

# 丘陵区土壤有机质空间分布预测的神经网络方法

李启权<sup>1</sup>, 王昌全<sup>1\*</sup>, 张文江<sup>2</sup>, 余 勇<sup>3</sup>, 李 冰<sup>1</sup>, 杨 娟<sup>1</sup>, 白根川<sup>1</sup>, 刘泳宏<sup>1</sup>

(1.四川农业大学资源环境学院, 成都 611130; 2.四川大学水力学与山区河流开发保护国家重点实验室, 成都 610065; 3.四川农业大学林学院, 四川 雅安 625014)

**摘要:**土壤性质空间分布信息的准确表达是土壤资源优化利用和土壤环境保护的需要。为模拟川中丘陵区县域尺度上土壤有机质的空间分布格局, 构建了以地理坐标、地形和植被因子为网络输入的径向基函数神经网络模型(RBFNN\_E), 并将该方法与普通克里格法(OK)、多元回归模型(MLR)和仅以地理坐标为网络输入的神经网络模型(RBFNN\_C)相比较。结果表明: RBFNN\_E 对 479 个验证点模拟结果的平均绝对误差(MAE)、平均相对误差(MRE) 和均方根误差(RMSE) 较 MLR 分别降低了 1.74%、1.45% 和 2.64%, 较 OK 分别降低了 7.77%、12.76% 和 3.92%, 较 RBFNN\_C 分别降低了 8.89%、9.81% 和 7.68%。从模拟的空间分布图来看, RBFNN\_E 能较好地刻画环境变化引起的土壤有机质空间变异的细节信息。因此, 融合环境因子的神经网络模型(RBFNN\_E)不仅具有较高的模拟精度, 还能更好地揭示复杂地形下土壤有机质的空间变异, 使模拟结果更符合区域地学规律与实际情况, 可为复杂环境条件下土壤管理、精准农业的实施以及区域环境规划等提供科学依据。

**关键词:**土壤; 植被; 模型; 地形因子; 丘陵区; 径向基函数神经网络; 空间预测

中图分类号:S153.6 文献标志码:A 文章编号:1672-2043(2012)12-2451-08

## Predict the Spatial Distribution of Soil Organic Matter for a Hilly Region with Radial Basis Function Netural Network

LI Qi-quan<sup>1</sup>, WANG Chang-quan<sup>1\*</sup>, ZHANG Wen-jiang<sup>2</sup>, YU Yong<sup>3</sup>, LI Bing<sup>1</sup>, YANG Juan<sup>1</sup>, BAI Gen-chuan<sup>1</sup>, LIU Yong-hong<sup>1</sup>

(1. College of Resources and Environment, Sichuan Agricultural University, Chengdu 611130, China; 2. State Key Laboratory of Hydraulics and Mountain River Engineering, Sichuan University, Chengdu 610065, China; 3. College of Forestry, Sichuan Agricultural University, Yaan 625014, China)

**Abstract:** Accurate spatial information of soil properties at regional scale is essential to land use and environment management. This paper proposed a radial basis function neural network method for predicting the spatial distribution of soil organic carbon(SOM) in the typical hilly region of Sichuan Basin, which uses geographic coordinates, terrain factors and vegetation index as inputs(RBFNN\_E). Its performance was compared with that of ordinary kriging(OK), multiple linear regression model(MLR) and a radial basis function neural network model only using geographic coordinates as inputs(RBFNN\_C). The results of 479 validation points showed that RBFNN\_E obtained lower estimation bias. The mean absolute error(MAE), root mean squared error(RMSE) and mean relative error(MRE) of RBFNN\_E were smaller than those of MLR respectively by 1.74%, 1.45% and 2.64%, smaller than those of OK respectively by 7.77%, 12.76%, 3.92%, and smaller than those of RBFNN\_C respectively by 8.89%, 9.81% and 7.68%. Moreover, RBFNN\_E produced the SOM map with much more details, which were contributed by the adoption of environmental factors as inputs. The results suggested the method of radial basis function neural network, which adopted environmental factors as inputs, can not only improve the prediction accuracy but also respond to the spatial variation of soil organic carbon over the environment variation. Therefore, RBFNN\_E can help to produce the SOM map with higher accuracy which was consistent with the true geographical information. This method provides a useful tool for the accurate prediction of soil properties for the typical hilly region of Sichuan Basin, the area with complex environment.

**Keywords:** soils; vegetation; models; terrain factors; hill region; radial basis function neural network; spatial prediction

---

收稿日期:2012-05-18

基金项目:国家杰出青年科学基金(40825003);国家自然科学基金项目(41201214, 40801175)

作者简介:李启权(1980—),男,四川泸县人,讲师,从事土壤环境与系统模拟研究。E-mail:liqq@lreis.ac.cn

\* 通信作者:王昌全 E-mail:w.changquan@163.com

精确的土壤性质空间分布信息是合理科学地进行土壤环境管理和农业生产管理的基础<sup>[1-2]</sup>。受多种成土因素和生态过程的影响,土壤性质具有高度的空间变异性<sup>[2]</sup>。研究土壤性质的空间变异规律,准确模拟土壤性质的空间分布特征,是土壤学和环境科学研究领域的热点问题之一<sup>[3-4]</sup>。

