

贝叶斯模型在土壤转换函数中的应用与适应性评价*

张娜¹ 屈忠义¹ 杨晓¹ 付小军²

(1. 内蒙古农业大学水利与土木建筑工程学院, 呼和浩特 010018;
2. 内蒙古河套灌区解放闸灌域管理局沙壕渠试验站, 杭锦后旗 015400)

摘要: 为了研究大型灌区节水改造后的区域农田生态环境效应中分布式水文模型空间参数的确定问题,通过内蒙古河套灌区解放闸灌域 22 个土壤水盐监测点 110 个土壤样本的采样与分析,利用贝叶斯神经网络(BNN)模型建立了河套灌区区域分层土壤特征参数与土壤水分特征曲线模型参数、特征含水率之间的土壤转换函数模型,并与已有的 BP 神经网络模型进行适应性比较及模型验证。结果表明,BP 模型土壤转换函数的训练模拟精度优于 BNN,但是在模拟预测方面,BNN 模型普遍好于 BP 模型,而且模型输入因子数量对 BP 模型的精度影响较大,而 BNN 模型对于不同输入因子表现出很好的稳健性,BNN 模型比传统的人工神经网络模型具有更好的适应性和预测效果,体现了土壤特征参数的空间随机性和结构性特征,而且预测的土壤水分特征曲线与实测和 VG 拟合结果更为接近,是一种具有广阔应用前景的区域土壤转换函数推求方法。

关键词: 贝叶斯神经网络 河套灌区 土壤转换函数 适应性

中图分类号: S271 **文献标识码:** A **文章编号:** 1000-1298(2014)02-0149-07

引言

在大区域多尺度的模型模拟研究中,由于土壤自身所具有的高度时空变异性 and 随机性特征,研究区域性问题时,必然涉及到大量取样测试的问题,这不仅耗费大量的时间,而且花费大量的人力、物力和财力,给参数的合理确定带来了极大的挑战。建立一个合理的采样规则和推求不同尺度土壤水力特征参数,已经成为目前国内外研究关注的热点问题之一^[1-5]。目前在区域土壤水力参数推求中研究最广泛的是进行各种土壤转换函数的研究,多元回归分析、人工神经网络及分形方法都在土壤转换函数中得到较为成功的应用^[2,6-12],这些方法在保证研究精度的基础上,很大程度上减少了田间实验工作量,但也存在不同程度的局限性,如 BP 神经网络的主要缺陷是过度训练及缺少不确定性估计^[2,4,13],致使 BP 模型得出的确定性最优权值不一定合适。而贝叶斯神经网络训练(BNN)给出的是一个权值的范围,这样的预测模型得到的是一个预测范围,同时应用马尔可夫链蒙特卡罗模拟技术减少训练局部最小的概率,可避免过度训练问题。即 BNN 既融合了传统神经网络的优点,同时又消除了它本身的不足,被

认为是神经网络的又一次革命^[2]。所以 BNN 在土壤转换函数中的应用是一个新的突破,而且已经成功建立了多尺度下的土壤转换函数,提供了参数尺度转换的新方法^[2,4],但在国内关于这种方法的应用仍然较少。

为了确定河套灌区区域农田水盐变化及节水工程实施后的节水环境效应,本文以内蒙古河套灌区解放闸灌域为研究区域,通过 22 个土壤水盐监测点 110 个土壤样本的采样与分析,利用 BNN 模型建立河套灌区区域分层土壤特征参数与土壤水分特征曲线模型参数、特征含水率之间的土壤转换函数模型,并与已有的 BP 神经网络模型进行适应性比较及模型验证,期望寻求一种区域土壤参数估计方法。

1 材料与方法

1.1 实验区域及采样

解放闸灌域位于河套灌区西部,南临黄河,北依阴山,西与乌兰布和沙漠、一干灌域接壤,东与永济渠灌域毗邻,灌域用户涉及杭锦后旗、临河市、乌拉特后旗、乌拉特中旗、磴口县、伊盟杭锦旗 6 个旗(县)市的 38 个乡镇(苏木)及巴盟农管局的一个农场。灌域南北长约 87 km,东西宽约 78 km,呈三角

