

江叶枫, 郭 熙, 叶英聪, 等. 应用集成 BP 神经网络模型预测土壤有机质空间分布[J]. 江苏农业学报, 2017, 33(5): 1044-1050.
doi: 10.3969/j.issn.1000-4440.2017.05.013

应用集成 BP 神经网络模型预测土壤有机质空间分布

江叶枫^{1,2}, 郭 熙^{1,2}, 叶英聪¹, 孙 凯¹, 饶 磊¹

(1. 江西农业大学国土资源与环境学院/江西省鄱阳湖流域农业资源与生态重点实验室, 江西 南昌 330045; 2. 南方粮油作物协同创新中心, 湖南 长沙 410000)

摘要: 基于 2014 年江西省万年县测土配方施肥数据, 以地理坐标、高程和坡度以及邻近样点信息作为网络的输入变量, 采用集成 BP 神经网络模型 (BPNN-Ada 模型) 预测土壤有机质的空间分布, 并与未集成的 BP 神经网络模型 (BPNN 模型) 和普通克里金模型 (OK 模型) 进行比较。结果表明, 3 种模型的预测精度大小顺序为 BPNN-Ada 模型 > BPNN 模型 > OK 模型。集成 BP 神经网络模型预测精度最高, 效果最好, 比较符合土壤有机质地学分布规律及实际情况。BPNN-Ada 模型克服了 BP 神经网络局部搜索能力差和易陷入全局最优的缺点, 提高了 BP 神经网络的泛化能力。

关键词: 土壤有机质; Adaboost 算法; BP 神经网络; 空间分布预测

中图分类号: S126 **文献标识码:** A **文章编号:** 1000-4440(2017)05-1044-07

Spatial distribution of soil organic matter predicted by BP neural network ensemble model

JIANG Ye-feng^{1,2}, GUO Xi^{1,2}, YE Ying-cong¹, SUN Kai¹, RAO Lei¹

(1. College of Land Resource and Environment, Jiangxi Agricultural University/ Key laboratory of Poyang Lake Watershed Agricultural Resources and Ecology, Nanchang 330045, China; 2. Southern Regional Collaborative Innovation Center for Grain and Oil Crops in China, Changsha 410000, China)

Abstract: Based on the data collected from the project of soiltest-based formulated fertilization in Wannian county, Jiangxi province in 2014, a back propagation neural network ensemble model (BPNN-Ada) was used to predict the spatial distribution of soil organic matter (SOM) which was then compared to those by back propagation neural network model (BPNN) and ordinary Kriging model (OK). The BPNN-Ada and BPNN model were trained using the geographical coordinates, elevation, slope and adjacent sampling points information as inputs. The prediction accuracy of three models followed the order of BPNN-Ada > BPNN > OK. BPNN-Ada model could help to produce the SOM map with higher accuracy and better effect, which was consistent with the true geographical information and actual situation of SOM. By overcoming the shortcomings of poor local search ability and easiness to fall into global optimum, BPNN-Ada improved the generalization ability of BPNN.

Key words: soil organic matter; adaptive boosting method; back propagation neural network; prediction of spatial distribution

收稿日期: 2017-01-05

基金项目: 国家自然科学基金项目 (41361049); 江西省自然科学基金项目 (20122BAB204012); 江西省赣鄱英才“555”领军人才项目 (201295)

作者简介: 江叶枫 (1994-), 男, 江西余干人, 硕士, 主要从事土壤环境与系统模拟方面研究。(E-mail) jiangyf0308@163.com

通讯作者: 郭 熙, (E-mail) xig435@163.com

从 2005 年 4 月开始, 农业部门在全国 200 个县开展第 1 批测土配方施肥试点工作, 旨在准确测定耕地土壤养分含量从而进行精准施肥。快速准确地获取土壤养分含量是有效管理土壤资源、科学规划土地利用、精准农业施肥的基础^[1]。目前基于实地

