

DOI: 10.11766/trxb202101240043

解雪峰, 濮励杰, 沈洪运, 吴涛, 朱明, 黄思华. 滨海重度盐碱地改良土壤盐渍化动态特征及预测[J]. 土壤学报, 2022, 59(6): 1504–1516.
XIE Xuefeng, PU Lijie, SHEN Hongyun, WU Tao, ZHU Ming, HUANG Sihua. Dynamics and Prediction of Soil Salinization Parameters under the Amelioration of Heavy Coastal Saline-alkali Land[J]. Acta Pedologica Sinica, 2022, 59 (6): 1504–1516.

滨海重度盐碱地改良土壤盐渍化动态特征及预测^{*}

解雪峰^{1, 2}, 濮励杰^{2, 3†}, 沈洪运^{2, 3}, 吴涛¹, 朱明^{2, 3}, 黄思华^{2, 3}

(1. 浙江师范大学地理与环境科学学院, 浙江金华 321004; 2. 自然资源部海岸带开发与保护重点实验室, 南京 210023; 3. 南京大学地理与海洋科学学院, 南京 210023)

摘要: 试验设置了对照处理 (CK)、有机肥 (OM)、聚丙烯酰胺+有机肥 (PAM+OM)、秸秆覆盖+有机肥 (SM+OM)、秸秆深埋+有机肥 (BS+OM) 和生物菌肥+有机肥 (BM+OM) 6 个处理方式来探讨滨海盐碱地不同改良方式对土壤含盐量、pH、钠吸附比 (SAR) 和碱化度 (ESP) 的影响, 进而识别影响土壤盐渍化程度的主要因子, 并构建多元线性回归模型 (Multi-linear Regression, MLR)、BP 神经网络模型 (BP Artificial Neural Network, BP-ANN) 和随机森林模型 (Random Forest, RF) 对滨海重度盐碱地改良背景下的土壤盐渍化参数进行模拟预测。研究结果表明: 各改良措施均能有效地降低表层土壤盐渍化水平, 其中 SM+OM 处理对于土壤含盐量的抑制效果最好, 而 BM+OM 处理则对于土壤碱分的抑制效果最好。改良过程中气象条件和土壤性质均对表层土壤盐渍化水平产生了显著影响。在模型预测中, 随机森林模型对土壤含盐量、pH、SAR 和 ESP 的综合预测精度明显优于 BP 神经网络模型和多元线性回归模型, 体现在随机森林模型具有较高决定系数 (Coefficient of determination, R^2) 和纳什系数 (Nash-sutcliffe efficiency coefficient, NSE) 和较低的均方根误差 (Root mean square error, RMSE)。

关键词: 土壤盐渍化参数; 滨海盐碱地; 动态预测; 随机森林模型; BP 人工神经网络模型

中图分类号: S156 **文献标志码:** A

Dynamics and Prediction of Soil Salinization Parameters under the Amelioration of Heavy Coastal Saline-alkali Land

XIE Xuefeng^{1, 2}, PU Lijie^{2, 3†}, SHEN Hongyun^{2, 3}, WU Tao¹, ZHU Ming^{2, 3}, HUANG Sihua^{2, 3}

(1. College of Geography and Environmental Sciences, Zhejiang Normal University, Jinhua, Zhejiang 321004, China; 2. Key Laboratory of the Coastal Zone Exploitation and Protection of Ministry of Natural Resources, Nanjing 210023, China; 3. School of Geography and Ocean Science, Nanjing University, Nanjing 210023, China)

Abstract: 【Objective】 Soil salinization is one of the main types of land degradation, which seriously inhibits the improvement of soil quality and the growth and grain yield of crops. Reclamation of coastal land is increasingly being used as a means of

* 国家自然科学基金项目 (42101068, 41871083, 42171245) 和浙江省自然科学基金项目 (LQ21D010007) 资助 Supported by the National Natural Science Foundation of China (Nos. 42101068, 41871083 and 42171245) and Natural Science Foundation of Zhejiang Province (No. LQ21D010007)

† 通讯作者 Corresponding author, E-mail: ljiu@nju.edu.cn

作者简介: 解雪峰 (1991—), 男, 博士, 讲师, 主要从事土地利用及其环境效应研究。E-mail: xiexuefeng2008@126.com

收稿日期: 2021-01-24; 收到修改稿日期: 2021-05-27; 网络首发日期 (www.cnki.net): 2021-09-28

raising agricultural productivity and improving food security in China. Determining the importance of potential influencing factors of soil salinization parameters and thus predicting their concentrations are important for formulating targeted control measures to improve soil quality and crop yield in tidal flat reclamation areas. **【Method】** In this study, six treatments including control (CK), organic manure (OM), polyacrylamide plus organic manure (PAM+OM), straw mulching plus organic manure (SM+OM), buried straw plus organic manure (BS+OM), and bio-organic manure plus organic manure (BM+OM) were applied to explore the effect of different reclamation treatments on different soil parameters. The effect of all treatments on soil salt content (SSC), pH, sodium adsorption ratio (SAR), and exchange sodium percentage (ESP) was analyzed and the main factors affecting the degree of soil salinization were identified. Thereafter, the multi-linear regression model (MLR), BP artificial neural network model (BP-ANN), and random forest model (RF) were conducted to predict the soil salinization parameters (SSC, pH, SAR, and ESP) using covariates, such as air temperature, precipitation, evaporation, wind speed, soil water content, soil temperature, and soil bulk density. **【Result】** The results indicated that the concentration of SSC, SAR, and ESP gradually increased, while the pH gradually decreased during the oat growing stage. All reclamation treatments effectively reduced the level of surface soil salinization. Among them, SM+OM treatment had the best inhibition effect on SSC, whereas BM+OM treatment had the best inhibition effect on soil pH, SAR and ESP. Besides, both meteorological parameters and soil properties had a significant impact on the level of surface soil salinization during the amelioration of coastal saline-alkali land. Additionally, the RF model performed much better than BP-ANN and MLR as it revealed a much higher coefficient of determination (R^2) and Nash-Sutcliffe efficiency (NSE), and lower root mean square error (RMSE) than BP-ANN and MLR model. **【Conclusion】** The above results indicate that the reclamation treatments can effectively inhibit soil evaporation, improve soil structure, increase soil water holding capacity, and thus reduce the salinization level of surface soil. Our results also suggest that the RF model is a more powerful modeling approach in predicting soil salinization dynamics of coastal saline-alkali land due to its advantages in handling the nonlinear and hierarchical relationships between soil salinization parameters and covariates, and insensitivity to overfitting and the presence of noise in the data. Thus, our findings could provide a reference for predicting the soil salinization parameters in areas with similar environmental conditions.