在已有的土壤性质空间分布模拟方法中,空间自相关模型如反比距离法和普通克里格法等利用土壤性质的空间自相关性和地理位置来模拟土壤性质的区域分布特征<sup>[5]</sup>,这类模型没有较充分地考虑各环境因素对土壤性质空间分布的影响。空间异相关模型基于土壤发生学理论,利用土壤与环境因素之间的关系来预测土壤性质的空间分布<sup>[5]</sup>,如多元回归模型<sup>[6]</sup>、模糊推理模型<sup>[7]</sup>、协同克里格法<sup>[8]</sup>等,对复杂环境下的土壤性质空间模拟,具有较好的效果。但土壤与环境因素间的关系是一种极其复杂的非线性关系<sup>[9]</sup>,对这种关系的定量表达还需开展更多的研究。

人工神经网络模型能自动分析多源输入与输出间的非线性映射关系,为解决非线性系统预测问题提供了一种有效的研究工具<sup>[10-11]</sup>。不少学者利用各种神经网络模型开展了区域土壤性质空间分布的模拟研究<sup>[12-14]</sup>,但这些方法主要以地理坐标作为网络的输入。也有研究采用以地理坐标和邻近样点作为网络输入进行土壤性质空间分布预测<sup>[15-16]</sup>。但这些应用方式从本质上讲也属于空间自相关模型,没有充分利用土壤与环境因素之间的关系,不能很好地揭示复杂环境条件下土壤性质的空间分布特征。

土壤有机质是土壤特性的重要指标之一,在土壤肥力、农业生产和环境保护等方面均有重要的作用和意义。本文采用径向基函数神经网络模型(Radial basis function neural network, RBFNN),构建描述土壤有机质与环境因素间非线性关系的空间异相关模型,模拟四川盆地丘陵区县域尺度上土壤有机质的空间分布格局,以期为复杂地形条件下土壤性质空间分布的准确预测提供方法上的探索,进而为区域土壤利用和环境保护提供科学的依据。

## 1 材料与方法

### 1.1 研究区概况

本文研究区选在四川盆地中部偏北的三台县,坐标为N30°42'~31°24',E104°42'~105°8',总土地面积2661 km<sup>2</sup>。该区域属亚热带湿润季风气候区,四季分明,年均气温16.7℃,年均日照时数1355.9 h,有效

积温6130.3℃,无霜期283 d,年均降水量895.2 mm。区域地势北高南低,地貌类型以丘陵为主,丘陵面积占总土地面积的94.3%,其余为平坝地。根据丘区丘体形态,可将其分为丘坡地和丘台地。其中,依据台地在丘体的部位从低到高可划分出1、2、3级台地;丘体与丘体之间为沟谷。研究区成土母质主要有全新统和更新统冲积物以及砂岩残积物。土壤类型包括水稻土、紫色土、潮土和黄壤土4类。土地利用以农业用地为主。

### 1.2 土壤样品采集与分析

2006年10月,在遵照全国耕地地力调查与质量评价技术规程、兼顾代表性与均匀性的基础上,采用多点混合的方法在研究区采集表层(0~20 cm)土壤样品2392个,每个采样点均以GPS记录其经纬度坐标和海拔高度,同时记录样点所在的地形部位。所有土壤样品经自然风干后磨碎过筛,采用重铬酸钾容量法测定其有机质含量。土壤样点分布如图1所示。

为评价本文方法对研究区土壤有机质空间分布模拟的精度,将2392个土壤样点划分为2个部分,分别用于建立模型和精度评价,即在ArcGIS软件的地统计分析模块中,随机抽取出20%的土壤样点作为验证点,其余80%作为建模点。建模点和验证点的空间分布位置如图1所示,其中建模点1913个,验证点479个。

### 1.3 环境因子提取

中小尺度上,地形因子和植被指数通常用来模拟土壤性质空间分布的环境因子<sup>[1,17-18,20]</sup>。地形因子中,高程(H)、坡度(S)、平面曲率(C<sub>t</sub>)、剖面曲率(C<sub>p</sub>)及地形湿度指数(TI)这5个地形因子可以反映土壤的发生和发育<sup>[19]</sup>。本文选择上述5个指标来反映研究区的地形特征,其中高程采用相对高程,各指标的计算方法可参见相关文献<sup>[5,20]</sup>。5个地形因子均由30 m分辨率的DEM数据(由1:5万地形图生成)在ArcGIS软件中计算得到。文中使用的植被指数为MODIS数据产品中的增强型植被指数(EVI)。考虑到土壤有机质的积累特点,本文选用2001至2006年每年7月和8月16日合成的250 m分辨率的EVI值。在对所下载的数据进行质量检查和处理后取平均值并重采样至30 m分辨率,即采用2001至2006年生物量最大时的平均植被指数来反映研究区的植被空间变化特征。