采样获取的土壤养分信息远远不能满足环境保护和精准农业的需要,且大规模采样并不现实。因此,预测土壤养分空间分布一直是土壤学研究的热点之一^[2-4]。土壤有机质(Soil organic matter, SOM)含量是土壤养分指标之一,是衡量土壤肥力高低的重要指标之一。目前,针对 SOM 的预测方法有很多,其中普通克里金(Ordinary kriging, OK)法是应用最普遍也最广泛的方法^[5],但在许多情况下因不能满足 OK 法的 3 个重要前提条件而导致预测精度偏低甚至不能应用,而且 OK 法容易造成平滑效应^[6],尤其是难以表达 SOM 含量突变的区域,导致突变区域信息丢失严重^[7]。

近年来国内外众多学者将人工神经网络引入 SOM 的空间分布预测中,并取得了显著成就^[8-10]。目前应用于 SOM 空间插值的神经网络主要有 BP 神经网络和 RBF 神经网络。BP 神经网络具有操作简单、可塑性好的优点,是目前训练网络权值的普遍算法。但是 BP 神经网络是基于最速下降法或者拟牛顿法,因而不可避免地会陷入全局最优甚至过度拟合等缺点^[11],在一定程度上影响了网络泛化能力的提高。Hansen 等^[12]开创性地提出了一种神经网络集成思想。Schapire 等^[13]通过构造 boosting 算法肯定了集成神经网络,但发现该算法需要知道弱学习器学习正确率的下限,这在实际应用中很难做到。为解决这一问题, Freund 等在 boosting 算法基础上提出了一种 Adaptive Boosting (Adaboost) 算法^[14]。该算法与 boosting 算法执行效率很接近,但却非常容易应用到实际问题中,且不用担心过度拟合,在土壤属性预测中达到了很好的效果^[5,15],是目前最流行的 boosting 算法。还有一些学者将邻近信息纳入 SOM 等土壤属性的空间预测中。徐剑波等^[16]利用欧式距离来寻找离建模点最近的 5 个土壤属性值,在不同样本下误差较 OK 法明显降低。李启权等^[17]根据空间距离衰减规律,选取离插值点最近的 3 个邻近采样点 SOM 值,与 OK 法相比预测误差显著降低。加入邻近信息能更好地反映土壤属性的局部变异信息。

本研究以江西省万年县耕地土壤有机质含量为研究对象,基于 2014 年测土配方施肥的数据,以地理坐标、高程和坡度同时利用四方位搜索法^[18]加入邻近样点信息作为网络的输入变量,采用 Adaboost 算法对 BP 神经网络进行集成,用集成 BP 神经网络模型预测 SOM 含量的空间分布。

1 材料与方法

1.1 研究区域概况

江西省万年县(28°30'~28°54'N, 116°46'~117°15'E)总面积为 1 140.76 km²,东西长 47 km,南北宽 43 km。属于亚热带季风性气候,海拔 14~650 m。研究区地貌类型以岗地和丘陵为主。境内水资源比较丰富,年平均降水量为 1 766 mm,无霜期为 263 d。耕地面积约为 1 111 hm²。土壤类型主要有水稻土、红壤和黄褐土等。

1.2 土壤采样与数据处理

土壤样品采集于 2014 年 11 月。按照均匀性、代表性和连续性的原则,在考虑地形的基础上,采用“S”形采样、多点混合的方法采集 0~20 cm 的耕地表层土壤样品,经过充分混合最后留取 1 kg 土样,得到 960 个耕地表层土壤样品(图 1)。土壤样品经过自然风干后,带回实验室磨碎过筛,采用重铬酸钾(K₂Cr₂O₇)油浴加热法测定 SOM 含量^[19]。数字高程模型(Digital elevation model, DEM)(图 1,分辨率 30 m)由 1:10 000 的地形图生成。

为减少样品采集与测定分析过程中的误差对 SOM 含量空间总体分布与统计分析的影响,采用拉依达准则法^[20]对各采样点 SOM 值进行处理,剔除粗差数据,剔除后总样点为 954 个。根据前人研究方法^[4,10],随机均匀选取 80%样点作为建模点(建模点 763 个)用于插值,剩余 20%样点作为测试点(测试点 191 个),不参与插值过程,只用于验证插值精度。