Key words: Soil salinization parameter; Coastal saline soil; Dynamic prediction; Random forest model; BP- artificial neural network model

土壤盐渍化是土地退化的主要形式之一, 严重抑制了土壤性质的改善和作物的生长发育^[1], 成为制约滨海滩涂围垦区土壤质量和作物产量的最主要因子^[2]。由于滨海滩涂土壤中含有大量的 Na^+ 、 Cl^- 等可溶性盐基离子, 使得植物遭受生理缺水和毒害胁迫, 引起植物发育不良或直接死亡^[3-5]。因此, 调控土壤水盐动态, 摸清土壤水盐运移规律, 开展土壤水盐动态预测, 制定针对性调控措施是提升滩涂围垦区土壤质量和作物产量的基础^[6]。土壤水盐动态是指土壤水分和盐分受各种因素共同影响下随时间和空间变化的动态过程^[7]。土壤水盐动态预测可以为盐渍化土壤改良提供保障和支持, 抑制土壤返盐。多年来我国对不同自然气候条件及不同改良措施条件下的土壤水盐动态的运移特征和影响因素开展了大量研究^[8-10], 并在此基础上对盐渍化土壤水盐运移特征进行模拟预测^[11-14]。近年来, 人工神经网络模型、支持向量机模型、分类与回归树模型和

随机森林模型等机器学习方法在土壤属性预测上得到广泛应用^[15-18]。与传统方法相比, 此类方法结构简单, 拟合能力强, 预测精度高, 省去了采样、分析中的人力、物力、时间等引起的麻烦, 为盐渍化土壤的评估和预报提供了一种方便快捷的新途径^[19-20]。本研究在厘清不同方式下土壤水盐动态特征及主控因素的基础上^[21], 通过多元线性回归模型、BP 神经网络模型和随机森林模型对滨海重度盐碱地改良背景下的土壤盐渍化参数进行模拟预测, 通过对比各模型的精度, 以期为盐渍化土壤改良提供支持。

1 材料与方法

1.1 试验设计

试验田块于2016年9月在江苏省南通市通州湾滨海园区建立(32°11' N, 121°22' E), 属北亚热带

季风性湿润气候,多年平均降水量和多年平均气温分别为1 029 mm和15.0℃;地下水埋深为1.2~1.8 m。试验区于2008年围垦,主要用于海水养殖;土壤来源于现代的海相和河相沉积,属于砂质壤土。试验区土壤含盐量、pH、钠吸附比和碱化度分别在6.5~15.0 g·kg⁻¹、8.06~8.68、13.29~38.76和15.44%~35.85%之间,属重度盐碱地^[5]。改良试验共设置18个田块,每个田块面积为6 m²(3 m×2 m),首先在各田块四周开挖深沟(宽30 cm,深60 cm),将双层塑料薄膜埋于沟内并用土填实以阻隔田块间的水盐交换。将田块土壤翻耕至20 cm,并反复细

翻直至土壤盐分基本均匀。试验设计了对照处理(CK)、鸡粪有机肥(OM)、聚丙烯酰胺+有机肥(PAM+OM)、秸秆覆盖+有机肥(SM+OM)、秸秆深埋+有机肥(BS+OM)和生物菌肥+有机肥(BM+OM)6种处理方式,每种方式3次重复,随机区组排列(表1)。燕麦于2016年11月3日开始播种,品种为美国海盗牌。燕麦以60 cm行距进行条播,播种量为90 kg·hm⁻²;在燕麦拔节期(2017年2月)以180 kg·hm⁻²的用量施用尿素,生育期内不再进行灌水,其他管理措施与当地农户一致,至2017年6月2日收获。

表1 试验设计和具体措施

Table 1 Experimental design and specific measures

处理措施 Treatment	具体措施 Specific measures
CK ¹⁾	对照处理,无任何措施
OM ²⁾	在0~20 cm深度施用鸡粪有机肥,用量为15 t·hm ⁻²
PAM+OM ³⁾	综合施用PAM结构改良剂和鸡粪有机肥,其中PAM结构改良剂为非离子800万分子量,用量为2 t·hm ⁻² ;均匀施用于20 cm深度,用量为15 t·hm ⁻²
SM+OM ⁴⁾	在0~20 cm深度施用鸡粪有机肥,用量为15 t·hm ⁻² ;然后将小麦秸秆剪为10 cm每段,以15 t·hm ⁻² 的用量覆盖于地表
BS+OM ⁵⁾	将小麦秸秆剪为10 cm每段,以15 t·hm ⁻² 的用量埋于地下20 cm深度,然后在0~20 cm深度施用鸡粪有机肥,用量为15 t·hm ⁻²
BM+OM ⁶⁾	复合施用嘉华生物菌肥和鸡粪有机肥,其中嘉华生物菌肥含生物细菌0.2亿个·克 ⁻¹ ,有机质≥45%,有效养分(N+P+K)≥12%;二者均匀施用于20 cm深度,用量为15 t·hm ⁻²

1) Control; 2) Organic manure: 有机肥, 3) Polyacrylamide plus organic manure: 聚丙烯酰胺+有机肥, 4) Straw mulching plus organic manure: 秸秆覆盖+有机肥, 5) Buried straw plus organic manure: 秸秆深埋+有机肥, 6) Bio-organic manure plus organic manure: 生物菌肥+有机肥。

1.2 样品采集与分析

研究区大气降雨量、大气温度、风速、蒸发量等参数由小型气象站监测,试验期内气象参数变化特征如图1所示;土壤温度由土壤温度传感器(NH133T,中科能慧科技公司)监测。由于耕层较浅,每隔30 d采集表层土壤(0~10 cm)。所有土壤样品在每个田块内随机采集3次,整个燕麦生育期内共采集土壤样品112个。土壤含水量采用烘干法测定,土壤容重采用环刀法测定;土壤盐分离子、阳离子交换量、pH等性质在土壤自然风干并过2 mm筛后待测。其中,土壤pH通过制备1:2.5土水质量比溶液,用PHS-3C型pH计测定;HCO₃⁻、CO₃²⁻用标准硫酸滴定法测定;Cl⁻用标准硝酸银滴

定法测定;Mg²⁺、Ca²⁺、SO₄²⁻用EDTA络合滴定法测定;Na⁺、K⁺用火焰光度法测定;土壤含盐量为8大离子浓度之和;土壤阳离子交换量采用乙酸铵交换法测定^[22]。钠吸附比(Sodium adsorption ratio, SAR)和碱化度(Exchange sodium percentage, ESP)的计算公式分别为^[23]:

$$SAR = \frac{Na^+}{\sqrt{\frac{1}{2}(Ca^{2+} + Mg^{2+})}} \quad (1)$$

$$ESP = \frac{交换Na^+}{阳离子交换量} \times 100\% \quad (2)$$

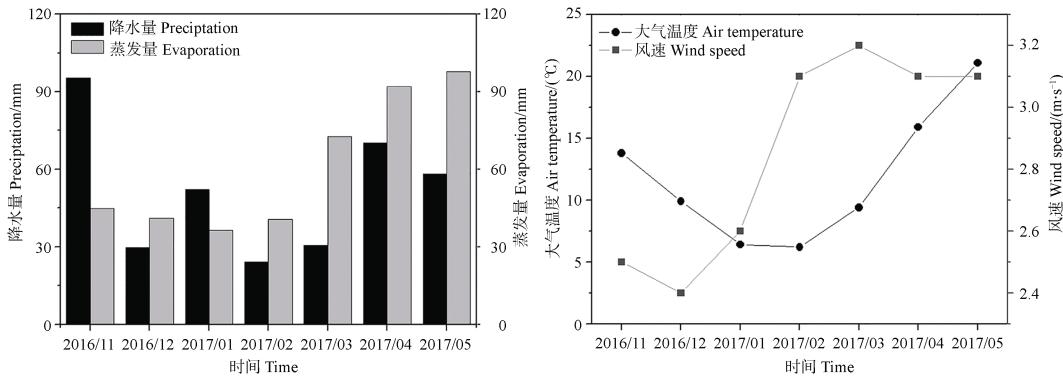


图 1 试验期内气象参数变化特征

Fig.1 Characteristics of meteorological parameters during the period of the experiment