### 1.4 研究方法

#### 1.4.1 RBF神经网络模型

RBF神经网络是一种具有单隐层的3层前馈网

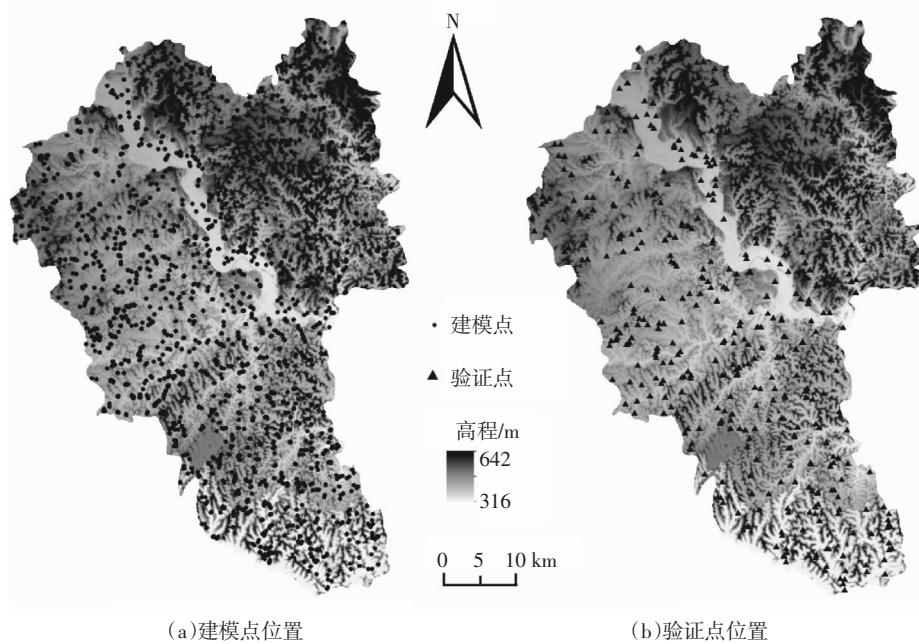


图 1 研究区土壤样点空间位置分布图

Figure 1 Spatial distribution of soil samples in the study area

络,能以任意精度逼近任意连续函数,与广泛应用的 BP 神经网络模型相比,在学习速度、参数设置等问题上具有明显优点<sup>[21-22]</sup>。本文以 RBF 神经网络为工具,以建模点的地理坐标、地形因子和植被指数作为网络的输入,以对应点位的土壤有机质含量作为网络输出,构建模拟丘陵区土壤有机质空间分布的空间异相关模型(Radial basis function neural network using environmental factors as inputs, RBFNN\_E)。其中,输入层的第 1、2 个节点为地理坐标,第 3 个至第 8 个节点为地形因子和植被指数。隐层节点数和扩展常数通过编写程序逐步搜索确定,具体方法是:以模型对建模点和验证点模拟结果的均方根误差最小为约束条件,隐层节点数从 1 开始每次增加 1 个节点,扩展常数从 0.05 开始每次增加 0.05,使得均方根误差最小的 2 个参数的组合即为该模型的最优结构。在进行区域模拟时,首先将研究区以 30 m 分辨率划分为 2680×1683 的栅格,然后把地理坐标值和 6 个环境因子转换为对应的矩阵,结合建立的 RBF 神经网络模型,在 MATLAB 软件中编程实现对整个研究区土壤有机质空间分布的模拟;模拟结果以.txt 文件格式储存,并在 ArcGIS 软件中转换为栅格格式的文件进行显示。

#### 1.4.2 对照方法

本文选用普通克里格法、多元回归模型和仅以地理坐标为网络输入的 RBF 神经网络模型(Radial

basis function neural network using coordinates as inputs, RBFNN\_C)作为对照方法,同时对研究区土壤有机质的空间分布进行模拟。普通克里格法是空间自相关模型中使用较广泛的方法,本文先在 GS+软件中进行半方差分析,确定最优的半方差参数,然后将参数输入 ArcGIS 软件的地统计学模块中完成普克里格插值。多元回归模型是实际应用较多的空间异相关模型<sup>[6,18]</sup>,本研究在 SPSS 软件中完成研究区土壤有机质与环境因子间的逐步回归方程拟合,在 ArcGIS 软件的空间分析模块中完成区域模拟。RBFNN\_C 方法的实现过程与 RBFNN\_E 方法相同,仅其网络输入的节点为地理坐标。

#### 1.5 模拟结果精度评价

以平均绝对误差、均方根误差和平均相对误差对建模点和验证点的模拟值和实际观测值进行对比分析,得出精度评价结果。平均绝对误差(MAE)、均方根误差(RMSE)和平均相对误差(MRE)的计算公式分别为:

$$MAE = \frac{1}{n} \sum_{i=1}^n |SOM_{obs(i)} - SOM_{pred(i)}| \quad (1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (SOM_{obs(i)} - SOM_{pred(i)})^2} \quad (2)$$

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|SOM_{obs(i)} - SOM_{pred(i)}|}{SOM_{obs(i)}} \times 100 \quad (3)$$