1.3 研究方法

1.3.1 基于 Adaboost 的集成 BP 神经网络模型
Adaboost 算法是机器学习中一种重要的迭代算法,主要解决分类问题与回归问题。该算法通过对同一个建模集进行重采样,然后针对每个建模集训练不同的弱分类器(单个 BP 神经网络),将这些弱分类器组合成一个强分类器(集成 BP 神经网络)^[21]。Adaboost 算法的核心思想是提高建模集中训练误差大的样本权值和分类效果强的弱学习器,降低建模集中训练误差小的样本权重和分类效果弱的弱学习器(图 2)。

Adaboost 算法中有 2 个参数需要设定:一个是重采样建模集的数量 K ,即迭代的次数;另一个是预设的最小误差阈值。本研究以测试集均方根误差最小为约束条件(表 1),在均方根误差相同的情况尽

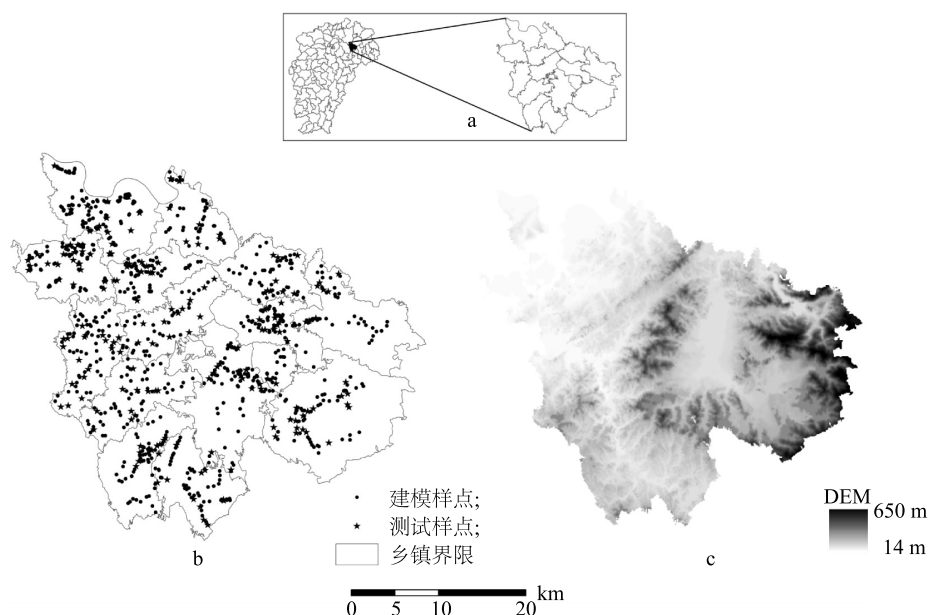


图 1 研究区位置(a)、土壤样点分布图(b)及数字高程模型(DEM)数据(c)

Fig.1 Location of study area(a), distribution of soil sampling sites(b) and DEM data(c)