收稿日期: 2013-03-05 修回日期: 2013-07-11

* 国家自然科学基金资助项目(51069006)和内蒙古自治区高等学校青年科技英才支持计划资助项目(NJYT-12-A05)

作者简介: 张娜,博士生,主要从事土壤参数尺度转换技术研究,E-mail: 710840895@qq.com

通讯作者: 屈忠义,教授,博士生导师,主要从事区域土壤水环境与节水灌溉理论研究,E-mail: quzhongyi68@sohu.com

形状,地形是西南高,东北低,海拔高程为 1 032 ~ 1 050 m。解放闸灌域总控制面积 $2.1568 \times 10^5 \text{ hm}^2$,灌溉面积 $1.421 \times 10^5 \text{ hm}^2$,其中耕地 $1.2193 \times 10^5 \text{ hm}^2$,林果地面积 $5.507 \times 10^3 \text{ hm}^2$,牧草地面积 $1.461 \times 10^4 \text{ hm}^2$ 。选择灌域内 22 个具有代表性的土壤水盐、地下水长期监测点,进行土壤采样。每个监测点挖 1 m 深剖面,分为 5 个土壤层 0 ~ 10、10 ~ 20、20 ~ 40、40 ~ 70 和 70 ~ 100 cm。每层土样用环刀(50 或 100 cm^3)采原状土,供室内测定土壤容积密度、孔隙度及水分特征曲线,并散装 500 g 土壤供室内其他实验。运用筛析法和比重计法对所取土样进行土壤颗粒分析实验,并按照国际制土壤分类方法对各土壤试样进行分类定名。参照 NY/T 85—1988《土壤有机质测定法》测定有机质,用压力膜仪对原状土样进行土壤水分特征曲线的测定(测定范围 0 ~ 1.5 MPa)。土壤饱和含水率 θ_s 利用环刀法直接测定,当压力膜仪压力为 1.5 MPa 时测定的土壤含水率为剩余含水率 θ_r 。于 $3 \times 10^4 \text{ Pa}$ 压力所对应的土壤含水率为田间持水率 θ_f 。



图 1 研究区土壤采样位置示意图

Fig. 1 Soil sampling location in research area

根据解放闸灌域土样颗粒分析结果,通过土壤质地自动分类软件(TAL for Windows 4.2)确定土层的土壤质地资料,得出解放闸灌区土壤类型有 9 类(表 1),其中以壤土类为主,土壤质地呈现出以下特征:上游区域以粉砂质粘壤土、壤土和粘壤土居多,中游区域以粘壤土为主,下游区域是壤质粘土。粘粒土壤的颗粒直径小于 0.002 mm,粉粒土壤的颗粒直径范围为(0.002 mm,0.02 mm],砂粒土壤的颗粒直径范围为[0.02 mm,2 mm]。上、中、下游的 22 个点土样的 0 ~ 40 cm 土层中(0 ~ 70 cm 为土壤耕作层):上游以粉砂质粘壤土和粘壤土为主,占上游土

壤比例超过 70%,中游土壤质地以粘壤土为主,占中游土壤比例大于 65%,下游土壤质地以壤质粘土和粘壤土为主。

表 1 9 类土壤的平均颗粒组成统计
Tab.1 Average particle composition of nine kinds of soil textures

土壤质地	土样数	粘粒质量 分数/%	粉粒质量 分数/%	砂粒质量 分数/%
粉砂质壤土	7	11	56	33
粉砂质粘壤土	20	21	52	27
粉砂质粘土	13	26	51	23
壤质粘土	16	31	42	27
壤土	11	10	41	49
粘壤土	28	19	40	41
粘土	1	50	37	13
砂质壤土	10	8	22	70
壤砂土	4	6	10	84
合计	110			