式中: $SOM_{pred(i)}$ 为模拟值; $SOM_{obs(i)}$ 为实际观测值; $n$ 为

样点个数。显然,MAE、RMSE、MRE值越小,则误差越小,模拟精度越高。

## 2 结果和分析

### 2.1 常规统计分析

常规统计分析结果表明(表1),研究区土壤有机质质量分数的平均值为 $17.88\text{ g}\cdot\text{kg}^{-1}$ ,变异系数为36.75%,属于中等变异性。从几个典型地形部位的统计结果来看,沟谷内土壤有机质含量的平均值明显高于其他地形部位,为 $22.67\text{ g}\cdot\text{kg}^{-1}$ ;其次为平坝地和靠近沟谷的一台地,平均值分别为 $17.71$ 、 $17.35\text{ g}\cdot\text{kg}^{-1}$ ;土壤有机质含量最低的地形部位为丘坡顶,平均值为 $10.30\text{ g}\cdot\text{kg}^{-1}$ 。

### 2.2 多元回归模拟分析

#### 2.2.1 土壤有机质与环境因子相关性分析

根据2392个样点数据与环境因子间的相关分析结果,研究区土壤有机质与相对高程呈极显著的负相关关系,相关系数为-0.07,这说明土壤有机质含量有随着相对高度升高而降低的趋势。有机质含量与坡度和平面曲率也表现为极显著的负相关关系,相关系数分别为-0.26和-0.07,这表明坡度越大,土壤有机质含量越低。剖面曲率与土壤有机质间的相关系数为0.03,未达到显著水平。地形湿度指数与有机质含量

则呈现极显著的正相关关系,相关系数达到0.30。综合土壤有机质与5个地形因子的相关性可以得出,研究区内土壤有机质含量在很大程度上受到地形因子的控制,在地势较高并且坡度较大的丘顶和坡地上土壤有机质含量一般较低,而在地势较低且湿度较大的平坦地区土壤有机质含量一般较高,这与常规统计所得结果一致。土壤有机质含量与植被指数(EVI)的相关系数为0.17,达到了极显著的正相关关系。

#### 2.2.2 土壤有机质的逐步回归模拟模型

由于研究区土壤有机质含量值呈非正态分布(表1),在进行回归方程拟合时先对原始数据进行了自然对数转换。考虑到土壤有机质空间分布存在的趋势,在回归方程拟合时将地理坐标也作为自变量。表2是采用逐步回归方法拟合的研究区土壤有机质的多元线性回归方程。从拟合结果来看,与土壤有机质相关性较大的坡度(S)、地形湿度指数(TI)和增强植被指数(EVI)3个地形因子参与了对土壤有机质空间分布的预测。此外,地理坐标中的经度值也参与了对土壤有机质的模拟,这表明研究区土壤有机质在东西方向上存在一定的分布趋势。

从回归方程的决定系数来看,方程的拟合程度并不高,与前人的一些结果相似。这主要有以下几方面的原因:研究表明,模拟区域面积增大,拟合方程的决

表1 研究区土壤有机质含量统计特征值

Table 1 Statistic characteristic values of soil organic matter in the study area

统计方式		样点数	最小值/ $\text{g}\cdot\text{kg}^{-1}$	最大值/ $\text{g}\cdot\text{kg}^{-1}$	均值/ $\text{g}\cdot\text{kg}^{-1}$	标准差/ $\text{g}\cdot\text{kg}^{-1}$	变异系数/%	偏度系数	峰度系数
地形部位	沟谷	742	9.00	47.60	22.67	6.42	28.31	0.78	1.06
	平坝地	63	10.60	27.20	17.71	4.13	23.33	0.33	-0.58
	一台地	595	10.10	46.20	17.35	5.41	31.20	1.60	4.24
	二台地	480	8.00	34.80	13.70	3.86	28.18	1.95	6.27
	三台地	41	7.00	23.10	12.02	2.73	22.71	1.30	5.82
	坡腰	114	6.60	34.70	12.83	4.12	32.09	2.17	8.77
	坡顶	31	4.20	15.70	10.30	2.95	28.61	0.07	-0.78
	建模点	1913	4.20	47.60	17.81	6.60	37.06	1.12	1.58
	验证点	479	7.80	43.40	18.19	6.46	35.51	0.91	0.64
	全部样点	2392	4.20	47.60	17.88	6.57	36.75	1.08	1.39

表2 研究区土壤有机质多元回归方程逐步拟合过程

Table 2 Stepwise process of multiple regression equations for soil organic matter in the study area

步骤	表达式	决定系数 $R^2$
1	$\ln(\text{SOM})=2.908-1.345S$	0.08
2	$\ln(\text{SOM})=2.745-0.969S+0.302TI$	0.10
3	$\ln(\text{SOM})=2.062-0.900S+0.297TI+1.471EVI$	0.11
4	$\ln(\text{SOM})=1.979-0.970S+0.281TI+1.579EVI+0.085X$	0.12

注:SOM为土壤有机质( $\text{g}\cdot\text{kg}^{-1}$ ),S为坡度, TI为地形湿度指数,EVI为增强植被指数,X为经度坐标值。

定系数会减小<sup>[17]</sup>。其次,土壤性质与环境因素间并非简单的线性关系<sup>[9]</sup>;研究区内土壤性质与环境因素间的关系还随着空间区位的变化而不同,采用一个回归方程只能反映研究区内土壤性质随环境因素变化而呈现的总体分布趋势<sup>[18]</sup>。此外,其他一些重要的影响因素如耕作制度、成土母质等没有包含在方程中,增加这些因子将会提高方程的拟合程度<sup>[23]</sup>。