1.3 模型构建

1.3.1 多元线性回归模型 多元线性回归模型

(Multiple Linear Regression, MLR) 因其结构简单、易于计算和解释, 已成为土壤科学领域较为常用的预测模型之一^[24]。多元线性回归模型假设目标变量与预测变量之间的关系是线性的。若某个目标变量 Y 与预测变量 x_1, x_2, \dots, x_i 有关, 它们之间表现出的线性关系称之为多元线性回归关系。多元线性回归模型表示为:

$$Y = a + \sum_{i=1}^n b_i x_i + \varepsilon = b_1 x_1 + b_2 x_2 + \dots + b_i x_i + \varepsilon \quad (3)$$

式中, Y 为土壤盐渍化参数 (土壤含盐量、pH、土壤 SAR、土壤 ESP); x_i ($i=1, 2, 3, \dots, n$) 为环境变量 (大气温度、土壤含水量、土壤温度、七日累积降雨量、七日累积蒸发量、风速、土壤容重); a 为截距; b_i ($i=1, 2, 3, \dots, n$) 为回归系数; ε 为回归残差。

1.3.2 BP 神经网络模型 BP 神经网络

(BP-Artificial Neural Network, BP-ANN) 是一种通过类似于人类神经系统的信息处理技术, 在生物神经网络的启示下建立的数据处理模型^[25]。BP 神经网络包含多个隐含层, 通过利用反向信息反馈来调整神经元之间权重, 使得神经网络能够输出期望的结果, 具备较强的学习和自身调整的能力^[25]。BP 神经网络模型由输入层、隐含层和输出层三部分组成, 以大气温度、土壤含水量、土壤温度、七日累积降雨量、七日累积蒸发量、风速、土壤容重为输入变量, 以土壤含盐量、土壤 pH、土壤 SAR、土壤 ESP 为输出变量预测土壤盐渍化参数动态。所选取的训练集进行标准化到 $[-1, 1]$ 后进行模型模拟。标准化

公式如下:

$$xp = \frac{xp_{\max} - xp_{\min}}{x_{\max} - x_{\min}} (x - x_{\min}) + xp_{\min} \quad (4)$$

式中, xp 为标准化后的变量值; xp_{\min} 和 xp_{\max} 为标准化后变量的最小值和最大值, 分别为 -1 和 1 ; x 为实测变量值, x_{\min} 和 x_{\max} 分别为实测变量的最小值和最大值。

在隐含层的选择中, 选择四层神经网络模型, 网络中间隐含层神经元的传递函数采用双曲正切函数 (\tanh), 即 $\tanh(x) = [\exp(x) - \exp(-x)] / [\exp(x) + \exp(-x)]$, 输出层神经元传递函数采用恒等函数, 优化算法采用贝叶斯规则法 (TRAINBR), 训练目标误差为 0.001 ^[25]。贝叶斯算法是在神经网络训练过程中, 在常规均方差性能函数基础上引入对性能函数的修正函数。通过反复调整隐含层神经元个数及网络参数, 最终确定网络拓扑结构为 $7 : 13 : 7 : 1$ (土壤含盐量、土壤 pH、土壤 SAR、土壤 ESP)。

$$f(w) = \alpha E_w + \beta E_d \quad (5)$$

式中, $f(w)$ 为修正后的性能函数; E_w 为网络所有权值的均方误差; E_d 为网络输出结果均方误差; α, β 为正则化参数。网络通过自适应方法自动根据训练结果调整 α, β 值以调整网络权值。贝叶斯正则化算法思想就是将权值参数设为随机变量, 根据权值的概率密度确定最优的权值函数^[26]。

1.3.3 随机森林模型 随机森林 (Random Forest, RF) 结合了分类与回归树、随机属性选择和装袋的算法思想, 使得每棵分类回归树均完全生长, 从而得到了低偏移的树; 同时, 随机属性选择

和装袋的方法使得随机森林中的每个个体其相关性均较低^[19-20]。随机森林模型选择土壤含盐量、pH、土壤 SAR 和土壤 ESP 为目标变量, 选择大气温度、土壤含水量、土壤温度、七日累积降雨量、七日累积蒸发量、风速、土壤容重为预测变量。在模型构建过程中, 随机森林回归树的数量 (Ntree)、树节点用于分割节点的预测变量数 (Mtry) 和叶片最小数量 (Nodesize) 是影响随机森林预测能力的主要参数。通过比较不同参数下的模型 OOB 误差 (Out of Bag Error), 当 OOB 误差值最小时所取的 Mtry 和 Ntree 值为构建模型的最优参数。经过反复调试, 土壤含盐量的 Ntree、Mtry 和 Nodesize 分别设置为 600、4 和 5, 土壤 pH、土壤 SAR 和土壤 ESP 的 Ntree、Mtry 和 Nodesize 分别设置为 800、4 和 5。

1.4 数据处理与分析

所有数据的统计分析检验均在 SPSS 19.0 for Windows 软件中完成, 并在 Sigma Plot 13.0 软件中进行图形绘制。BP 神经网络模型、随机森林模型和多元线性回归模型均在 SPSS Modeler 18.0 软件中构建。模型构建过程, 随机选取 70% 为训练数据集, 剩下 30% 为验证数据集。土壤含盐量、土壤 pH、土壤 SAR 和土壤 ESP 的预测精度通过决定系数

(Coefficient of Determination, R^2)、纳什系数 (Nash-Sutcliffe Efficiency, NSE) 和均方根误差 (Root Mean Square Error, RMSE) 来进行检验^[20]。

2 结 果

2.1 土壤盐渍化参数动态特征

燕麦生育期内, 各处理方式下表层土壤含盐量均随时间推移呈逐渐上升的趋势, 且不同改良方式均能有效地抑制土壤盐分 (图 2a)。相对于 CK 处理, SM+OM、BS+OM、PAM+OM、BM+OM 和 OM 处理下的土壤含盐量在生育期内分别下降了 57.5%~74.8%、56.3%~76.9%、49.4%~72.0%、46.5%~65.0% 和 -5.9%~45.0%。此外, 燕麦生育期内的 PAM+OM、SM+OM、BS+OM 和 BM+OM 处理间的含盐量并没有显著性差异。