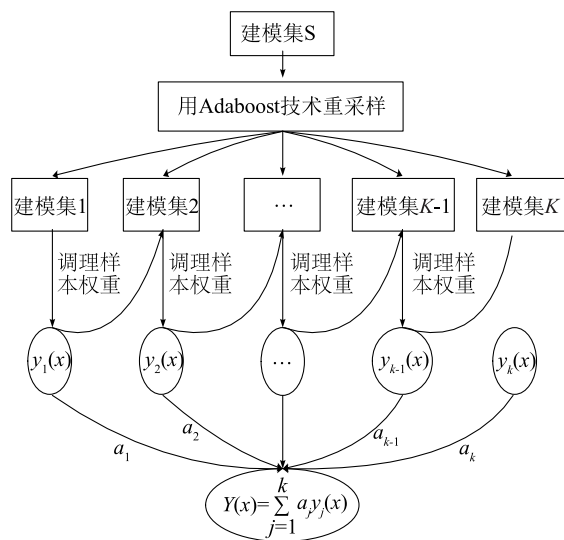


图 2 基于 Adaboost 的集成 BP 神经网络算法流程

Fig.2 Algorithm of BP neural network ensemble model based on Adaboost

量选取重采样次数少的来加快网络的收敛速度,最终得到重采样数量为 20,最小误差为 0.2。集成 BP 神经网络流程图见图 2。

1.3.2 参照方法 将普通克里金法(OK)和以地理坐标、高程和坡度以及邻近信息为输入变量的 BP 神经网络方法(BPNN)作为参照方法。根据反距离

加权算法(Inverse distance weighted, IDW)的算法思想^[18]和空间自相关理论^[22],利用四方位搜索法^[18],以插值点为坐标原点,SOM 含量变程为搜索半径,计算插值点与其他采样点的欧式距离来寻找 4 个邻近 SOM 含量值。最后以均方根误差最小为约束条件,将 BP 神经网络的模型迭代次数设为 30,隐藏神经元数量为 5,学习率为 0.1,即网络的拓扑结构为 8-5-1。为了使集成 BP 神经网络和单个 BP 神经网络具有可比性,集成 BP 神经网络在单个 BP 神经网络的基础上进行集成。

1.4 插值精度分析

运用 ArcGIS10.2 软件创建子集模块,得到建模集和测试集,以均方根误差(RMSE)和平均相对误差(MRE)对建模和测试预测值与实际采样值进行对比分析,评价精度,其公式分别为:

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

$$MRE = \frac{1}{n} \sum_{i=1}^n \frac{|SOM_{ob(i)} - SOM_{pv(i)}|}{Z_i} \times 100\% \quad (2)$$

式中, $SOM_{pv(i)}$ 为样点的预测值; $SOM_{ob(i)}$ 为样点的实际观测值; n 为样点数。 $RMSE$ 和 MRE 值越小,说明误差越小,模拟精度越高。

表 1 不同网络参数下的均方根误差 (RMSE)

Table 1 The root mean square error (RMSE) of BPNN-Ada with different network parameters

| 误差阈值 | 集成 BP 神经网络的重采样次数 | | | | | | | |
|------|------------------|------|------|------|------|------|------|------|
| | 10 | 20 | 30 | 40 | 50 | 60 | 100 | 200 |
| 0.05 | 5.27 | 5.27 | 5.26 | 5.24 | 5.27 | 5.25 | 5.25 | 5.25 |
| 0.10 | 5.28 | 5.27 | 5.24 | 5.25 | 5.23 | 5.26 | 5.27 | 5.24 |
| 0.20 | 5.27 | 5.23 | 5.26 | 5.25 | 5.23 | 5.24 | 5.24 | 5.24 |
| 0.30 | 5.25 | 5.24 | 5.25 | 5.24 | 5.26 | 5.25 | 5.26 | 5.25 |

本研究中常规性统计分析均在 SPSS (version 22) 软件中计算,集成 BP 神经网络、BP 神经网络和四方位搜索法均在 MATLAB R2014a 软件中通过编程实现,半方差函数分析主要借助于 GS+ (version 7) 软件,空间分析主要在 MATLAB 和 ArcGIS10.2 软件中进行。

2 结果与分析

2.1 土壤有机质 (SOM) 含量的统计特征

SOM 常规性统计分析结果 (表 2) 显示,SOM 含量的平均值为 33.33 g/kg,值域范围为 9.81~56.31 g/kg。从 K-S 检验的 P 值 ($P>0.05$) 可以看出 SOM

含量接近于正态分布。SOM 含量的变异系数在 10%至 100%之间,属于中等变异性。同时对建模集和测试集进行常规性统计分析,结果表明建模集和测试集的变异系数分别为 23.18%和 23.34%,为中等程度的变异性。

2.2 SOM 含量的半方差函数分析

SOM 含量半方差函数分析结果显示:研究区 SOM 含量的最优模型为球状,拟合系数为 0.942,拟合程度较高;块金值与基台值分别为 35.00 和 58.24,块金效应为 0.60,说明研究区 SOM 含量呈中等空间相关性;变程为 1 515 m,表明空间自相关的范围比较小。

