

海涂围垦区土壤盐分空间变异模拟的比较研究*

姚荣江 杨劲松[†] 韩建均

(中国科学院南京土壤研究所, 南京 210008)

摘要 以苏北海涂围垦区为例, 利用人工神经网络(ANN)、普通克里格(OK)插值和序贯高斯模拟(SGS)对典型地块土壤盐分空间分布进行了模拟、插值与预测, 获取了各方法的优化结构与参数, 并就各方法对土壤盐分分布特征与空间结构的预测能力进行了比较分析。结果表明: ANN、OK 和 SGS 法均较好地模拟和预测了土壤盐分的空间分布, 达到了较高模拟、插值与预测精度; ANN 获得的土壤盐分空间分布最为连续, SGS 法整体分布相对离散; ANN 能较好地预测盐分较低的样点, 但 ANN 对高盐分样点的预测结果不如 SGS 和 OK; SGS 预测结果最符合实测值的波动特点, ANN 预测结果波动范围最窄, SGS 较 ANN 和 OK 更能反应数据随机变量的结构性和波动性, 在整体上要优于 ANN 和 OK 法。该结果为滨海地区盐渍土壤的精准评估与高效改良提供了参考依据。

关键词 海涂; 土壤盐分; 空间变异; 模拟; 优化模型

中图分类号 S158.3 **文献标识码** A

精确农业中经常对土壤属性进行估值、模拟和制图以描述土壤属性的空间变异情况, 给出土壤属性的空间分布图及未知点的估计值。目前, 地统计学的克里格插值法被广泛用于对土壤属性的空间分布进行预测^[1-3]。然而大量研究发现, 克里格插值对数据分布具有特殊要求, 其具有的平滑效应会使得空间数据变化剧烈区域的重要信息丢失, 且克里格插值存在着由于估计值与实际值之间的偏差导致的不确定性^[4-5]。近年来, 诸多方法包括随机模拟、时序分析、人工智能等被用以克服克里格法的缺陷。这些方法或将空间数据作为一个整体来复原其空间结构以尽可能地接近真实的空间分布^[6-7], 或利用空间变异周期序列特点以构建空间状态模型^[8], 或是基于一种具有自学习、自组织能力大规模并行的非线性动态运算系统^[9-10], 目前这些方法在精准农业中越来越受到重视。

在土壤属性空间变异研究方面, 这些方法均有一定的应用实例。如屈忠义等^[11]对冻土水盐空间变异进行条件模拟, 并与普通克里格和人工神经网络结果进行对比; 沈掌泉等^[12]应用集成 BP 神经网络进行田间土壤性质空间变异研究, 并与广泛应

用的克里格法的试验结果进行精度比较; 陈亚新等^[13]进行两种田间尺度水盐空间变异性的随机模拟, 并与普通克里格法估值进行比较。陈翠英等^[14]利用随机模拟技术进行土壤养分空间变异性研究和空间分布不确定性评价。本研究以苏北海涂围垦区典型地块为例, 利用人工神经网络(Artificial Neural Network, ANN)、普通克里格(Ordinary Kriging, OK)和序贯高斯模拟(Sequential Gaussian Simulation, SGS)方法进行了土壤盐分空间变异研究, 确定了各种方法的优化结构与参数, 量化比较了各方法对土壤盐分分布特征与空间结构的预测能力, 为围垦区盐渍土壤的利用评估与高效改良提供了理论依据。

1 材料与方法

1.1 研究区概况

研究区域位于江苏省大丰市金海农场, 东距黄海约 4 km, 西临大丰麋鹿国家级自然保护区, 于 1999 年围垦。该区地处北亚热带季风气候区, 具有明显的过渡性、海洋性和季风性, 年降水量主要集中在 6 ~

* 公益性行业(农业)科研专项经费项目(200903001)、国家自然科学基金项目(41101199)、江苏省企业院士工作站项目(BM2009622)、江苏省自然科学基金项目(BK2009337; BK2011423)、江苏省产学研前瞻性联合研究项目(BY2011195)和江苏省科技支撑计划项目(BE2010313)资助

[†] 通讯作者: 杨劲松(1959—), 博士, 研究员, 博士生导师, 主要研究领域为土壤和水资源利用与管理。E-mail: jsyang@issas.ac.cn

作者简介: 姚荣江(1980—), 男, 江苏靖江人, 博士, 助理研究员, 主要从事水土资源空间变异与溶质运移研究。E-mail: rjyao@issas.ac.cn