燕麦生育期内, 所有处理方式下表层土壤 pH 均随时间推移呈逐渐下降的趋势, 且不同改良方式下表层土壤 pH 同样差异显著 (图 2b)。其中, BM+OM 处理对于表层土壤 pH 的调控效果最佳, 在生育期内较 CK 处理下降了 4.1%~8.5%, 而 SM+OM

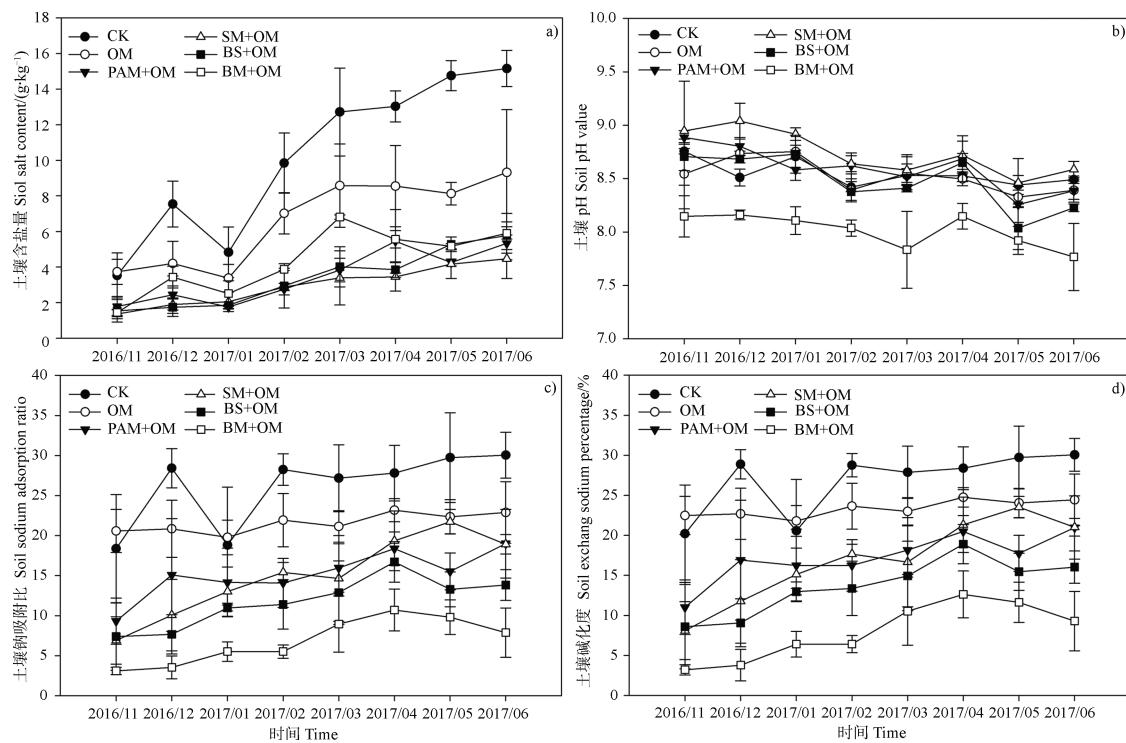


图 2 不同改良方式 a) 土壤含盐量、b) pH、c) 钠吸附比和 d) 碱化度动态特征

Fig. 2 Dynamic of soil salt content (a), pH (b), sodium adsorption ratio (c), and exchange sodium percentage (d) under different treatment

处理对于表层土壤 pH 的调控效果最差, 在生育期内较 CK 处理上升了 0.4%~5.5%, 其余改良措施下表层土壤的 pH 与 CK 相比差异并不显著。

燕麦生育期内, 各处理方式下表层土壤 SAR 均随时间推移逐渐上升, 且不同改良方式在整个生育期内均能有效地降低土壤 SAR 水平, 以 BM+OM 处理的效果最好(图 2c)。相对于 CK 处理, BM+OM、BS+OM、SM+OM、PAM+OM 和 OM 处理下的土壤 SAR 在生育期内分别下降了 61.5%~87.6%、39.9%~73.0%、27.0%~64.6%、24.8%~50.2% 和 -12.1%~26.6%。此外, PAM+OM、SM+OM 和 BS+OM 间的 SAR 并没有显著性差异。

燕麦生育期内, 各处理方式下表层土壤 ESP 的变化特征与 SAR 相似, 均随时间推移逐渐上升, 且不同改良方式下土壤 ESP 也存在显著差异, 以 BM+OM 处理最低(图 2d)。相对于 CK 处理, BM+OM、BS+OM、SM+OM、PAM+OM 和 OM 处理下的土壤 ESP 在生育期内分别下降了 55.5%~86.9%、33.4%~68.6%、20.9%~59.9%、21.2%~

45.5% 和 -11.3%~21.4%。此外, PAM+OM、SM+OM 和 BS+OM 间的 ESP 同样没有显著性差异。

2.2 土壤盐渍化参数与环境因子的关系

Pearson 相关分析表明燕麦生育期内表层土壤盐渍化程度显著受土壤环境因子影响(表 2)。土壤含盐量与土壤容重、蒸发量、土壤温度和风速存在极显著正相关关系, 与大气温度呈正相关关系; 与土壤含水量和降雨量呈极显著负相关关系。pH 与降雨量存在极显著正相关关系, 与土壤容重呈显著正相关关系; 而与土壤温度呈极显著负相关关系, 与风速、大气温度呈显著负相关关系, 与蒸发量和土壤含水量无显著相关关系。土壤 SAR 与土壤容重、蒸发量存在极显著正相关关系, 和风速呈显著正相关关系; 而与土壤含水量呈极显著负相关关系, 与降雨量呈显著负相关关系; 与大气温度和土壤温度无明显相关关系。土壤 ESP 与土壤容重和蒸发量呈极显著正相关关系, 与风速呈正相关关系; 而与土壤含水量呈极显著负相关关系, 与土壤温度、大气温度和降雨量无显著性相关关系。

表 2 表层土壤盐渍化参数与土壤环境因子相关关系

Table 2 Correlation between soil salinization parameters and soil environmental factors in surface soil

	大气温度	降雨量	蒸发量	风速	土壤含水量	土壤温度	土壤容重
	Air temperature	Precipitation	Evaporation	Wind speed	Soil water content	Soil temperature	Soil bulk density
土壤含盐量 ^①	0.215*	-0.336**	0.586**	0.289**	-0.525**	0.307**	0.644**
pH	-0.187*	0.245**	-0.156	-0.205*	0.077	-0.244**	0.222*
土壤钠吸附比 ^②	0.126	-0.192*	0.462**	0.202*	-0.521**	0.184	0.723**
土壤碱化度 ^③	0.116	-0.184	0.450**	0.211*	-0.539**	0.178	0.733**

① Soil salt content, ② Soil sodium adsorption ratio, ③ Soil exchange sodium percentage。注: * 和 ** 分别表示在 0.05 和 0.01 水平上显著相关。Note: * and ** represents a significance at 5% and 1% level, respectively.