表 2 SOM 含量的描述性统计特征

Table 2 Descriptive statistic characteristics of SOM content

| 数据集 | 样点数 | 最大值 (g/kg) | 最小值 (g/kg) | 平均值 (g/kg) | 中位数 (g/kg) | 标准差 (g/kg) | 偏度 | K-S 检验的 P 值 | 变异系数 (%) |
|------|-----|---------------|---------------|---------------|---------------|---------------|-------|------------------|-------------|
| 全部样点 | 954 | 56.31 | 9.81 | 33.33 | 33.18 | 7.74 | -0.10 | 0.30 | 23.22 |
| 建模集 | 763 | 56.31 | 10.17 | 33.47 | 33.27 | 7.76 | -0.05 | 0.19 | 23.18 |
| 测试集 | 191 | 53.11 | 9.81 | 32.77 | 32.76 | 7.65 | -0.32 | 0.20 | 23.34 |

2.3 3 种模型预测能力对比分析

为说明集成 BP 神经网络模型预测的拟合能力,将集成 BP 神经网络模型与单个的 BP 神经网络模型和 OK 模型进行对比。通过平均绝对误差、相关系数和拟合系数判断 3 种方法的预测能力。表 3、表 4 是 3 种模型在建模集和测试集中的预测能力对比分析结果。BPNN 模型较 OK 模型在建模集中相关系数和拟合系数分别增加了 0.18 和 0.24,平均绝对误差降低了 0.78,降低程度达到显著水平 ($P<0.05$);BPNN 模型较 OK 模型在测试集中相关系数和拟合系数分别增加了 0.38 和 0.40,平均绝对误差降低了 1.37,降低达到极显著水平 ($P<0.01$)。从图 3 可以看出 BPNN 模型较 OK 模型在

预测误差绝对值上有明显改善。集成神经网络模型 (BPNN-Ada) 在建模集中较 OK 模型相关系数和拟合系数分别增加了 0.22 和 0.30,平均绝对误差降低了 0.99,降低程度达到极显著水平 ($P<0.01$) (表 4);测试集中 BPNN-Ada 模型较 OK 模型相关系数和拟合系数分别增加了 0.40 和 0.43,平均绝对误差降低了 1.59,降低达到极显著水平 ($P<0.01$) (表 5)。从预测能力对比分析结果可以看出 BP 神经网络模型能更好地捕捉自变量与 SOM 含量的复杂非线性关系,这与前人研究结果^[1,7]一致。虽然集成 BP 神经网络模型较 BP 神经网络模型在平均绝对误差的降低程度上没有达到显著水平 ($P>0.05$) (表 3),但从图 3 可以看出,集成 BP 神经网络误差较

低,同时也克服了易陷入全局最优的缺点(图 4),预测结果更加接近实测值。

表 3 3 种模型拟合能力对比分析

Table 3 Comparative analysis of fitting ability of three models

| 模型 | 建模集 | | | 测试集 | | |
|----------|------------------------|-------------|---------------------------|------------------------|-------------|---------------------------|
| | 平均绝对误差 (MAE) (g/kg) | 相关系数 (r) | 拟合系数 (R ²) | 平均绝对误差 (MAE) (g/kg) | 相关系数 (r) | 拟合系数 (R ²) |
| OK | 4.90 | 0.57 | 0.32 | 5.61 | 0.34 | 0.12 |
| BPNN | 4.12 | 0.75 | 0.56 | 4.24 | 0.72 | 0.52 |
| BPNN-Ada | 3.91 | 0.79 | 0.62 | 4.02 | 0.74 | 0.55 |


OK:普通克星金法模型;BPNN:BP 神经网络模型;BPNN-Ada:集成 BP 神经网络模型。

表 4 不同模型下预测绝对误差的 LSD 检验

Table 4 LSD test of absolute errors predicted by different models

| 模型 | 建模集 | | | 测试集 | | |
|----------|-------|-------|----------|-------|-------|----------|
| | OK | BPNN | BPNN-Ada | OK | BPNN | BPNN-Ada |
| OK | 1.000 | | | 1.000 | | |
| BPNN | 0.001 | 1.000 | | 0 | 1.000 | |
| BPNN-Ada | 0 | 0.586 | 1.000 | 0 | 0.279 | 1.000 |