1.2 水分特征曲线模型及参数估计

利用室内压力膜仪(USA)测定 110 个原状土样土壤水分特征曲线,采用 van Genuchten 水分特征曲线模型(VG 模型),应用 RETC 软件拟合模型参数。VG 模型描述为

$$\theta(h) = \theta_r + \frac{\theta_s - \theta_r}{(1 + |\alpha h|^n)^m}$$
 (1)

其中 $m = 1 - 1/n$
式中 $\theta(h)$ ——土壤体积含水率, cm^3/cm^3
 α, n ——形状参数 h ——压力水头

利用以上模型,结合水分特征曲线测试结果,已知 θ_s, θ_r 及不同水吸力下的含水率,利用 RETC 软件进行模型曲线拟合,求得不同土样的 VG 模型参数。

1.3 贝叶斯神经网络

目前已有的神经网络 PTFs 不能够解释不同尺度下土壤水力参数空间变异性的物理过程,传统的神经网络模型是通过输入、输出数据的误差控制而实现的,其输入输出关系可以表示为

$$y = f(x|w) + E$$
 (2)

式中 $f(x|w)$ ——近似函数 E ——误差项
 w ——神经网络层的权值和阈值矢量

传统的神经网络就是通过最小误差的寻求获得一个确定的权值和阈值。而 BNN 对于网络层的权值和阈值给出的是一个概率分布范围,根据 Bayes' 理论

$$P(w|Y,X) = \frac{P(Y|w,X)P(w)}{P(Y|X)}$$
 (3)

其中 $X = (x_1, x_2, \dots, x_n)$ $Y = (y_1, y_2, \dots, y_n)$
式中 X ——输入矢量 Y ——目标矢量

$P(Y|X) = \int P(Y|w,X)P(w)dw$ 是目标输出

矢量 y_i 的边际分布。 $P(\boldsymbol{w})$ 是权值 $\boldsymbol{w}$ 的一个先验分布, 而 $P(\boldsymbol{Y}|\boldsymbol{w}, \boldsymbol{X})$ 是似然函数。 边际分布是一个比例常数, 而且是一个正则化的常数。 权值 $\boldsymbol{w}$ 的先验分布是事先给定的一个值。 根据 Kingston 等^[3] 所描述的 y_{n+1} 的预测性分布为

$$P(y_{n+1}|x_{n+1}, \boldsymbol{Y}, \boldsymbol{X}) = \int P(y_{n+1}|x_{n+1}, \boldsymbol{w}) P(\boldsymbol{w}|\boldsymbol{Y}, \boldsymbol{X}) d\boldsymbol{w} \quad (4)$$

式中下标 $n+1$ 表示一组新的输入输出变量的集合。 式(4)中的积分无法用传统的解析或数值积分的方法求得。

MCMC 方法主要是从一个连续的目标密度集合中产生多个样本^[14], 在多层神经网络中, 先验权值的分布一般是非常复杂的。 由于从复杂的先验权值分布中直接提取样本是困难的, 所以使用一个更为简单的对称分布来产生权值矢量。 这就是所谓的建议分布, 认为它是一个局部高斯函数。 在马尔可夫链随机移动的实现过程中, 这个建议分布取决于前面的权值, 首先从先验分布中的任意选取权值 $\boldsymbol{w}$, 这样一系列的权值就可以通过马尔可夫链来确定。 而且这些选取的值应该满足

$$\alpha = \min \left\{ 1, \frac{P(y|\boldsymbol{X}, \boldsymbol{w}^*) P(\boldsymbol{w}^*)}{P(y|\boldsymbol{X}, \boldsymbol{w}_{prev}) P(\boldsymbol{w}_{prev})} \right\} \quad (5)$$