2.3 土壤盐渍化参数预测与验证

2.3.1 土壤盐分预测与验证 土壤含盐量全部数据、训练数据和验证数据的预测效果均表现为随机森林模型>BP 神经网络模型>多元线性回归模型(图 3)。其中多元线性回归模型和随机森林模型的训练数据预测精度最高, 全部数据次之, 验证数据精度最低, 而 BP 神经网络模型三个数据集模拟精度差异不大。从 R^2 、NSE 和 RMSE 来看, 全部数据、训练数据和验证数据预测结果的 R^2 和 NSE 均表现为随机森林模型最高, 分别为 0.89、0.93、0.79 和 0.89、0.92、0.79; 其次为 BP 神经网络模型, R^2 和 NSE

分别为 0.81、0.81、0.83 和 0.80、0.81、0.79; 多元线性回归模型最低, 其 R^2 和 NSE 分别为 0.61、0.66、0.51 和 0.61、0.66、0.43。全部数据、训练数据和验证数据预测结果的 RMSE 则刚好与 NSE 和 R^2 相反, 表现为随机森林模型 (1.00 g·kg⁻¹、0.89 g·kg⁻¹ 和 1.22 g·kg⁻¹) <BP 神经网络模型 (1.31 g·kg⁻¹、1.36 g·kg⁻¹ 和 1.22 g·kg⁻¹) <多元线性回归模型 (1.87 g·kg⁻¹、1.80 g·kg⁻¹ 和 2.01 g·kg⁻¹)。

2.3.2 土壤 pH 动态预测与验证 如图 4 所示, 土壤 pH 全部数据、训练数据的预测效果表现为随机森林模型>BP 神经网络模型>多元线性回归模型, 而

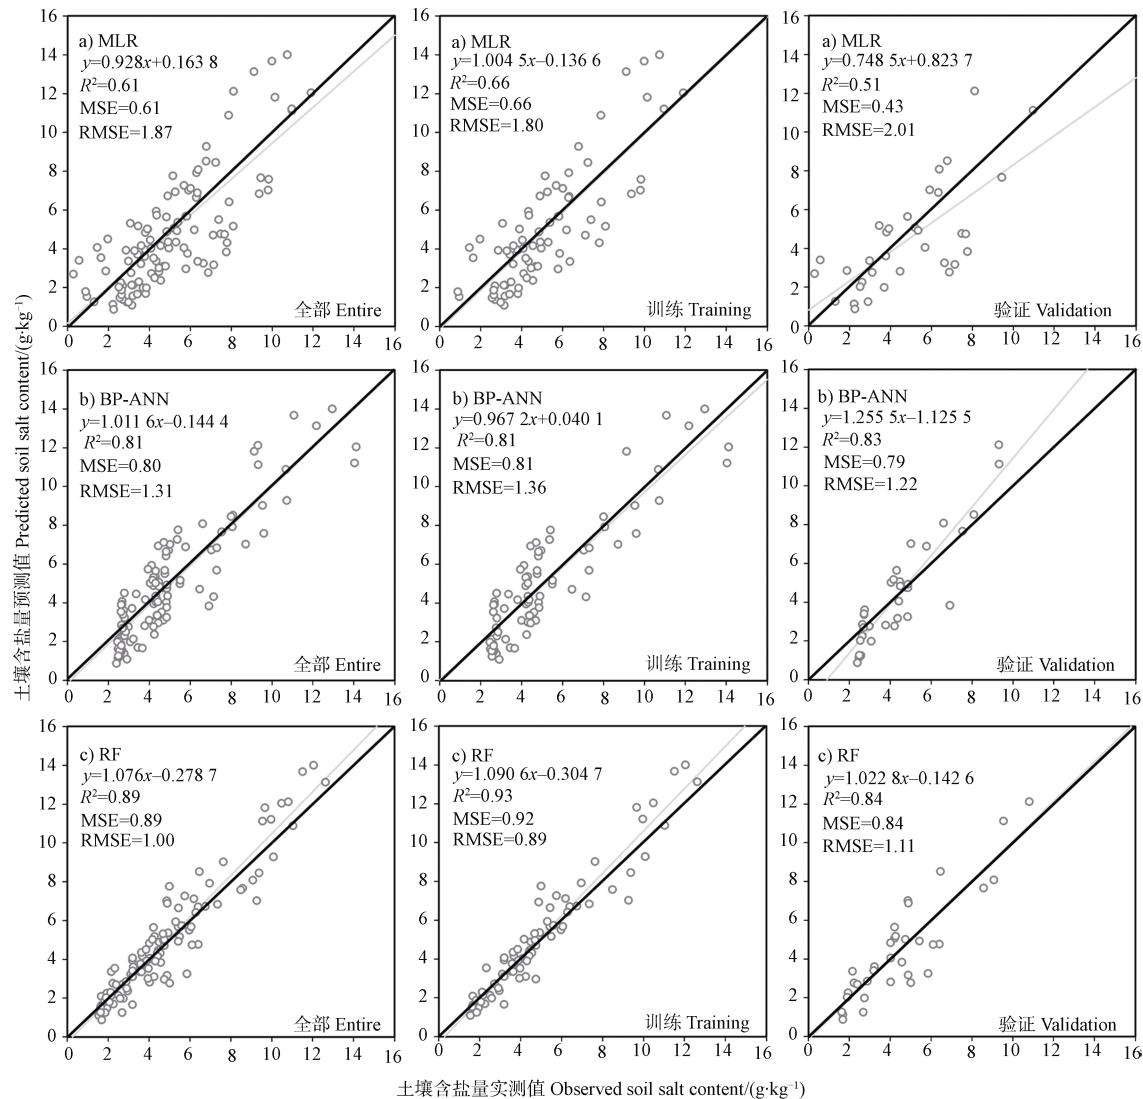


图3 土壤含盐量动态 a) 多元线性回归模型、b) BP 神经网络模型、c) 随机森林模型预测与验证

Fig. 3 Dynamic prediction and verification of soil salt content based on multiple linear regression model (a), BP neural network model (b) and random forest model (c)

验证数据的预测效果则表现为 BP 神经网络模型最好, 随机森林模型次之, 多元线性回归模型最差。从 R^2 、NSE 和 RMSE 来看, 全部数据、训练数据和验证数据预测结果的 R^2 均表现为随机森林模型 (0.85、0.92 和 0.74) >BP 神经网络模型 (0.77、0.76 和 0.76) >多元线性回归模型 (0.46、0.45 和 0.46)。全部数据、训练数据和验证数据的 NSE 表现为随机森林模型最高, 分别为 0.83、0.90 和 0.69; 其次为 BP 神经网络模型, 分别为 0.73、0.73 和 0.73; 多元线性回归模型最低, 分别为 0.45、0.44 和 0.46。全部数据、训练数据和验证数据的 RMSE 与 NSE 和 R^2 相反, 均表现为随机森林模型 <BP 神经网络模型