### 2.3 半方差分析

半方差分析结果如图2所示。拟合结果表明,研究区土壤有机质的半方差模型符合球状模型,拟合决定系数达到0.91;拟合方程的块金值和基台值分别为0.095和0.124,两者之比为0.77,这表明研究区土壤有机质的空间自相关程度较弱;拟合变程为7 km,表明空间自相关的范围不大。

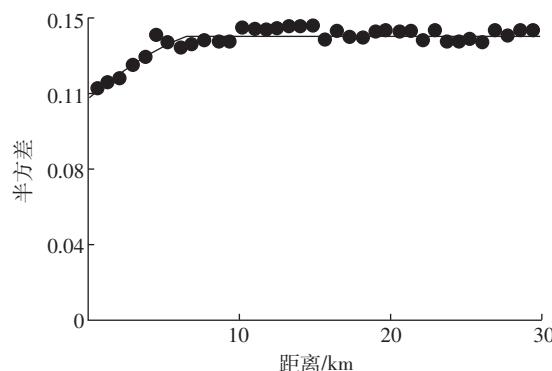


图2 研究区土壤有机质半方差模型

Figure 2 Semivariograms of soil organic matter in the study area

### 2.4 土壤有机质空间分布模拟结果

基于回归分析结果、半方差分析结果和2个最优结构的RBF神经网络模型完成对研究区土壤有机质空间分布格局的模拟;4种方法的模拟结果如图3所示。可以看出,研究区土壤有机质含量的空间分布呈现中间低四周高的趋势,主要高值区域分布于东南、东北和西北部。

4种方法模拟结果差异明显。仅以地理坐标为网络输入的RBF神经网络模型(图3 b)的模拟结果与普通克里格法(图3 d)更为相似,这2种方法主要反映的是研究区土壤有机质的空间分布趋势。而以地理坐标和环境因子作为网络输入的RBF神经网络模型(图3 a)的模拟结果与多元回归模型(图3 c)更为接近。不同于前述2种空间自相关模型,RBFNN\_E和多元回归模型还反映了不同地形部位上土壤有机质含量的差异,能提供更多的细节信息。如高值区域内土

壤有机质含量值较高的地点主要出现在沟道和地势较低平的区域,这与常规统计结果和相关分析结果一致;而RBFNN\_C和普通克里格法则不能反映这种规律,其模拟结果的高值和低值区域为整块出现,这显然不符合丘陵区土壤性质空间分布的地学规律。

### 2.5 模拟精度分析

误差分析结果(表3)表明,以地理坐标和环境因子为网络输入的RBF神经网络模型(RBFNN\_E)的模拟误差明显小于其他3种方法,多元回归模型(MLR)模拟精度低于RBFNN\_E但高于另2种方法。从这4种方法对验证点的预测结果来看,RBFNN\_E预测结果的平均绝对误差(MAE)、平均相对误差(MRE)和均方根误差(RMSE)分别为4.51 g·kg<sup>-1</sup>、25.09%和5.89 g·kg<sup>-1</sup>,分别较多元回归模型(MLR)降低了1.74%、1.45%和2.64%,其中均方根误差降低水平显著( $P=0.023<0.05$ );与普通克里格法(OK)相比,RBFNN\_E的预测误差分别降低了7.77%、12.76%和3.92%,误差降低水平显著( $P_{MAE}=0.001<0.01$ 、 $P_{MRE}=8.37E-06<0.01$ 和 $P_{RMSE}=0.015<0.05$ );与仅以地理坐标为输入的RBF神经网络模型(RBFNN\_C)相比,RBFNN\_E的预测误差分别降低了8.89%、9.81%和7.68%,误差降低水平极显著( $P=2.07E-05$ 、 $1.33E-04$ 、 $2.90E-05<0.01$ )。MLR的预测误差分别为4.59 g·kg<sup>-1</sup>、25.46%和6.05 g·kg<sup>-1</sup>,与RBFNN\_C相比,误差降低水平极显著( $P=4.81E-04$ 、 $2.84E-04$ 、 $0.002<0.01$ );与OK相比,平均绝对误差(MAE)、平均相对误差(MRE)降低水平显著( $P_{MAE}=0.022<0.05$ 、 $P_{MRE}=5.10E-05<0.01$ ),但均方根误差降低水平不显著。

精度验证表明,融合环境因子的空间异相关模型(RBFNN\_E和MLR)比空间自相关模型(RBFNN\_C和OK)更适合复杂地形条件下的土壤性质空间分布

表3 不同模拟方法对土壤有机质的模拟结果误差

Table 3 Precision errors of different methods for predicting soil organic matter

模拟方法	建模点			验证点		
	MAE	MRE	RMSE	MAE	MRE	RMSE
OK	4.78	28.72	6.00	4.89	28.76	6.13
MLR	4.67	26.94	6.25	4.59	25.46	6.05
RBFNN_C	4.93	28.63	6.46	4.95	27.82	6.38
RBFNN_E	4.40	25.20	5.94	4.51	25.09	5.89