式中 $\boldsymbol{w}_{prev}$ ——前一次迭代的权值
 α ——建议分布

如果通过马尔可夫链确定的新权值 $\boldsymbol{w}^*$ 被接受, 那么 $\boldsymbol{w}_{prev}$ 就被 $\boldsymbol{w}^*$ 替代, 开始下一次的迭代。 而权值被接受率在 30% ~ 70% 之间被认为是最优的^[14]。 这样, 通过足够量次的迭代就可以确保马尔可夫链收敛于一个稳定的分布。 贝叶斯方法可以通过定义一些超参数的模糊先验来控制模型参数复杂性, 并且可对任何感兴趣的变量产生后验预测分布, 使得置信区间的计算成为可能^[14-15]。 贝叶斯神经网络的建模预测问题, 是通过融入模型参数的先验知识, 在给定数据样本及模型假设下进行后验概率的贝叶斯推理, 使用马尔可夫链蒙特卡罗算法来优化模型控制参数, 实现了对神经网络模型中不同部分复杂度的控制, 获得了模型参数的后验分布及预测分布, 而正则化方法则是用于提高神经网络泛化能力的一种方法。

1.4 神经网络土壤转换函数的结构设计

BNN 模型和 BP 模型的基本结构都是一致的, 只不过是模型参数确定(权值、阈值)上有不同的方法。 由于论文篇幅的限制, 关于模型结构参数选取过程不再详述。 模型结构均确定为 3 层网络模型。 模型根据不同输入因子分成 3 组: ①粘粒、粉

粒、砂粒质量分数, 简称 SSC。 ②粘粒、粉粒、砂粒质量分数和容积密度, 简称 SSC + BD。 ③粘粒、粉粒、砂粒质量分数、容积密度和有机质质量分数, 简称 SSC + BD + OM。

输出分别为 $\theta_r, \theta_s, \theta_f, \alpha$ 和 n 。

所有模型输入、输出数据都要进行归一化处理, 使绝对值位于 $[0, 1]$ 。 网络的激励函数分别选用 logsig、tansig、pureline。 其他参数根据经验和试算结果比较确定。 模型计算参照文献[15]中作者编制的基于 Matlab 2009 版本的 BP 和 BNN 程序进行模拟建模。 通过模型参数的遴选与模拟、检验结果的比较, 最终确定一个相对合理的参数, 作为最终模型的结构, 然后可以进行 2 种方法优劣的比较。 对解放闸区域 22 个土壤采样点、5 层共 110 个点的采样数据进行模拟训练及检验, 为了体现模型预测结果的空间特性, 选取浅层的 3 层土壤 66 个土样数据作为模型训练数据, 而深层的 2 层土壤 44 个土样数据为模型检验数据。 这样建模可以实现用浅层土壤易于观测的数据来预测深层土壤参数, 从而减少深层取样测试的工作量。

2 结果与讨论

2.1 土壤特征含水率的模拟与检验

土壤特征含水率($\theta_r, \theta_s, \theta_f$)是反映土壤质地特征的重要物理水力学参数, 也是众多水文模型中必须的输入参数, 利用土壤基本特性参数建立二者之间的土壤转换函数模型, 可以提供一种确定特征含水率的简洁方法。 根据上述两种神经网络模型方法的训练模拟结果(图 2): 发现 BP 模型(输入变量为 SSC + BD + OM)的模拟训练结果较 BNN 模型(输入变量为 SSC)好, 这主要是由于两种神经网络模型参数确定方法和误差检验标准的差异而造成的。 而且随着输入因子数量的增加, BP 模型的训练模拟误差进一步减小, 但是这种训练模拟精度的提高是通过牺牲检验精度而实现的^[13]。 由于 BNN 模型给出的权值和阈值是一个范围, 所以模拟训练结果对应的也是一个范围, 即只要模型输出的最大值、最小值区间包含实测值, 即认为模拟结果满足要求。 BNN 模型对土壤特征含水率的模拟结果虽较 BP 模型较差, 但一定范围内可包含实测值。

从模型检验结果看(表 2、3), BP 模型的模拟检验结果精度与模型输入因子数量关系密切, 随着输入因子数量的增加, 模型检验精度逐步提高。 BNN 模型给出的预测结果是一个范围, 本文选取预测范围的平均值进行统计分析。 发现虽然 BNN 模型模拟训练精度略逊于 BP 模型, 但是模型的检验结果