OK、BPNN、BPNN-Ada 见表 3 注。



OK、BPNN、BPNN-Ada 见表 3 注。

图 3 3 种模型测试集的预测误差绝对值

Fig.3 Absolute errors of prediction of different models

2.4 3 种模型预测的插值精度分析

从 3 种模型对 SOM 含量预测的精度对比结果(表 5)可以看出,集成 BP 神经网络模型(BPNN-Ada)较 BP 神经网络模型(BPNN)在建模集预测中均方根误差(RMSE)和平均相对误差(MRE)分别降低了 5.70%、6.94%,测试集预测降低了 3.69%、6.06%;BPNN-Ada 模型较 OK 模型在建模集预测中 RMSE 和 MRE 分别降低了 22.38%、21.77%,测试

集预测分别降低了 29.13%、31.95%;BPNN 模型较 OK 模型在建模集预测中分别降低了 17.68%、15.94%,测试集预测中分别降低了 26.42%、27.56%。从插值精度看,集成神经网络模型预测精度最高,误差最小,而 OK 模型的预测精度最低,误差最大,与表 3 结果一致。BPNN 模型通过把邻近信息引入网络,同时加入高程和坡度,其预测效果明显高于 OK 模型。由 20 个 BPNN 模型集成得到的

集成神经网络模型,不仅提高了非线性函数的逼近效果,而且在一定程度上提高了神经网络的泛化能力(图 3)。

表 5 3 种模型的 SOM 含量预测方法精度对比

Table 5 Comparison of precision of 3 models for predicting SOM content

| 模型 | 建模集 | | 测试集 | |
|----------|-----------------|-----------------|-----------------|-----------------|
| | 均方根误差 (RMSE) | 平均相对误差 (MRE) | 均方根误差 (RMSE) | 平均相对误差 (MRE) |
| OK | 6.39 | 16.63 | 7.38 | 21.19 |
| BPNN | 5.26 | 13.98 | 5.43 | 15.35 |
| BPNN-Ada | 4.96 | 13.01 | 5.23 | 14.42 |

OK、BPNN、BPNN-Ada 见表 3 注。

将 2 种神经网络模型预测趋势项在 MATLAB 中以 30 m 分辨率输出并保存在文本中,在 ArcGIS10.2 中显示,得到神经网络空间分布模拟图(图 4)。由图 4 可以看出,3 种方法模拟的 SOM 含量空间分布均呈西部高而东部低的趋势,主要高值区域分布在西北和正南方向。但 OK 模型预测的 SOM 含量高低值分布较平滑,难以体现 SOM 含量空间变异的细节信息。以高程和坡度为辅助变量,同时加入邻近信息的神经网络模型(BPNN)预测结果高低

值呈块状分布,空间连续性较 OK 模型有所增强,插值精度明显提高,能在一定程度上体现 SOM 含量的空间变异信息,但在局部范围内难以体现 SOM 含量空间位置变化的细节信息,空间模拟效果不强。以 20 个 BP 神经网络模型集成的 BPNN-Ada 模型高低值斑块更加丰富,且区域内出现了较多明显的低值区,该区域内 DEM 要略高于周围区域(图 1),形成了高值区域包含的低值部分,这可能是因为万年县汛期多降雨导致 DEM 较高处受暴雨冲刷相对严重,从而使得 SOM 流失,这比较符合 SOM 地学运动规律与实际情况,BPNN-Ada 模型预测结果揭示了 SOM 随地形变化的细节信息。从预测结果的值域来看,BPNN 神经网络预测的值域最小(26.19 ~ 41.52 g/kg),表明单个神经网络模型预测结果更趋向于平均值,难以克服平滑效应,容易陷入局部最优,而经过集成的 BP 神经网络值域最为接近统计分析值(18.96 ~ 49.24 g/kg),说明经过 Adaboost 重采样的集成 BP 神经网络模型通过不断调整样本权重改善了 BPNN 模型易陷入局部最优而无法得到全局最优解的缺点,提高了 BPNN 模型的拟合精度和泛化能力,使预测结果更加符合 SOM 的地学运动规律以及实际情况。