<多元线性回归模型; 且训练数据的 RMSE 最小, 全部数据次之, 验证数据最大。

2.3.3 土壤 SAR 动态预测与验证 土壤 SAR 全部数据、训练数据和验证数据的预测效果同样表现为随机森林模型 >BP 神经网络模型 >多元线性回归模型 (图 5)。从 R^2 、NSE 和 RMSE 来看, 全部数据、训练数据和验证数据预测结果的 R^2 均表现为随机森林模型 (0.85、0.88 和 0.78) >BP 神经网络模型 (0.77、0.78 和 0.74) >多元线性回归模型 (0.63、0.63 和 0.63)。全部数据、训练数据和验证数据的 NSE 同样表现为随机森林模型最高, 分别为 0.77、0.81 和 0.67; 其次为 BP 神经网络模型, 分别为 0.74、

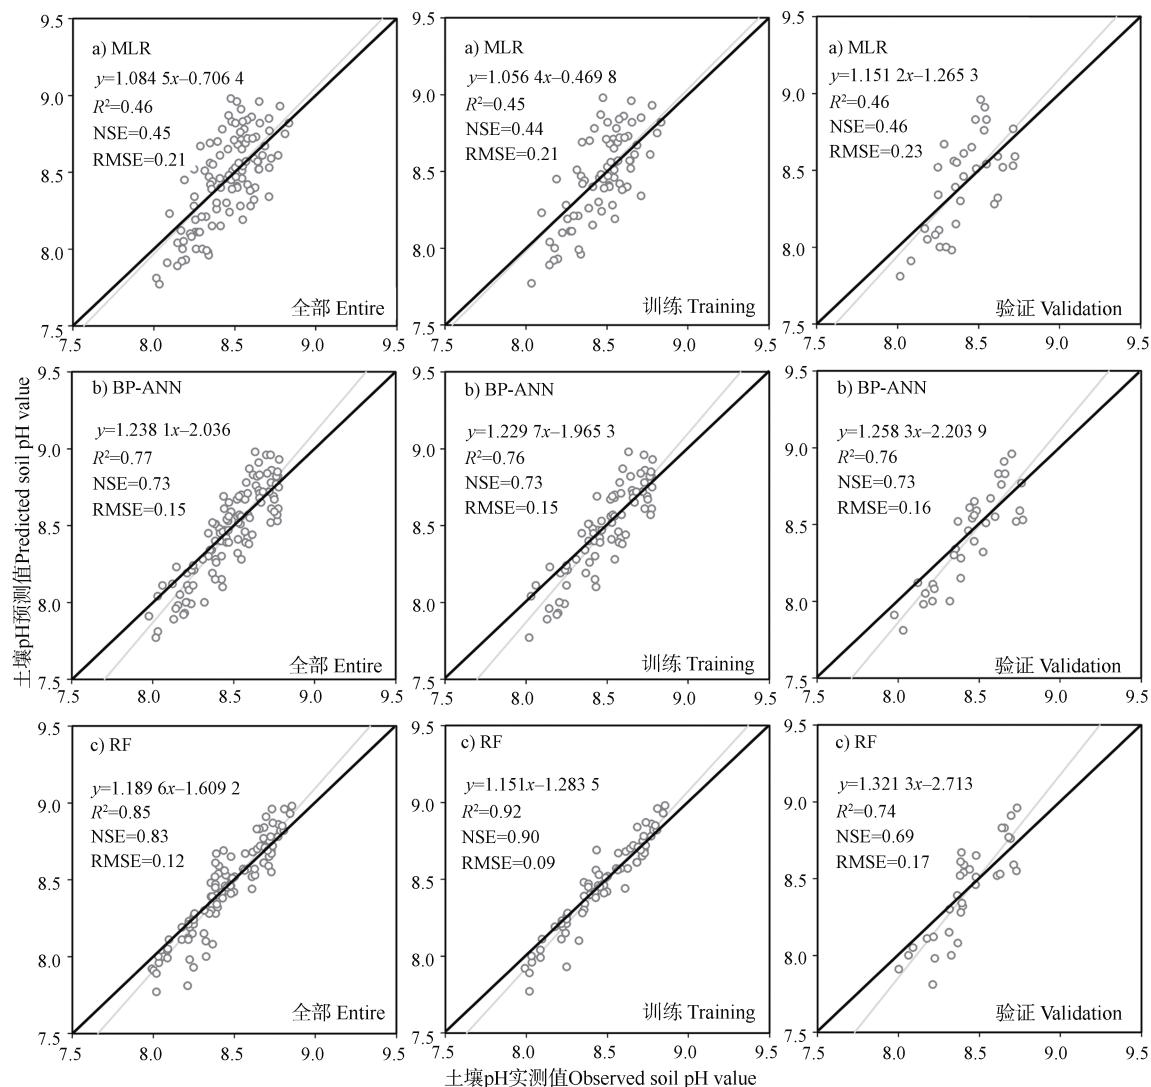


图 4 土壤 pH 动态 a) 多元线性回归模型、b) BP 神经网络模型、c) 随机森林模型预测与验证

Fig. 4 Dynamic prediction and verification of soil pH based on multiple linear regression model (a), BP neural network model (b) and random forest model (c)

0.75 和 0.71; 多元线性回归模型最低, 分别为 0.63、0.63 和 0.63。全部数据、训练数据和验证数据的 RMSE 与 NSE 和 R^2 相反, 均表现为随机森林模型 <BP 神经网络模型<多元线性回归模型; 且训练数据的 RMSE 最小, 全部数据次之, 验证数据最大。

2.3.4 土壤 ESP 动态预测与验证 土壤 ESP 全部数据、训练数据和验证数据的预测效果同样表现为随机森林模型>BP 神经网络模型>多元线性回归模型 (图 6)。从 R^2 、NSE 和 RMSE 来看, 全部数据、训练数据和验证数据预测结果的 R^2 均表现为随机森林模型 (0.85、0.89 和 0.79)>BP 神经网络模型 (0.78、0.81 和 0.71)>多元线性回归模型 (0.64、0.64 和 0.63)。全部数据、训练数据和验证数据的 NSE 同样

表现为随机森林模型最高, 分别为 0.80、0.82 和 0.75; 其次为 BP 神经网络模型, 分别为 0.76、0.79 和 0.69; 多元线性回归模型最低, 分别为 0.64、0.64 和 0.63。全部数据、训练数据和验证数据的 RMSE 与 NSE 和 R^2 相反, 均表现为随机森林模型<BP 神经网络模型<多元线性回归模型, 且训练数据的 RMSE 最小, 全部数据次之, 验证数据最大。

3 讨 论

本研究中, SM+OM、BS+OM、PAM+OM、BM+OM 和 OM 处理下的土壤含盐量、SAR 和 ESP 在生育期内均较 CK 处理明显下降, 表明各改良措