图2 模型模拟训练结果对比

Fig.2 Contrast of simulated results

总体上好于 BP 模型,而且多数模型只用土壤颗粒含量作为输入因子,即可达到较高精度,对于不同输入因子表现出很好的稳健性,从它们的统计结果可以看出,在对饱和含水率(田间持水率)的预测中,BNN 模型在只将 SSC 作为输入时,其多项统计结果已比 BP 模型在 SSC + BD + OM 作为输入时更接近实测值。在剩余含水率的预测中,BNN 的优势虽没

有饱和含水率大,但是在同等输入条件下,平均值、求和指标 BNN 模型的效果更好。由于 BNN 的检验样本预测结果选取预测范围的均值进行统计分析,所以标准差及方差总体较小,而且预测范围不及 BP 模型分散,所以最大值最小值的统计结果 BP 模型更好。说明 BNN 模型具有很好的模拟预测能力,这就为简化模型、减少土壤分析工作量提供了极大便利。

表 2 模型预测统计结果对比(饱和含水率)

Tab.2 Statistical results contrast for water content of saturated soil (θ_s) g/g

项目	BP 模型输入变量			BNN 模型输入变量			实测值
	SSC	SSC + BD	SSC + BD + OM	SSC	SSC + BD	SSC + BD + OM	
平均	0.497	0.494	0.505	0.509	0.520	0.520	0.524
标准差	0.043	0.053	0.063	0.039	0.040	0.046	0.043
方差	0.002	0.003	0.004	0.002	0.002	0.002	0.002
最小值	0.394	0.343	0.392	0.440	0.455	0.399	0.447
最大值	0.601	0.621	0.663	0.546	0.632	0.598	0.621
求和	21.848	21.727	22.236	22.409	22.877	22.839	23.069

表 3 模型预测统计结果对比(剩余含水率)

Tab.3 Statistical results contrast for residual water content (θ_r) g/g

项目	BP 模型输入变量			BNN 模型输入变量			实测值
	SSC	SSC + BD	SSC + BD + OM	SSC	SSC + BD	SSC + BD + OM	
平均	0.221	0.239	0.217	0.221	0.228	0.214	0.212
标准差	0.081	0.079	0.090	0.039	0.069	0.067	0.106
方差	0.006	0.006	0.008	0.002	0.005	0.005	0.011
最小值	0.045	0.069	0.032	0.046	0.142	0.056	0.011
最大值	0.367	0.541	0.420	0.267	0.426	0.368	0.372
求和	9.732	10.517	9.535	9.726	10.020	9.199	9.308

从两种模型的训练及检验过程可知:虽然 BP 模型及 BNN 模型均可得到较为满意的结果,但是 BP 模型要在不断调整其网络结构,如网络层数、学习速率、激励函数等基础上才有可能消除其由于网络结构过于复杂造成的过拟合问题,而 BNN 模型自身就可回避这个问题;而且 BP 模型权值和阈值最后的确定完全依赖于输入因子,不同的训练数据必然会导致不同的权值和阈值,只有假设可以得到一个足够大的数据样本,那么,就可以假定

获得的最佳权重对整个数据整体是具有代表性的。然而,这是几乎不可能的情况,而 BNN 因为其得出的结果是一个分布区间,而不是一个单一的值,这样,可以明显地反映预测的不确定性。可见,在区域土壤转换函数中 BNN 模型的应用更加简易。

2.2 水分特征曲线模型参数模拟与检验

水分特征曲线参数 α 、 n 的预测结果(表 4、5)与特征含水率具有相似的结果,从二者的统计结果可

以看出: BNN 模型的预测结果(选取预测范围的均值)较 BP 模型更为接近观测值。BP 模型的统计结果随着输入因子的增加,逐渐与观测值的统计结果呈现出一致性,而 BNN 模型的 3 种输入变量模型预测结果差异不大,从统计结果看:在 BNN 模型只将

SSC 作为输入时,其结果已更为接近观测值。BNN 模型对参数 α 、 n 的预测结果的平均值、求和等较 BP 模型的结果更接近于观测值,在实际应用中可以直接使用土壤颗粒组成作为输入建模,这样可以减少化验、分析的工作量和费用。