注:OK为普通克里格法,MLR为多元回归模型,RBFNN\_C为以地理坐标为输入的RBF神经网络模型,RBFNN\_E为融合环境因子的RBF神经网络模型;MAE为平均绝对误差,MRE为平均相对误差,RMSE为均方根误差。

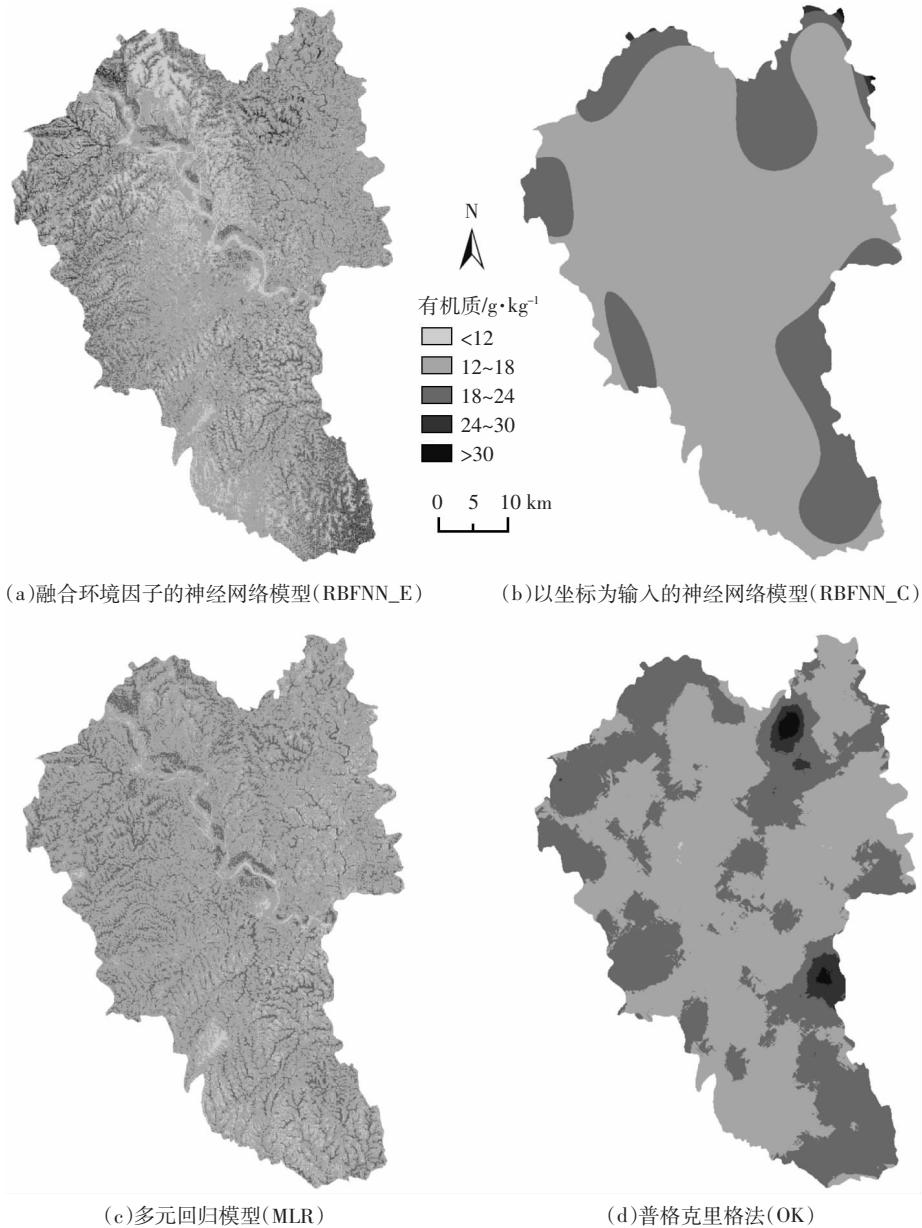


图3 基于不同方法模拟的研究区土壤有机质空间分布格局

Figure 3 Spatial distribution of soil organic matter in the study area produced by four methods

模拟;空间异相关模型中,非线性方法能更好地揭示土壤性质与环境因子间的复杂关系,从而提高对丘陵区复杂地形条件下土壤有机质空间分布模拟的精度。

### 3 讨论

由于土壤形成过程的连续性、气候等因素的渐变性,土壤性质在一定范围内存在着空间自相关性<sup>[24]</sup>,这是空间自相关模型的理论基础。空间自相关程度的大小决定了这类模型模拟结果的精度<sup>[25]</sup>。本文研究区位于四川盆地丘陵区,地形条件相对复杂,由气候、成土母质等因素决定的空间自相关性受到地形、植被以