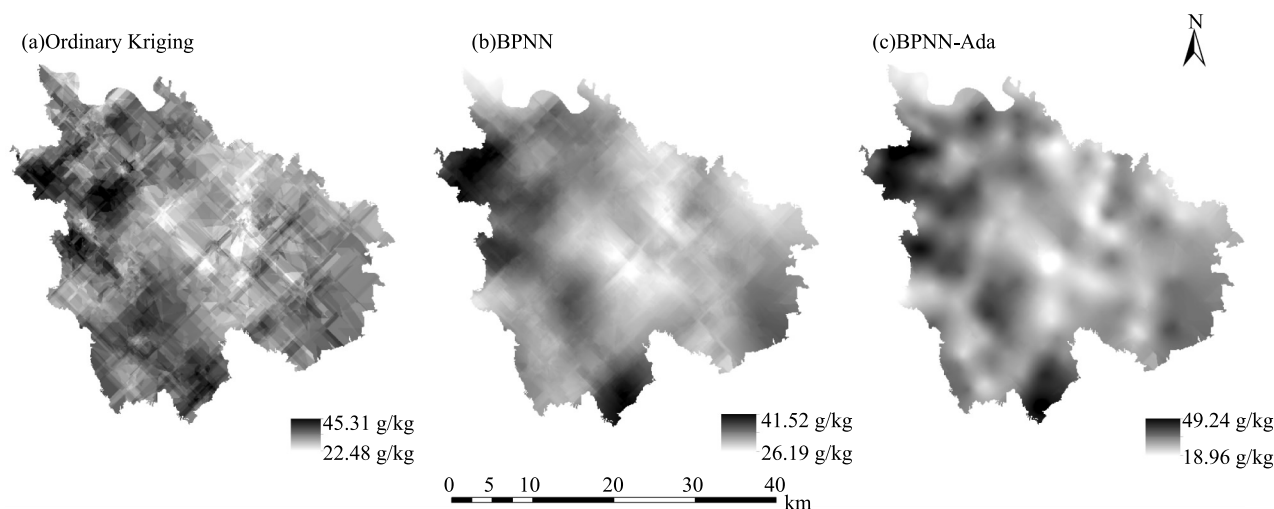


图 4 不同模型下 SOM 含量空间分布预测结果

Fig.4 Prediction results of spatial distribution of SOM content by three models

3 讨论

在 SOM 含量空间分布预测方法中,OK 法是应用最普遍也最具代表性的,虽然能够通过邻近相关

采样点土壤属性值权重来预测未知点,并对预测结果给出误差,但该方法没有考虑地形因子和邻近信息的影响,导致其在制图效果和预测精度上还不理想^[4,17]。而 BP 神经网络模型利用四方位搜索法,

根据 IDW 算法中距离越近影响越大、距离越远影响越小的思想,以地理坐标、高程和坡度以及邻近信息作为网络的输入变量,能够明显提高 SOM 含量的预测精度。但单个 BP 神经网络存在易陷入全局最优和网络结构难以确定等缺点,经过 Adaboost 技术重采样后的集成 BP 神经网络克服了该缺点,预测结果较单个 BP 神经网络模型更为理想。对 191 个测试数据的分析结果显示,集成 BP 神经网络模型的均方根误差、平均绝对误差和平均相对误差较 BPNN 模型分别降低了 3.69%、4.72%、6.06%,相关系数和拟合系数分别提高了 0.02 和 0.03;集成 BP 神经网络模型的均方根误差、平均绝对误差和平均相对误差较 OK 模型分别降低了 29.13%、28.34%、31.95%,相关系数和拟合系数分别提高了 0.40 和 0.43。因此,集成 BP 神经网络模型在 SOM 含量空间分布预测中具有很大的应用价值。