收稿日期: 2011-04-23; 收到修改稿日期: 2011-08-26

8 月份的雨季。由于缺乏蓄水工程,农田灌溉一般采用当地微咸水(主要是上游东台河水)。研究区域地下水埋深 1.5~2.0 m,矿化度平均 8.5 g L^{-1} ,土壤质地以砂壤土为主,盐渍化是制约该地区农业生产发展的主要障碍因子。尽管已连续垦种多年,研究区域土壤盐分的变异程度仍相当显著,局部部位作物生长状况差异较大。

1.2 样品采集与分析

本研究选择的地块位于研究区域西南部位,面积为 0.69 hm^2 ($48 \text{ m} \times 144 \text{ m}$),呈南北狭长形。研究地块北部土壤盐分总体较低,部分种植蔬菜,其余均种植棉花,受盐分变异性的影响棉花长势差异较大,局部为裸露盐斑地。在研究地块进行网格布点采样,采样点平均间距约 4 m,在地块最南部进行加密采样,平均间距约 2.5 m,每个样点均对 0~20 cm 表土层进行采样,为保证样品的代表性,各样点均在中心点和相邻的 3 个角采集土样,并混合组成待测样品。本研究共计采集 285 个样点的表土层混合土样,所有样点的空间分布如图 1 所示。

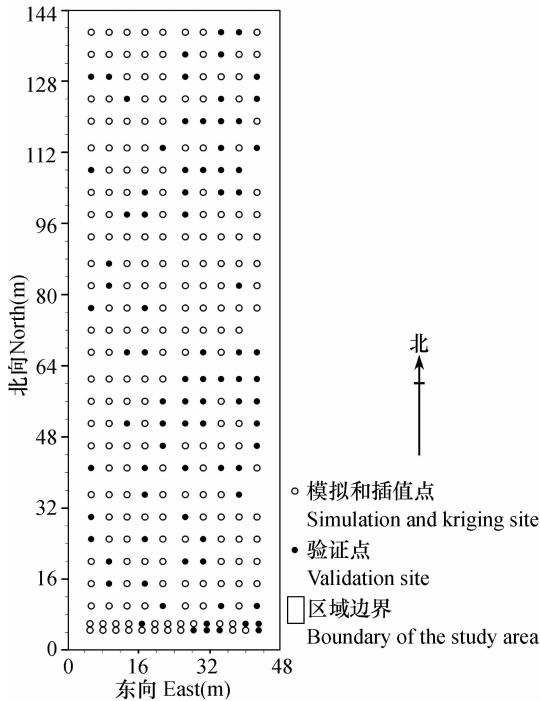


图 1 土壤盐分采样点、模拟、插值点与验证点的空间分布

Fig. 1 Geographic location of sampling sites, simulation sites and kriging sites and validation sites for soil salinity

采集的土样带回实验室内自然风干,磨碎、过 2 mm 筛后备用。所有的土样均制备 1:5 土水比浸提液,并测定其电导率 $EC_{1:5}$ 。具体测定方法参考文献[15]。本文采用土壤电导率 $EC_{1:5}$ 表征土壤盐渍

化程度,主要考虑到滨海滩涂区土壤全盐含量和电导率 $EC_{1:5}$ 之间有极显著的相关性,且土壤浸提液电导率较全盐含量能更真实地反映田间土壤盐渍化状况。

1.3 研究方法

分别运用人工神经网络、普通克里格和序贯高斯模拟方法对土壤盐分空间分布进行模拟、插值和预测,有关各方法的原理很多文献有详细介绍^[16-19]。为量化比较这 3 种方法对土壤盐分分布特征与空间结构的预测能力,本研究从 285 个样点数据中随机抽取 30% (85 个) 作为验证数据集,用于各方法预测精度的独立验证与对比,其余 200 个样点数据作为训练数据集(人工神经网络)、插值数据集(普通克里格)和模拟数据集(序贯高斯模拟),用于各方法优化结构与最佳参数的确定。模拟和插值点以及验证点的空间位置见图 1。