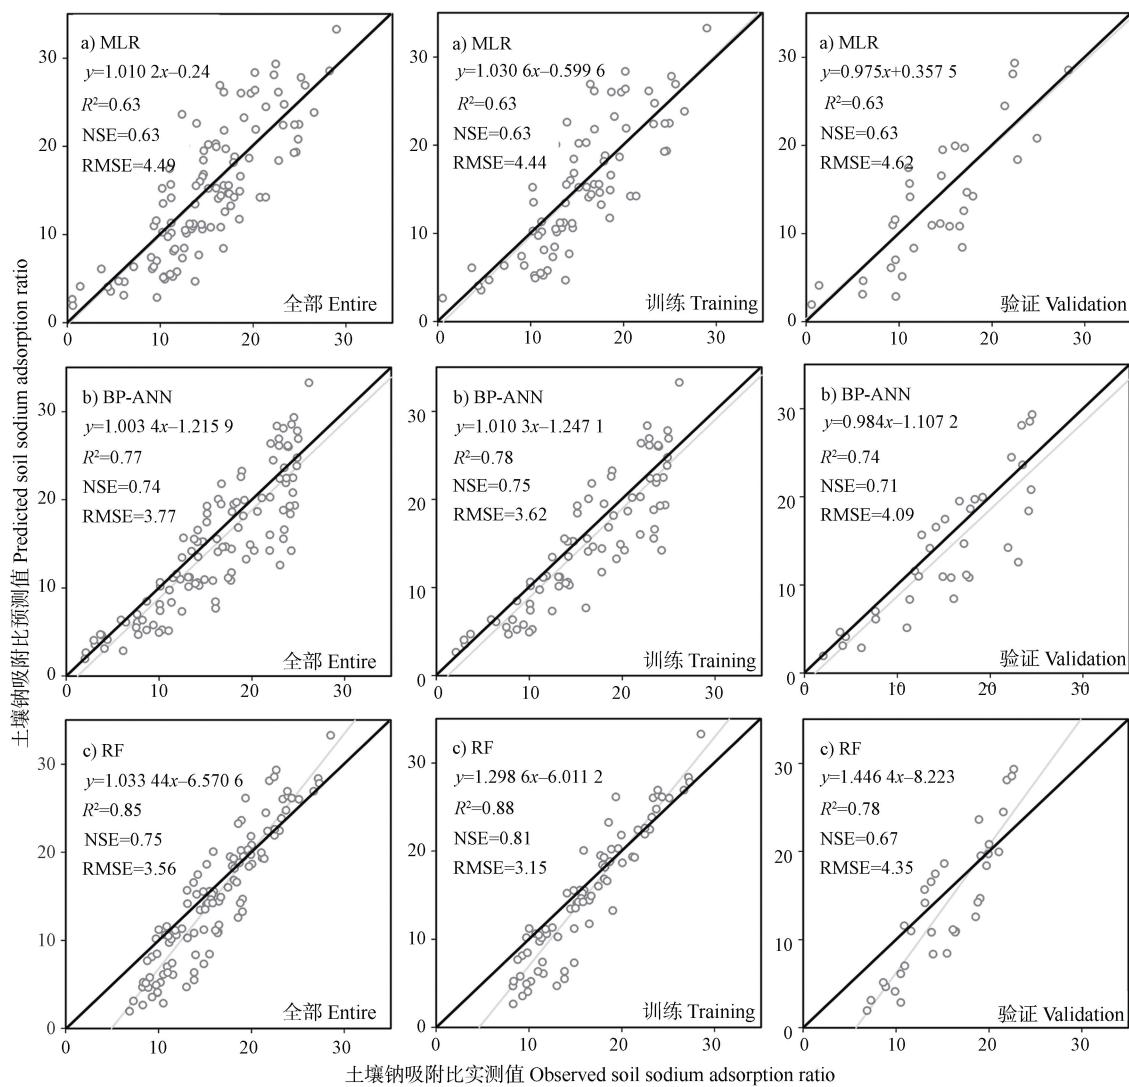


图 5 土壤钠吸附比动态 a) 多元线性回归模型、b) BP 神经网络模型、c) 随机森林模型预测与验证

Fig. 5 Dynamic prediction and verification of soil sodium adsorption ratio based on multiple linear regression model (a), BP neural network model (b) and random forest model (c)

施均能显著降低表层土壤盐渍化水平。本研究中, SM+OM 处理在整个生育期内均能够非常显著降低土壤盐渍化程度, 基本在轻度盐碱土和中度盐碱土的范围内波动。诸多研究表明秸秆覆盖能够增加地表覆盖度, 提高土壤持水能力、调控土壤温度, 抑制表层土壤水分蒸发和潜水上行, 降低了根区土壤盐渍化程度^[27-28]。秸秆深埋通过改变土壤结构、切断土壤毛管、阻断地下潜水上行, 进而降低上层土壤盐碱程度, 先前的研究表明将秸秆层埋设在地下 20~30 cm 深处能够有效阻止地下咸水上行, 减少表层土壤盐、碱累积, 在本试验中同样也观测到这种现象^[29]。PAM 是一种新型高效土壤结构改良剂, 属线型水溶性高分子聚合物, 可溶于水且具有很强

的黏聚作用, 已广泛应用于盐碱土改良中^[4, 21]。在本研究中, PAM+OM 措施显著降低了表层土壤盐渍化水平, 这可能是由于 PAM+OM 处理增加了表层土壤颗粒间的凝聚力, 提高了土壤团聚体的稳定性和土壤孔隙率, 增加了土壤入渗速率, 从而促进了土壤盐分淋溶到深层^[30]。同样地, 研究发现 BM+OM 措施也具有良好的抑制盐碱效果; 早前诸多研究表明施用生物菌肥能够显著地增强微生物活性和有机底物代谢, 导致盐渍土中游离离子浓度降低, 特别是 Na^+ 和 Cl^- 的降低, 从而降低土壤盐渍化水平^[31]。OM 处理措施在燕麦生长前期阶段能较好地抑制土壤盐碱程度, 这是因为鸡粪堆肥能够改善土壤结构, 增加有机质、氮、磷、钾等养分含