表 4 VG 模型参数 α 统计结果对比
Tab. 4 Contrast of statistical results of parameter α

项目	BP 模型输入变量			BNN 模型输入变量			实测值
	SSC	SSC + BD	SSC + BD + OM	SSC	SSC + BD	SSC + BD + OM	
平均	0. 026	0. 040	0. 041	0. 029	0. 029	0. 028	0. 032
标准差	0. 028	0. 075	0. 046	0. 017	0. 006	0. 010	0. 053
方差	0. 001	0. 006	0. 002	0	0	0	0. 003
最小值	0	0. 001	0	0. 013	0. 024	0. 006	0. 001
最大值	0. 149	0. 399	0. 209	0. 097	0. 046	0. 058	0. 179
求和	1. 141	1. 780	1. 803	1. 292	1. 294	1. 233	1. 400

表 5 VG 模型参数 n 统计结果对比
Tab. 5 Contrast of statistical results of parameter n

项目	BP 模型输入变量			BNN 模型输入变量			实测值
	SSC	SSC + BD	SSC + BD + OM	SSC	SSC + BD	SSC + BD + OM	
平均	1. 290	1. 244	1. 259	1. 227	1. 284	1. 228	1. 226
标准差	0. 241	0. 159	0. 231	0. 031	0. 142	0. 247	0. 129
方差	0. 058	0. 025	0. 054	0. 001	0. 020	0. 061	0. 017
最小值	1. 056	1. 004	0. 913	1. 155	1. 027	1. 012	1. 002
最大值	2. 063	1. 787	1. 956	1. 269	1. 701	2. 411	1. 611
求和	56. 765	54. 727	55. 408	53. 975	56. 513	54. 017	53. 943

对于两种神经网络模型检验样本的进一步比较结果(表 6)可知:对于特征含水率(θ_r 、 θ_s 、 θ_f)及水分特征曲线参数(α 、 n),BNN 模型的误差整体上小于 BP 模型,说明在模拟预测方面,BNN 模型要优于 BP 模型,BP 模型的误差随着输入因子的增加而减小,

即 BP 模型的精度是以较多输入因子为前提的,而 BNN 模型的误差随输入因子的增加变化不大,且在只将 SSC 作为输入时,其精度已达到甚至优于 BP 模型将 SSC + BD + OM 作为输入时。可见 BNN 模型在数据预测方面的优越性。

表 6 模型预测标准误差统计
Tab. 6 Error statistics of predicted results

参数	BP 模型输入变量			BNN 模型输入变量		
	SSC	SSC + BD	SSC + BD + OM	SSC	SSC + BD	SSC + BD + OM
θ_r	0. 103 0	0. 083 2	0. 080 8	0. 081 9	0. 080 4	0. 082 1
θ_s	0. 053 2	0. 043 2	0. 043 4	0. 043 4	0. 040 4	0. 043 3
θ_f	0. 048 3	0. 043 9	0. 042 1	0. 043 3	0. 048 7	0. 043 1
α	0. 053 6	0. 053 9	0. 053 1	0. 052 1	0. 047 0	0. 049 9
n	0. 220 0	0. 212 6	0. 216 6	0. 211 4	0. 219 9	0. 217 1

2.3 SWRC 模型比较验证

将不同输入因子下两种模型的预测结果通过 RETC 软件绘制其不同土壤质地的水分特征曲线图(图 3),可以看出,各种模型的预测结果与前面的统计结果是一致的,BP 模型预测的 SWRC 曲线区间总体上随着输入因子的增加而逐步趋于接近实测的 SWRC 点,可以说明,在应用 BP 模型进行

SWRC 曲线预测时,建议最好使用 SSC + BD + OM 作为模型输入因子,这样可以提高模型预测精度。而从 BNN 模型的预测结果可以看出,3 种输入因子的预测结果差别不大,而且 3 种曲线均与 VG 模型拟合曲线和实测曲线较为一致,可以使用 SSC 作为输入因子建模,达到简化模型和实验测试工作量的目的。