2 结果与分析

2.1 人工神经网络

本文应用类神经网络仿真软件 NeuroSolutions 5.0 构建 BP 神经网络,对不同隐含层神经元个数的 3 层网络进行训练、检验和预测。为获得神经网络优化参数并防止网络训练“过拟合”现象,在样本训练前,对 200 组网络训练数据进行分类,从中随机抽取 20% (40 组) 用作交叉验证,其余 160 组数据用于网络训练。以采样点的经、纬坐标为输入因子,以土壤盐分为输出因子,隐含层、输出层的传递函数使用 TanhAxon 双曲正切函数,学习函数选用 Momentum 学习法则,网络训练最大迭代次数 (Epoch) 设为 1 000 次,并采用遗传算法 (Genetic Algorithm, GA) 确定最优化网络结构及其参数,计算结果表明当 Momentum 学习速率 l_r 取 0.08、隐含层 PEs (神经元) 数量为 8 时,得到的训练误差和交叉验证误差收敛速度最快、泛化能力最强,因而本研究土壤盐分的 BP 网络的最佳拓扑结构定为 2:8:1。图 2a 显示了网络训练误差和交叉验证误差随迭代次数的变化关系,利用该网络拓扑结构和参数对 200 组数据进行仿真,得到的土壤盐分实测值与模拟值之间的关系如图 2b 所示(文中只给出一次模拟结果)。可以看出,土壤盐分实测值和模拟值间的相关系数 r 达到 0.607 0,在 1% 置信水平上表现为极显著 ($r_{0.01} = 0.181, n = 200$),具有较高仿真精度并可用于土壤盐分的预测。

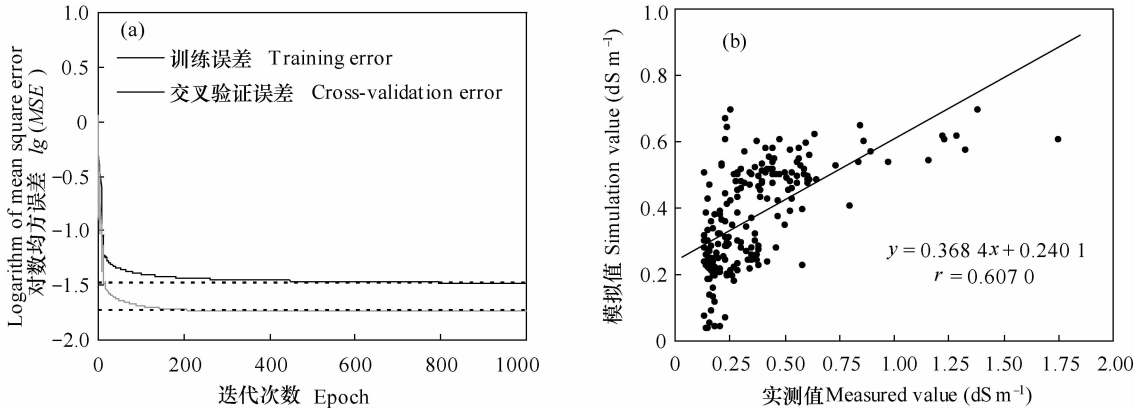


图2 土壤盐分网络训练误差曲线以及实测值与模拟值的散点图

Fig. 2 Network training error curve and scatter plot of measured values and simulated values of soil salinity

2.2 普通克里格

结合普通克里格方法 (Ordinary Kriging, OK), 本研究运用插值数据集 (200 个样点) 进行土壤盐分空间估值, 并利用验证数据集 (85 个样点) 进行空间预测的准确性检验。文中半方差函数分析、参数拟合、交叉验证与精度检验、克立格插值均是在 GS + 7.0 软件中完成的。

土壤盐分不同方向半方差函数 (包括 $\text{NE}0^\circ$ 、 $\text{NE}30^\circ$ 、 $\text{NE}60^\circ$ 和 $\text{NE}90^\circ$ 4 个方向) 及其空间插值的 Jackknife 交叉验证结果见图 3。由图可知, 尽管不同

方向土壤盐分半方差函数存在差异, 但各方向上的块金值、基台值和变程差异较小, 且其平均各向异性比为 1.11, 并不存在几何和带状各向异性, 故可以认为其是各向同性的。各向同性下土壤盐分表现出较好的空间结构性, 拟合获得的半方差参数列于图 3a。在插值数据点上, 土壤盐分预测值和实测值间平均误差 ME 、均方误差 $RMSE$ 仅分别为 0.001 1 和 0.125 0, 其相关系数 r 达 0.874 1 (图 3b), 表明普通克里格方法对土壤盐分空间插值的精度和可信度较高。

