋向于 1,表明自变量对因变量的解释程度越高^[28];以真实值为 x 轴,预测值为 y 轴,当 R^2 越趋向于 1,

方程 $y=x$ 参考价值越高,表明预测值越趋向于真实值,因此可以明显看出,SVM 模型的 R^2 都在 0.9 以上,BP 神经网络模型的 R^2 都在 0.6 左右,说明 SVM 模型的拟合优度更好。SVM 模型更适合施加生物炭土壤水分的预测。

表 3 BP 神经网络和 SVM 模型的误差指标分析

时间 (年-月)	模型	RMSE	MRE/%	MAE/%	R^2
2015-01	BP	1.036957	0.47	3.78	0.64
	SVM	0.170735	0.07	0.56	0.99
2015-06	BP	1.163576	0.68	4.57	0.56
	SVM	0.339417	0.07	1.27	0.96

4 讨论

从上述两种模型预测结果分析来看,BP 神经网络和 SVM 模型均能很好地应用于施加生物炭土壤的水分预测。针对 BP 神经网络模型,尹健康等^[9]利用 BP 人工神经网络,建立土壤水分预测模型应用于烟田土壤,预测效果良好,平均相对误差为 9%左右;而本研究将该模型应用于施加生物炭的土壤水分预测,平均相对误差为 3.78%左右,亦取得良好的预测效果。从 SVM 模型角度分析,本研究在 SVM 模型的基础理论上,对惩罚系数 C 和核函数系数 g 进行寻优处理后模拟,得到应用于施加生物炭土壤的水分预测模型,平均相对误差为 0.56%且数值预测稳定,得到良好的预测结果,这与张强^[10],丁铁山^[24],Gill^[29]等利用 SVM 模型,直接建立土壤水分预测模型,预测非施加生物炭土壤水分,精度较高,结果相互一致。

然而,SVM 模型比 BP 神经网络更加稳定,精度较高,分析形成差异的原因,聂春燕等^[30]对比了支持向量机和神经网络模型对土壤水力学参数的预测效果,认为样本量和输入参数数量对预测效果影响很大,尤其是样本量,在相同条件下,支持向量机模型预测效果优于神经网络模型,这与本文研究结果一致。笔者主要认为:从理论基础分析,支持向量机比人工神经网络模型更具有优势;因为支持向量机从严格的数学理论出发,论证和实现了在小样本情况下最大限度地提高预测的可靠性,得到全局最优解,有效避免了神经网络易陷入的局部极值问题。同时,在实际应用过程中,支持向量机不需要过多的先验信息和使用技巧,而人工神经网络方法往往需要过多的使用技巧和大量的样本数据才能得出比较满意的结果。

5 结论

本文通过生物炭还田小区定位试验,选取 BP 神

神经网络和SVM模型,建立施加生物炭的土壤水分预测模型,探究模型适用性研究,得出如下结论:

(1) BP神经网络预测值的平均相对误差为3.78%,最大误差为13.14%;SVM模型的平均相对误差为0.56%,最大误差为2.42%。不受施加生物炭类型和添加比例的影响,BP神经网络和SVM模型都能很好地预测土壤水分。

(2) SVM模型的RMSE、MRE、MAE值均小于BP神经网络的,且决定系数 R^2 值SVM模型大于BP神经网络。SVM模型预测结果更加稳定,精度较高,更适于施加生物炭土壤水分的预测研究。

参考文献:

- [1] 傅伯杰,杨志坚,王仰麟,等.黄土丘陵坡地土壤水分空间分布数学模型[J].中国科学:D辑,2001,31(3):185-191.
- [2] 白天路,杨勤科,申佳.黄土高原丘陵沟壑小流域土壤水分垂直分布变异特征及影响因子[J].生态学杂志,2009(12):2508-2514.
- [3] 刘志鹏,邵明安.黄土高原小流域土壤水分及全氮的垂直变异[J].农业工程学报,2010,26(5):71-77.
- [4] 李光,应杰,刘长荣.土壤水分预测模型的研究[J].南水北调与水利科技,2010,8(4):95-98.
- [5] 刘洪斌,武伟,魏朝富,等.土壤水分预测神经网络模型和时间序列模型比较研究[J].农业工程学报,2003,19(4):33-36.
- [6] Downer C W, Ogden F L. Prediction of runoff and soil moistures at the watershed scale: Effects of model complexity and parameter assignment[J]. Water Resources Research, 2003,39(3):276-290.
- [7] 陈天华,唐海涛.基于ARM和GPRS的远程土壤墒情监测预报系统[J].农业工程学报,2012,28(3):162-166.
- [8] 许秀英,衣淑娟,黄操军.土壤含水量预报现状综述[J].农机化研究,2013,35(7):11-15.
- [9] 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.
- [10] 张强,黄生志,陈晓宏.基于支持向量机的土壤湿度模拟及预测研究[J].土壤学报,2013,50(001):59-67.
- [11] Marris E. Putting the carbon back: Black is the new green[J]. Nature,2006,442(7103):624-626.
- [12] Shrestha G, Traina S J, Swanston C W. Black carbon's properties and role in the environment: a comprehensive review[J]. Sustainability, 2010,2(1):294-320.
- [13] Ahmad M, Rajapaksha A U, Lim J E, et al. Biochar as a sorbent for contaminant management in soil and water: A review[J]. Chemosphere, 2014,99(3):19-33.
- [14] 陈温福,张伟明,孟军.生物炭与农业环境研究回顾与展望[J].农业环境科学学报,2014,33(5):821-828.
- [15] 王丹丹,郑纪勇,颜永毫,等.生物炭对宁南山区土壤持水性影响的定位研究[J].水土保持学报,2013,27(2):101-104.
- [16] Karhu K, Mattila T, Bergström I, et al. Biochar addition to agricultural soil increased CH₄ uptake and water holding capacity: Results from a short-term pilot field study[J]. Agriculture, Ecosystems & Environment, 2011,140(1):309-313.
- [17] Basso A S, Miguez F E, Laird D A, et al. Assessing potential of biochar for increasing water-holding capacity of sandy soils[J]. Gcb Bioenergy, 2013, 5(2): 132-143.
- [18] 王彤彤,张剑,涂川,等. IPSO-BP神经网络在渭河天水段水质评价中的应用[J].环境科学与技术,2013,36(8):175-181.
- [19] Guyon I, Weston J, Barnhill S, et al. Gene selection for cancer classification using support vector machines[J]. Machine Learning,2002,46(1/3):389-422.
- [20] Support vector machines: theory and applications[M]. Springer Science & Business Media, 2005.
- [21] Shahraiyini H, Ghafouri M, Shouraki S, et al. Comparison between active learning method and support vector machine for runoff modeling[J]. Journal of Hydrology and Hydromechanics,2012,60(1):16-32.
- [22] Brereton R G, Lloyd G R. Support vector machines for classification and regression[J]. Analyst, 2010, 135(2): 230-267.
- [23] 张兰影,庞博,徐宗学,等.基于支持向量机的石羊河流域径流模拟适用性评价[J].干旱区资源与环境,2013,27(7):113-118.
- [24] 丁铁山,董汝瑞,温季.基于支持向量机理论的土壤水分预测模型研究[J].人民黄河,2011,33(3):68-73.
- [25] 王慧勤,雷刚.基于LIBSVM的风速预测方法研究[J].科学技术与工程,2011,11(22):5440-5442.
- [26] Chang C C, Lin C J. LIBSVM: a library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology,2011,2(3):389-396.
- [27] Chih-Chung Chang and Chih-Jen Lin. LIBSVM -A Library for Support Vector Machines [EB/OL]. <http://www.csie.ntu.edu.tw/~cjlin/libsvm/index.html>, 2015-12-14.
- [28] 王彤彤,吴旺旺,张小平,等.甘肃省能源利用碳足迹估算与分析[J].湖北农业科学,2016,55(2):349-353.
- [29] Gill M K, Asefa T, Kembrowski M W, et al. Soil moisture prediction using support vector machines1[J]. Journal of the American Water Resources Association,2006,42(4):1033-1046.
- [30] 聂春燕,胡克林,邵元海,等.基于支持向量机和神经网络的土壤水力学参数预测效果比较[J].中国农业大学学报,2010(6):102-107.