目前对 BP 神经网络进行优化的方式主要有初始权值和阈值的优化、网络结构的优化以及学习规则的优化。本研究只是利用 Adaboost 技术对 BP 神经网络进行集成,达到了对学习规则优化的目的,同时利用四方位搜索法以及 DEM 增加了网络的输入节点数,但是在网络初始权值和阈值方面仍有不足之处,后续研究应引入优化算法(如思维进化算法和遗传算法等)对网络的初始权值和阈值进行优化,也可以尝试利用选择性集成、动态集成、选择性动态集成技术来优化 BP 神经网络,甚至可以将优化算法和集成方式进行结合。此外,还可以引入更多的辅助变量(如地形因子、环境因子、土壤结构性因子甚至时间因子等)作为网络的输入变量来预测 SOM 含量的空间分布。

参考文献:

- [1] 刘二永,刘健,余坤勇,等.基于环境因子和 R-STPS 的林地土壤有机质预测模型[J].农业机械学报,2015,46(1):133-137.
- [2] 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.
- [3] 马泉来,高凤杰,张志民,等.我国东北黑土丘陵区小流域土壤有机质空间分布模拟[J].环境科学研究,2016,29(3):382-390.
- [4] 李启权,王昌全,岳天祥,等.基于定性和定量辅助变量的土壤有机质空间分布预测——以四川三台县为例[J].地理科学进展,2014,33(2):259-269.
- [5] 史舟,李艳.地统计学在土壤学中的应用[M].北京:中国农业出版社,2006.
- [6] 沈掌泉,施洁斌,王珂,等.应用集成 BP 神经网络进行田间土壤空间变异研究[J].农业工程学报,2004,20(3):35-39.
- [7] 董敏,王昌全,李冰,等.基于 GARBF 神经网络的土壤有效磷空间插值方法研究[J].土壤学报,2010,47(1):42-50.
- [8] 李启权,王昌全,岳天祥,等.基于神经网络模型的中国表层土壤有机质空间分布模拟方法[J].地球科学进展,2012,27(2):175-184.
- [9] 沈润平,丁国香,魏国栓,等.基于人工神经网络的土壤有机质含量高光谱反演[J].土壤学报,2009,46(3):391-397.
- [10] 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.
- [11] 陈明.MATLAB 神经网络原理与实例精解[M].北京:清华大学出版社,2013.
- [12] HANSEN L K, SALSMON P. Neural network ensembles[J]. IEEE Trans Pattern Analysis and Machine Intelligence, 1990,12(10):993-1001.
- [13] SCHAPIRE R E. The strength of weak learnability[J]. Machine Learning, 1990,5(2):197-227.
- [14] FREUND Y, SCHAPIRE R E. A decision-theoretic generalization of on-line learning and an application to boosting[J]. Journal of Computer and System Sciences, 1997,55(1):119-139.
- [15] 沈掌泉.神经网络集成技术及其在土壤学中的应用的研究[D].杭州:浙江大学,2005.
- [16] 徐剑波,宋立生,夏振,等.基于 GARBF 神经网络的耕地土壤有效磷空间变异分析[J].农业工程学报,2012,28(16):158-165.
- [17] 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.
- [18] 王玉璟.空间插值算法的研究及其在空气质量监测中的应用[D].郑州:河南大学,2010.
- [19] 张甘霖,龚子同.土壤调查实验室分析方法[M].北京:科学出版社,2012.
- [20] 王丹丹,史学正,于东升,等.东北地区旱地土壤有机碳密度的主控自然因素研究[J].生态环境学报,2009,18(3):1049-1053.
- [21] 吴俊利,张步涵,王魁.基于 Adaboost 的 BP 神经网络改进算法在短期风速预测中的应用[J].电网技术,2012,36(9):221-225.
- [22] 朱会义,刘述林,贾绍凤.自然地理要素空间插值的几个问题[J].地理研究,2004,23(4):425-432.

(责任编辑:张震林)