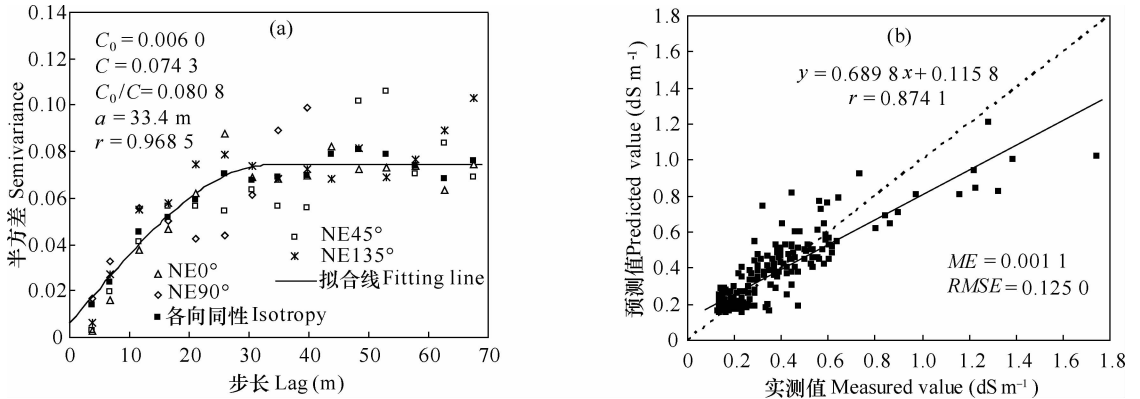


图3 土壤盐分半方差函数及其空间插值的交叉验证结果

Fig. 3 Semivariogram and cross-validation of spatial interpolation of soil salinity

2.3 随机模拟

一般而言, 随机模拟方法主要有序贯高斯模拟 (Sequential Gaussian simulation, SGS)、序贯指示模拟 (Sequential indicator simulation, SIS) 和截断高斯模拟 (Truncated Gaussian simulation, TGS) 3 种。序贯高斯模拟 SGS 是应用高斯概率理论和序贯模拟算法产生连续变量空间分布的一种随机模拟方法。该方法比较简单、灵活, 计算效率高, 所以是条件高

斯随机模拟中最常用的方法之一^[20]。本研究利用斯坦福大学地质统计建模软件 S-GeMS 对模拟数据集 (200 个样点) 的土壤盐分实测数据进行序贯高斯随机模拟, 计算结果生成一系列土壤盐分随机模拟空间分布图, 分布图的个数可以根据要求确定, 每个分布图均满足相同的约束条件, 被认为是等概率的, 即每一个分布图均被认为是实际土壤盐分分布的一个现实。本研究共生成 10 个序列的随机模拟

结果,利用验证数据集(85 个样点)对空间模拟结果(取 10 个序列的平均值)的准确性进行检验,图 4 显示了其中 5 次模拟结果获得的土壤盐分随机模拟分布图。

2.4 空间分布特征比较

图 5 显示了人工神经网络(ANN)模拟、普通克里格(OK)插值和序贯高斯模拟(SGS)(10 次随机模拟平均值)得到的土壤盐分空间分布图。无论是插值还是模拟,均可以明显看出研究区表现出东部和南部土壤盐分含量较高、中部和西部盐分较低的

分布特点。总体看来,ANN 模拟结果的数据分布最平缓,其空间分布图整体比较连续和平滑(图 5a),条带状特征明显;其次是普通克里格 OK,呈现条带状与斑块状特点;SGS 整体分布相对离散,突出了原始数据分布的局部波动性,降低了空间分布的连续性。显然,ANN 和 OK 均一定程度减小土壤盐分空间分布的变异性。事实上,插值主要是对某一空间属性进行估计和预测,其追求的是一种优化的结果,而随机模拟是通过某一空间属性进行随机建模来考察变量的不确定性,其结果不是最优的,




图 4 土壤盐分序贯高斯模拟分布图

Fig. 4 Spatial distribution of soil salinity simulated with the sequential Gaussian method




图 5 土壤盐分人工神经网络、普通克里格与序贯高斯模拟分布图

Fig. 5 Spatial distributions of soil salinity simulated with the artificial neural network, ordinary kriging and sequential Gaussian methods