及耕作制度等因素的影响,空间自相关性减弱,空间自相关的范围较小(图2)。因此仅以地理坐标为输入的RBF神经网络模型(RBFNN\_C)与普通克里格法对研究区土壤有机质的模拟结果误差相对较大;同时,由于2种方法依据地理坐标和邻近样点来推测未采样区域的值,计算过程没有充分考虑地形和植被等局部环境因子的影响,模拟结果仅反映了研究区土壤有机质空间分布的整体趋势,没有反映出丘陵区不同地形部位上土壤有机质的差异。对本研究中仅以地理坐标为输入的RBF神经网络模型而言,它是通过全部样点来推测局部点位的值,而普通克里格法则是通过

局部的邻近样点来推测未采样区域的值,这使得在空间自相关范围较小、空间自相关程度较弱的情况下,仅以地理坐标为网络输入的RBF神经网络模型的模拟精度不如普通克里格法。

复杂地形条件下,如果模拟方法不能反映由地形因素引起的土壤性质空间异质性,必然会导致对土壤性质过高或过低的估计<sup>[26]</sup>。本研究中,以地理坐标和环境因子为网络输入的RBF神经网络模型不仅考虑了土壤有机质的空间分布趋势,还融入了地形和植被因子对土壤有机质的影响,建立了土壤有机质与地形、植被因子间的非线性映射关系,综合模拟结果和精度评价结果来看,该方法的模拟结果优于其他3种方法。

由于本文研究尺度较大,而土壤性质与环境因素间的关系还随着空间区位的变化而不同<sup>[18]</sup>;同时区域内成土母质、土地类型、耕作制度均会对土壤有机质的空间分布产生影响。因此,在构建RBF神经网络模型时融入上述影响因素对土壤有机质空间分布进行模拟,可进一步提高模型预测的精度。

## 4 结论

本文以四川省三台县为研究区,采用径向基函数神经网络模型,构建描述地形、植被因子与土壤有机质间非线性关系的空间异相关模型(RBFNN\_E),模拟川中丘陵区县域尺度上土壤有机质的空间分布格局。结果表明:

(1)融合环境因子的神经网络模型能较好地捕捉土壤有机质与环境因子间的非线性关系,对丘陵区土壤有机质空间分布的预测精度明显高于多元回归模型、普通克里格法和仅以地理坐标为输入的神经网络模型。误差分析表明,融合环境因子的神经网络模型(RBFNN\_E)对479个验证点模拟结果的平均绝对误差(MAE)、平均相对误差(MRE)和均方根误差(RMSE)较多元回归模型(MLR)分别降低了1.74%、1.45%和2.64%,较普通克里格法(OK)分别降低了7.77%、12.76%和3.92%,较仅以地理坐标为网络输入的神经网络模型(RBFNN\_C)分别降低了8.89%、9.81%和7.68%。

(2)从模拟结果图来看,融合环境因子的神经网络模型能够揭示地形变化引起的土壤有机质空间变异的细节信息,使模拟结果更符合研究区地学规律与实际情况。该方法为准确模拟复杂环境条件下土壤性质的空间分布提供了有益的参考,可为类似区域的土

壤及环境管理提供借鉴。

## 参考文献:

- [1] Motaghian H R, Mohammadi J. Spatial estimation of saturated hydraulic conductivity from terrain attributes using regression, kriging, and artificial neural networks[J]. *Pedosphere*, 2011, 21(2):170–177.
- [2] Sculka P, Franklina J, Chadwickb O A, et al. Predictive soil mapping: A review[J]. *Progress in Physical Geography*, 2003, 27(2):171–197.
- [3] 孟涛,周非,聂庆华,等. 污灌条件下农田土壤重金属的空间变异与模拟[J]. 农业环境科学学报, 2008, 27(3):867–872.  
MENG Tao, ZHOU Fei, NIE Qing-hua, et al. Spatial variation of heavy metal contents in farmland soils under permanent irrigation from polluted river water[J]. *Journal of Agro-Environment Science*, 2008, 27(3):867–872.
- [4] 石淑芹,陈佑启,李正国,等. 基于土壤类型和微量元素辅助信息的土壤属性空间模拟[J]. 农业工程学报, 2010, 26(12):199–205.  
SHI Shu-qin, CHEN You-qi, LI Zheng-guo, et al. Spatial interpolation of soil properties based on soil types and trace micro-elements[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2010, 26(12):199–205.
- [5] 李启权,岳天祥,范泽孟,等. 中国表层土壤有机质空间分布模拟分析方法研究[J]. 自然资源学报, 2010, 25(8):1385–1399.  
LI Qi-quan, YUE Tian-xiang, FAN Ze-meng, et al. Study on method for spatial simulation of topsoil SOM at national scale in China[J]. *Journal of Natural Resources*, 2010, 25(8):1385–1399.
- [6] Grunwald S. Multi-criteria characterization of recent digital soil mapping and modeling approaches[J]. *Geoderma*, 2009, 152(3/4):195–207.
- [7] Zhu A X, Hudson B, Burt J, et al. Soil mapping using GIS, expert knowledge, and fuzzy logic[J]. *Soil Science Society of America Journal*, 2001, 65(5):1463–1472.
- [8] 刘兴权,许晶玉,江丽华,等. 山东省种植区地下水硝酸盐污染空间变异及分布规律研究[J]. 农业环境科学学报, 2010, 29(6):1172–1179.  
LIU Xing-quan, XU Jing-yu, JIANG Li-hua, et al. Spatial variability and distribution pattern of groundwater nitrate pollution in farming regions of Shandong Province, China[J]. *Journal of Agro-Environment Science*, 2010, 29(6):1172–1179.
- [9] McBratney A B, Mendonca Santos M L, Minasny B. On digital soil mapping[J]. *Geoderma*, 2003, 17(1/2):3–52.
- [10] Erzin Y, Rao B H, Singh D N. Artificial neural network models for predicting soil thermal resistivity[J]. *International Journal of Thermal Sciences*, 2008, 47(10):1347–1358.
- [11] Zou P, Yang J S, Fu J R, et al. Artificial neural network and time series models for predicting soil salt and water content[J]. *Agricultural Water Management*, 2010, 97(12):2009–2019.
- [12] 何勇,张淑娟,方慧. 基于人工神经网络的田间信息插值方法研究[J]. 农业工程学报, 2004, 20(3):120–123.  
HE Yong, ZHANG Shu-juan, FANG Hui. Interpolation method of field information based on the artificial neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2004, 20(3):120–123.