图 3 不同质地土壤水分特征曲线预测结果对比
Fig. 3 Contrast of predicted results of SWRC for different texture soil
(a) 粉粘土 (b) 沙壤土 (c) 粉粘壤土 (d) 壤土

3 结 论

(1)通过内蒙古河套灌区解放闸灌域 22 土壤水盐监测点 110 个土壤样本的采样与分析,通过土壤基本特征参数(容积密度、颗粒组成、有机质)和特征含水率(饱和含水率、剩余含水率、田间持水率等)及 VG 模型参数之间的内在关系,利用 BNN 模型建立了河套灌区区域分层土壤特征参数与土壤水分特征曲线模型参数、特征含水率之间的土壤转换函数模型,并与已有的 BP 神经网络模型进行适应性比较及模型验证。

(2)贝叶斯神经网络通过融入模型参数的先验知识,在给定数据样本及模型假设下进行后验概率的贝叶斯推理,使用马尔可夫链蒙特卡罗算法来优化模型控制参数,实现了对神经网络模型中不同部

分复杂度的控制,获得了模型参数的后验分布及预测分布,可以达到较好的建模预测效果。

(3)传统 BP 模型土壤转换函数的训练模拟精度优于 BNN 模型,但是在模拟预测方面,BNN 模型普遍好于 BP 模型,而且模型输入因子数量对 BP 模型的精度影响较大,而 BNN 模型对于不同输入因子表现出很好的稳健性,在实际应用中可以直接使用土壤颗粒组成作为输入建模,这样可以减少化验、分析的工作量和费用。BNN 模型预测值为一个区间范围,比传统的人工神经网络模型具有更好的适应性和预测效果,体现了土壤特征参数的空间随机性和结构性特征,预测的土壤水分特征和 VG 拟合曲线与实测结果更为接近,而且模型的训练及检验过程较 BP 模型更加简单,是一种具有广阔前景的区域土壤转换函数推求方法。

参 考 文 献

1 许迪. 灌溉水文学尺度转换问题研究综述[J]. 水利学报,2006,37(2):141-149.
Xu Di. Review on scaling study in irrigation hydrology[J]. Journal of Hydraulic Engineering, 2006,37(2):141-149. (in Chinese)

2 Springer E P. Multiscale Bayesian neural networks for soil water content estimation[J]. Water Resources Research, DOI: 10.1029/2008WR006879.

3 Kingston, G B, Lambert M F, Maier H R. Bayesian training of artificial neural networks used for water resources modeling[J]. Water Resoures Research, DOI: 10.1029/2005WR004152.

4 Jana R B, Mohanty B P, Springer E P. Multiscale pedotransfer functions for soil water retention[J]. Vadose Zone Journal, 2007, 6(4): 868-878.

5 Wosten J H M, Pachepsky Ya A, Rawls W J. Pedotransfer functions: bridging the gap between available basic soil data and missing soil hydraulic characteristics[J]. Journal of Hydrology, 2001,251(3-4): 123-150.

6 高如泰, 陈焕伟, 李保国, 等. 基于 BP 神经网络的土壤水力学参数预测[J]. 土壤通报,2005,36(5):641-646.
Gao Rutai, Chen Huanwei, Li Baoguo, et al. Prediction of soil hydraulic characteristic parameters based on BP neural network

[J]. Soil Bulletin, 2005,36(5):641-646. (in Chinese)

7 聂卫波,费良军,马孝义. 区域尺度土壤入渗参数空间变异性规律研究[J]. 农业机械学报,2011,42(7):102-108.
Nie Weibo, Fei Liangjun, Ma Xiaoyi. Spatial variability of infiltration parameters at the region scales[J]. Transactions of the Chinese Society for Agricultural Machinery, 2011,42(7):102-108. (in Chinese)

8 胡振琪,张学礼. 基于 ANN 的复垦土壤水分特征曲线的预测研究[J]. 农业工程学报,2008,24(10):15-19.
Hu Zhenqi, Zhang Xueli. Artificial neural network for predicting water retention curves of reclaimed soils[J]. Transactions of the CSAE, 2008,24(10):15-19. (in Chinese)