但其主要目的是在模拟值接近真实值的前提下,再现变量的空间不确定性。因此,经常将随机模拟现实作为蒙特卡罗模拟或其他模型的输入数据,由同一数据系列的多个模拟现实得到多个模型输出结果,可计算输出结果的统计规律,也可以分析输入数据与输出结果的统计关系,以及模型的灵敏度等^[21]。

2.5 预测精度对比分析

分别采用上文的人工神经网络(ANN)、普通克里格(OK)和序贯高斯模拟(SGS)对 85 个验证数据点的土壤盐分进行预测,获得的各验证点土壤盐分预测值、实测值的统计特征与验证结果列于表 1。从 3 种方法对土壤盐分预测值的统计与验证对比看出,SGS 和 OK 的预测结果总体要好于 ANN,ANN

能较好地预测土壤盐分较低的样点,但对于高盐分样点 ANN 的预测结果不如 SGS 和 OK,在精度检验上 ANN 要逊于 SGS 和 OK。表 1 的统计结果亦表明 SGS 获得的土壤盐分分布与实测值最为接近,更符合实测值的波动特点;其次是普通克里格 OK;ANN 预测结果波动最窄,也最为平滑。从变异系数 CV 来看,ANN 的 CV 明显小于 OK 和 SGS,说明 ANN 在反映数据波动性和变异性方面不如 OK 和 SGS 法。从反映数据离散程度的方差 σ^2 来看,由于 ANN 显著的平滑效应,使得 ANN 的估计方差小于 OK 和 SGS ($\sigma_{SGS}^2 = 3.82\sigma_{ANN}^2, \sigma_{SGS}^2 = 1.27\sigma_{OK}^2$),进一步表明 SGS 在尊重原始数据分布的前提下,更大程度地再现了数据的波动性与空间结构性。

表 1 不同方法下土壤盐分预测值和实测值的统计特征与验证结果

Table 1 Descriptive statistics and validation of measured values and predicted values of soil salinity using different methods


土壤盐分 Soil salinity (dS m ⁻¹)	最小值 Min.	中位值 Median	平均值 Mean	最大值 Max.	方差 Var.	变异系数 CV(%)	平均误差 ME	均方误差 MSE	相关系数 r
人工神经网络 ANN	0.130	0.408	0.392	0.579	0.011	26.64	-0.547	0.310	0.612
普通克里格 OK	0.141	0.385	0.410	0.882	0.033	44.30	-0.529	0.286	0.729
序贯高斯模拟 SGS	0.126	0.416	0.444	1.145	0.043	45.95	-0.485	0.251	0.784
实测值 Measured value	0.137	0.339	0.432	1.355	0.083	66.64			

变异函数是反映空间数据分布特征和变异程度的主要工具,通过将实测值与 ANN、OK 和 SGS 预测值的变异函数进行对比分析,可进一步说明不同方法的优劣。图 6 显示了 3 种方法下土壤盐分预测值和实测值的变异函数。可以看出 SGS、OK 和 ANN 的变异函数均在实测值变异函数的下方,这主要是由于平滑效应造成的变异函数减小,其中 ANN

的平滑效应最为明显,其次是 OK,SGS 与实测值最为接近,说明 SGS 的变异函数较 ANN 和 OK 更能反映数据随机变量的结构性,在整体上要优于 ANN 和 OK 法,这与上文的分析结果也是一致的。

3 结 论

人工神经网络 ANN 是一种与普通克里格 OK 和随机模拟 SGS 运算目标类似的空间变量估值方法;从数据模拟的角度看,ANN、OK 和 SGS 方法均较好地模拟和预测了土壤盐分的空间分布与结构,达到了较高的模拟、插值与预测精度。从预测精度检验结果可知:SGS 和 OK 的预测结果总体要好于 ANN,ANN 能较好地预测土壤盐分较低的样点,但对于高盐分样点 ANN 的预测结果不如 SGS 和 OK;SGS 预测结果最符合实测值的波动特点,ANN 预测结果波动范围最窄,ANN 在反映数据波动性和变异性方面不如 OK 和 SGS。由预测结果的分布特征和变异程度来看,ANN 变异函数的平滑效应最为明显,其次是 OK,SGS 与实测值最为接近。从模拟、检验、估值、统计参数与变异函数等方面对比,SGS 较 ANN 和 OK 更能反映数据随机变量的结构性和波动