- [13] 胡大伟, 卞新民, 李思米, 等. 基于神经网络的农田土壤重金属空间分布分析[J]. 农业环境科学学报, 2007, 26(1):216–223.  
HU Da-wei, BIAN Xin-min, LI Si-mi, et al. Analysis of spatial distribution of soil heavy metals in farmland based on artificial neural networks[J]. *Journal of Agro-Environment Science*, 2007, 26(1):216–223.
- [14] 雷能忠, 王心源, 蒋锦刚, 等. 基于BP神经网络插值的土壤全氮空间变异[J]. 农业工程学报, 2008, 24(11):130–134.  
LEI Neng-zhong, WANG Xin-yuan, JIANG Jin-gang, et al. Spatial variability of soil nitrogen by BP neural network interpolation [J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2008, 24(11):130–134.
- [15] 李启权, 王昌全, 岳天祥, 等. 基于RBF神经网络的土壤有机质空间变异研究方法[J]. 农业工程学报, 2010, 26(1):87–93.  
LI Qi-quan, WANG Chang-quan, YUE Tian-xiang, et al. Method for spatial variety of soil organic matter based on radial basis function neural network[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2010, 26(1):87–93.
- [16] 李启权, 王昌全, 岳天祥, 等. 不同输入方式下RBF神经网络对土壤性质空间插值的误差分析[J]. 土壤学报, 2008, 45(2):360–365.  
LI Qi-quan, WANG Chang-quan, YUE Tian-xiang, et al. Error analysis of soil property spatial interpolation with RBF artificial neural network with different input methods[J]. *Acta Pedologica Sinica*, 2008, 45(2):360–365.
- [17] Ziadat F M. Analyzing digital terrain attributes to predict soil attributes for a relatively area[J]. *Soil Science Society of America Journal*, 2005, 69(5):1590–1599.
- [18] Mishra U, Lal R, Liu D S, et al. Predicting the Spatial variation of the soil organic carbon pool at a regional scale[J]. *Soil Science Society of America Journal*, 2010, 74(3):906–914.
- [19] McSweeney K, Slater B K, Hammer R D, et al. Towards a new framework for modeling the soil–landscape continuum[M]//Factors of Soil Formation: A Fiftieth Anniversary Publication, R.Amundson (ed.), Madison, WI: Soil Science Society of America, 1994:127–145.
- [20] 张素梅, 王宗明, 张柏, 等. 利用地形和遥感数据预测土壤养分空间分布[J]. 农业工程学报, 2010, 26(5):188–194.  
ZHANG Su-mei, WANG Zong-ming, ZHANG Bai, et al. Prediction of spatial distribution of soil nutrients using terrain attributes and remote sensing data[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2010, 26(5):188–194.
- [21] Alp M, Cigizoglu H K. Suspended sediment load simulation by two artificial neural network methods using hydrometeorological data [J]. *Environmental Modelling and Software*, 2007, 22(1):2–13.
- [22] Sharma V, Negi S C, Rudra R P, et al. Neural networks for predicting nitrate–nitrogen in drainage water[J]. *Agricultural Water Management*, 2003, 63(3):169–183.
- [23] Meersmans J, De Ridder F, Canters F, et al. A multiple regression approach to assess the spatial distribution of soil organic carbon (SOC) at the regional scale(Flanders, Belgium)[J]. *Geoderma*, 2008, 143(1/2):1–13.
- [24] Burrough P A. Soil variability: A late 20th century view[J]. *Soils and Fertilizers*, 1993, 56(5):529–562.
- [25] Kravchenko A N. Influence of spatial structure on accuracy of interpolation methods[J]. *Soil Science Society of America Journal*, 2003, 67(5):1564–1571.
- [26] Webster K L, Creed I F, Beall F D, et al. A topographic template for estimating soil carbon pools in forested catchments[J]. *Geoderma*, 2011, 160(3/4):457–467.