9 廖凯华,徐绍辉,吴吉春,等. 一种基于 PCA 和 ANN 的土壤水力性质估计方法[J]. 水利学报,2012,43(3):333-338.
Liao Kaihua, Xu Shaohui, Wu Jichun, et al. A method based on principal component analysis and artificial neural network for estimating soil hydraulic properties[J]. Journal of Hydraulic Engineering, 2012,43(3):333-338. (in Chinese)

10 刘继龙,马孝义,张振华. 土壤入渗特性的空间变异性及土壤转换函数[J]. 水科学进展,2010,21(2):214-221.
Liu Jilong, Ma Xiaoyi, Zhang Zhenhua. Spatial variability of soil infiltration characteristics and its pedo-transfer functions[J]. Advances in Water Science, 2010,21(2):214-221. (in Chinese)

11 刘建立,徐绍辉,刘慧. 估算土壤水分特征曲线的间接方法研究进展[J]. 水利学报,2004,35(2):68-76.
Liu Jianli, Xu Shaohui, Liu Hui. A review of development in estimating soil water retention characteristics from soil data[J]. Journal of Hydraulic Engineering, 2004,35(2):68-76. (in Chinese)

12 Qu Z, Huang G, Yang J. Evaluation of regional pedotransfer functions based on the BP neural networks[C] // 2009 IFIP International Federation for Information Processing 294, Computer and Computing Technologies in Agriculture II, 2009, 2: 1 189-1 199.

13 Budiman Minasny, Alex B McBratney. The Neuro-m method for fitting neural network parametric pedotransfer functions[J]. Soil Science Society of Amewac Journal, 2002,66(2):352-361.

14 Bates B C, Campbell E P. A Markov chain Monte Carlo scheme for parameter estimation and inference in conceptual rainfall runoff modeling[J]. Water Resources Research, 2001, 37(4): 937-947.

15 屈忠义,陈亚新,史海滨,等. 地下水文预测中 BP 网络的模型结构算法探讨[J]. 水利学报,2004,35(2):88-93.
Qu Zhongyi, Chen Yaxin, Shi Haibin, et al. Structure and algorithm of BP network for underground hydrology forecasting[J]. Journal of Hydraulic Engineering, 2004, 35(2): 88-93. (in Chinese)

Application and Adaptability Evaluation of Bayesian Model in Soil Transfer Functions

Zhang Na¹ Qu Zhongyi¹ Yang Xiao¹ Fu Xiaojun²

(1. College of Water Resources and Civil Engineering, Inner Mongolia Agricultural University, Huhhot 010018, China

2. Shahaogu Irrigation Experimental Station, Jiefangzha Management Bureau of Hetao Irrigation District, Hangjinhouqi 015400, China)

Abstract: In order to study the spatial parameters of the distributive hydrological models among the ecological influences of regional farmland under the condition of water-saving practices in large scale irrigation district, the Bayesian neural networks and back-propagation artificial neural network models were applied to establish regional pedotransfer function models. Based on the relationship of measured soil characteristic contents, soil particle percentage, organic matter and bulk density, the adaptability of these two kinds of ANN models were evaluated through simulated and predicted values statistically, accompanied with the SWRC figures. Results indicated that the BP and BNN were both feasible PTFs methods. The training simulated accuracy of traditional BP model was better than that of BNN. However, the predicted accuracy of BNN model generally was better than the BP model. Furthermore, the predictive accuracy of BP model was significantly influenced by the number of input factor groups. But there were little influences on different input factors of BNN model. So, the BNN showed good robustness for the simple inputs. Besides, the predicted SWRC was better fitted with measured and VG fitted curve than that of ANN. Thus, the BNN model was better than the traditional artificial neural network model. It had better adaptability in the pedotransfer function establishment when only soil particle distribution was used. All showing that the BNN method was a practical method for regional pedotransfer function establishment.

Key words: Bayesian neural network Hetao irrigation district Pedotransfer functions Adaptability