• 实测值 Measured value — 拟合线 Fitting line
 △ ANN 预测值 ANN value ANN 拟合线 ANN fitting line
 * OK 预测值 OK value - - - - - OK 拟合线 OK fitting line
 ◇ SGS 预测值 SGS value - · - · - SGS 拟合线 SGS fitting line

图 6 不同方法下土壤盐分预测值和实测值半方差函数对比

Fig. 6 Comparison of semivariograms of the measured values with respective predicted values of soil salinity using different methods

性,在整体上要优于 ANN 和 OK 法。

参考文献

- [1] van Meirvenne M, Goovaerts P. Evaluating the probability of exceeding a site-specific soil cadmium contamination threshold. *Geoderma*, 2001, 102: 75—100
- [2] Cattle J A, McBratney A B, Minasny B. Kriging method evaluation for assessing the spatial distribution of urban soil lead contamination. *Journal of Environmental Quality*, 2002, 31: 1 576—1 588
- [3] 胡克林, 张凤荣, 吕贻忠, 等. 北京市大兴区土壤重金属含量的空间分布特征. *环境科学学报*, 2004, 24(3): 463—468. Hu K L, Zhang F R, Lü Y Z, et al. Spatial distribution of concentrations of soil heavy metals in Daxing County, Beijing (In Chinese). *Acta Scientiae Circunantiae*, 2004, 24(3): 463—468
- [4] Goovaerts P. *Geostatistics for natural resources evaluation*. New York: Oxford University Press, 1997
- [5] Wang G, Gertner G, Parysow P, et al. Spatial prediction and uncertainty analysis of topographic factors for the revised soil losses equation (RUSLE). *Journal of Soil and Water Conservation*, 2000, 55(3): 374—384
- [6] Deutsch C V, Journel A G. *GSLIB: Geostatistical software library and user's guide*. New York: Oxford University Press, 1998
- [7] 史舟, 李艳, 程街亮. 水稻土重金属空间分布的随机模拟和不确定评价. *环境科学*, 2007, 28(1): 209—214. Shi Z, Li Y, Cheng J L. Stochastic simulation of spatial distribution and uncertainty assessment of heavy metal in paddy soil (In Chinese). *Chinese Journal of Environmental Science*, 2007, 28(1): 209—214
- [8] 李艳, 史舟, 徐建明, 等. 地统计学在土壤科学中的应用及展望. *水土保持学报*, 2003, 17(1): 178—182. Li Y, Shi Z, Xu J M, et al. Utilization and perspective of geostatistics in soil sciences (In Chinese). *Journal of Soil and Water Conservation*, 2003, 17(1): 178—182
- [9] 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. *农业工程学报*, 2004, 20(3): 120—123. He Y, Zhang S J, Fang H. Interpolation method of field information based on the artificial neural network (In Chinese). *Transactions of the CSAE*, 2004, 20(3): 120—123
- [10] 王明新, 吴文良, 刘文娜. 基于 GIS 和 BP 神经网络的农区地下水硝态氮含量分布特征分析. *农业工程学报*, 2006, 22(12): 39—43. Wang M X, Wu W L, Liu W N. Spatial analysis of groundwater $\text{NO}_3^- - \text{N}$ concentration in agriculture-dominated regions based on GIS-based BPNN (In Chinese). *Transactions of the CSAE*, 2006, 22(12): 39—43
- [11] 屈忠义, 陈亚新, 杨靖宇. 人工神经网络在冻土水盐空间变异与条件模拟中的应用比较. *农业工程学报*, 2007, 23(7): 48—53. Qu Z Y, Chen Y X, Yang J Y. Application and comparison research of artificial neural network on conditional simulation and space variability of water-salt for frozen earth (In Chinese). *Transactions of the CSAE*, 2007, 23(7): 48—53
- [12] 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. *农业工程学报*, 2004, 20(3): 35—39. Shen Z Q, Shi J B, Wang K, et al. Spatial variety of soil properties by BP neural network ensemble (In Chinese). *Transactions of the CSAE*, 2004, 20(3): 35—39
- [13] 陈亚新, 史海滨, 田圃德, 等. 水盐空间变异性监测的条件模拟. *水利学报*, 2000, 31(6): 67—73. Chen Y X, Shi H B, Tian P D, et al. Study on conditional simulation of soil water-salt spatial variability monitoring (In Chinese). *Journal of Hydraulic Engineering*, 2000, 31(6): 67—73
- [14] 陈翠英, 江永真. 土壤养分空间变异性的随机模拟及其应用. *农业机械学报*, 2006, 37(12): 67—71. Chen C Y, Jiang Y Z. Stochastic simulation of spatial variability of soil nutrient property and its application (In Chinese). *Transactions of the CSAM*, 2006, 37(12): 67—71
- [15] 鲁如坤. *土壤农业化学分析方法*. 北京: 中国农业科技出版社, 1999: 90—99. Lu R K. *Analytical methods of soil and agro-chemistry* (In Chinese). Beijing: China Agricultural Science and Technology Press, 1999: 90—99
- [16] 屈忠义, 陈亚新, 史海滨, 等. 地下水文预测中 BP 网络的模型结构及算法探讨. *水利学报*, 2004, 35(2): 88—93. Qu Z Y, Chen Y X, Shi H B, et al. Structure and algorithm of BP Network for underground hydrology forecasting (In Chinese). *Journal of Hydraulic Engineering*, 2004, 35(2): 88—93
- [17] 刘全明, 陈亚新, 魏占民, 等. 非参数统计理论与人工智能技术在水土空间变异中的应用研究. *灌溉排水学报*, 2006, 25(1): 49—53. Liu Q M, Chen Y X, Wei Z M, et al. Applied research based on the non-parametric approach and artificial intelligence computing technique in water soil spatial variation (In Chinese). *Journal of Irrigation and Drainage*, 2006, 25(1): 49—53
- [18] 陈亚新, 徐英, 史海滨, 等. 条件模拟原理和技术进展及在水资源系统中的应用. *水科学进展*, 2002, 13(2): 246—252. Chen Y X, Xu Y, Shi H B, et al. Theory, development and application of the conditional simulation in water resources system (In Chinese). *Advances in Water Science*, 2002, 13(2): 246—252
- [19] 胡克林, 李保国, 陈研. 表层土壤饱和和导水率的空间变异对农田水分渗漏的影响. *水利学报*, 2006, 37(10): 1 217—1 223. Hu K L, Li B G, Chen Y. Effect of spatial variability of surface soil saturated hydraulic conductivity on water drainage at field scale (In Chinese). *Journal of Hydraulic Engineering*, 2006, 37(10): 1 217—1 223
- [20] Pendrel J, Leggett M, Mesdag P, et al. Geostatistical simulation for reservoir characterization. 2004 CSEG National Convention, 2004
- [21] 张泽浦, 王学军. 土壤微量元素含量空间分布的条件模拟. *土壤学报*, 1998, 35(3): 423—429. Zhang Z P, Wang X J. Conditional simulation for spatial distribution of trace elements in soils (In Chinese). *Acta Pedologica Sinica*, 1998, 35(3): 423—429

COMPARATIVE STUDY OF SIMULATIONS OF SPATIAL VARIABILITY OF SOIL SALINITY IN COASTAL POLDERS

Yao Rongjiang Yang Jingsong[†] Han Jianjun

(*Institute of Soil Science, Chinese Academy of Sciences, Nanjing 210008, China*)

Abstract Artificial neural network (ANN), ordinary kriging (OK) and sequential Gaussian simulation (SGS) was introduced separately to simulation, interpolation and prediction of spatial distribution of soil salinity in a field typical of the coastal polder in North Jiangsu, to work out optimal structures and parameters of various methods for comparison of the methods in efficiency of predicting distribution characteristics and spatial structure of soil salinity. Results show that all the three methods, ANN, OK and SGS, were quite good at simulating and predicting spatial distribution of soil salinity and displayed quite high accuracy in the simulation, interpolation and prediction. The spatial distribution obtained by the ANN method was the most continuous and smooth, while that obtained by the SGS method was relatively discrete and fluctuant. The ANN method exhibited a relatively high prediction accuracy at sites of low soil salinity, but a much lower accuracy than the SGS and OK did at sites of high soil salinity. Furthermore, the prediction of SGS tallied the most with the fluctuation trait of measured value, and the narrowest fluctuation range was observed in prediction using the ANN method. The SGS method was better than the ANN and OK methods at reflecting spatial structure and fluctuation of the random variables of data, indicating that SGS is superior to ANN and OK as a whole. The findings may be cited as reference for precision assessment and high-efficiency amelioration of saline soil in coastal polders.

Key words Coastal tidal mud flat; Soil salinity; Spatial variability; Simulation; Optimal model