量, 有利于盐渍土的保水和盐分的淋溶; 然而在燕麦生长中后期阶段, 其抑盐效果随着有机肥的分解

流失逐渐下降, 导致土壤盐分重新上升至重度盐渍化水平^[4]。

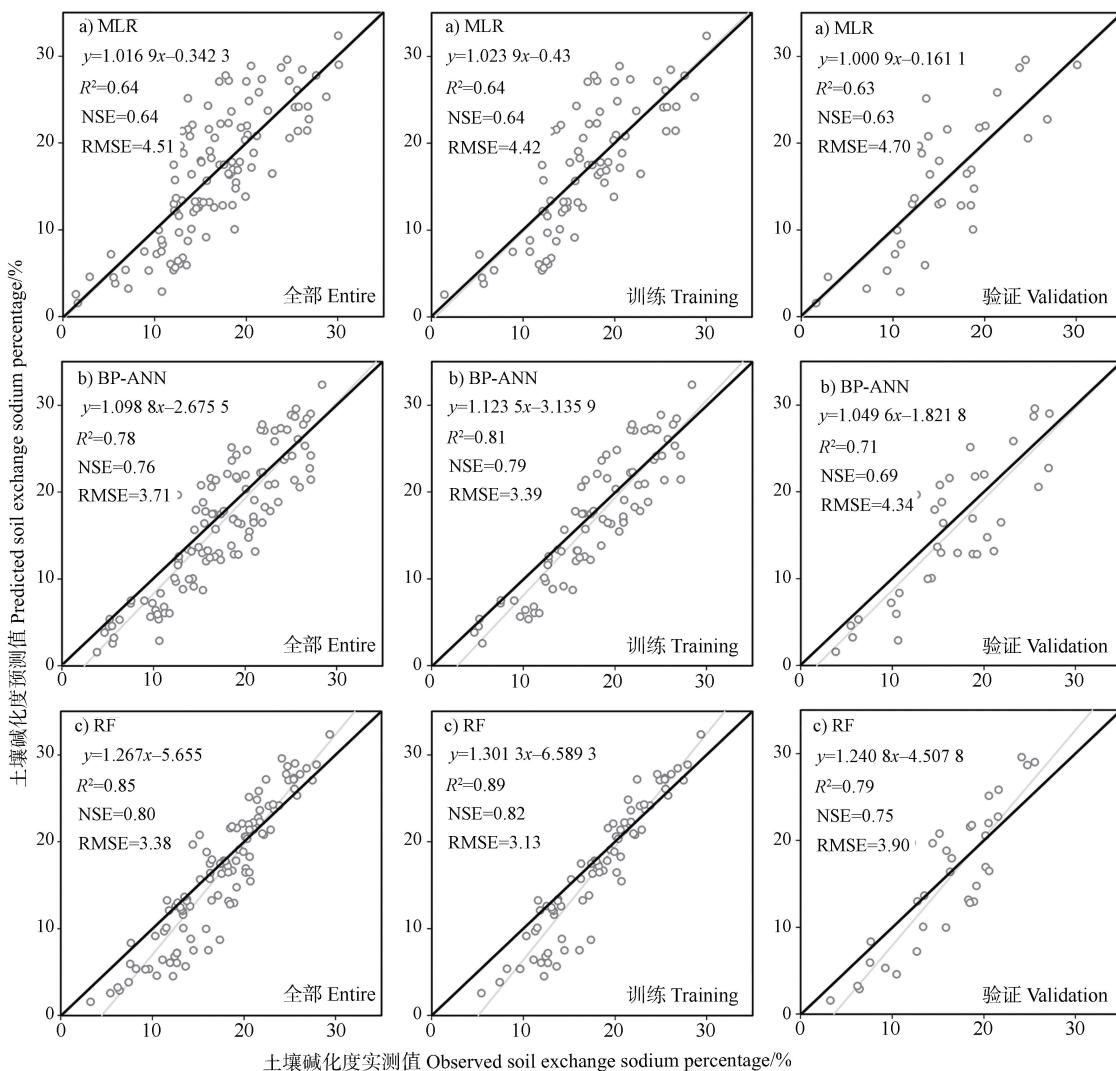


图 6 土壤碱化度动态 a) 多元线性回归模型、b) BP 神经网络模型、c) 随机森林模型预测与验证

Fig. 6 Dynamic prediction and verification of soil exchange sodium percentage based on multiple linear regression model (a), BP neural network model (b) and random forest model (c)

土壤盐渍化动态同样也受到气象条件和土壤性质的影响^[21]。在本试验中, 所有处理方式下的表层土壤盐渍化水平逐渐上升, 且各处理措施下的土壤盐渍化水平均呈现出强烈的时间变异性, 与研究区的气象条件密切相关。本研究中, 土壤盐渍化参数与降雨量和蒸发量呈现出显著的相关关系, 不同处理的表层土壤对降水的接收能力和对蒸发的抑制程度有所不同, 从而造成土壤盐渍化程度的差异。大气风速、土壤温度和土壤盐渍化均与大气温度呈现出显著的正相关关系, 这是由于较高的风速、大气温度和土壤温度会使得土壤蒸发量上升, 进而导致

潜水上行, 使得土壤盐渍化程度上升。土壤水分是影响土壤盐分的主要因子之一, 土壤盐分运移遵循“盐随水来, 盐随水去”的原理。大量研究表明由蒸发或蒸腾造成土壤水分损失, 导致地下潜水上升是引起根区土壤盐分上升的主要原因^[27]。本试验中, PAM+OM、BM+OM、SM+OM 和 BS+OM 处理措施均在燕麦生育期内有效地保持土壤水分含量, 从而降低了表层土壤盐渍化水平。土壤容重的降低可以增加土壤孔隙度, 改善通气透水性, 改变土壤水盐运移特征, 降低土壤盐渍化水平, 本研究中各改良措施均有效地降低了土壤容重, 从而有效地抑制了

土壤盐碱程度。

本研究表明,随机森林模型和BP神经网络模型均能很好地应用于改良背景下的土壤盐分、pH、土壤SAR和土壤ESP的预测,而多元线性回归模型的预测效果则较差。这主要是因为在改良背景下,土壤盐渍化参数同时受到多种环境因素的影响(如气候因素、土壤结构因素、土壤肥力等),其空间变异特征较大^[32];因此土壤盐渍化参数与环境变量之间的关系不仅表现出简单直接的线性关系,往往还表现出非线性特征^[20, 33]。此时引用多元线性回归模型拟合盐渍化参数与环境变量之间的关系,其结果往往不甚理想,而BP神经网络模型和随机森林模型不仅能够发现它们之间的线性关系,还能够很好地捕捉到土壤盐渍化参数与环境变量之间的非线性和层状关系^[20, 25]。在本研究中,在随机森林模型的训练数据集中,土壤含盐量、pH、SAR和ESP的 R^2 最高,误差指数最低,这表明随机森林模型具有良好的训练能力(图3~图6)。虽然随机森林模型的验证数据集的 R^2 和误差指数与训练数据集相比,预测精度有所下降,但仍高于BP神经网络模型和多元线性回归模型(pH除外)。以上结果表明,随机森林模型在预测土壤盐渍化参数方面优于BP神经网络模型和多元线性回归模型。已有研究报道随机森林模型在预测其他土壤性质(如土壤质地、土壤有机碳、土壤氮)方面较多元线性模型有更好的表现^[19, 25, 34]。与BP神经网络模型和多元线性模型相比,随机森林模型更为稳定,这主要是随机森林模型避免了其他算法中常遇到的过度拟合和多重共线性等问题,提高了预测精度^[20]。此外,由于研究区不同改良方式下土壤盐渍化程度的差异较大,土壤含盐量、pH、SAR和ESP的变化范围分别在0.87 g·kg⁻¹~14.00 g·kg⁻¹、7.77~8.98、1.93~33.27和1.56%~32.35%之间,BP神经网络和随机森林模型在预测高值和低值时均误差较大,而在模拟中间值时效果比较理想。这可能是由于受实测资料的限制,本研究仅选择大气温度、土壤温度、七日累积降雨量、七日累积蒸发量、风速、土壤含水量和土壤容重作为影响土壤盐渍化程度的主要因子,不能完全代表土壤盐渍化特征与环境因子之间的关系,影响了预测精度;另一方面,部分预测变量如土壤容重等变异程度较低的变量未获取整个生育期的数据,仅以播种时和收获时测量的数据代替,因此导

致整体预测精度下降。此外,BP神经网络隐含层的层数及节点的选取和随机森林模型部分参数的设置多根据经验确定,并无理论依据,也影响了拟合和预测的精度^[14, 35]。

4 结 论

(1) 不同改良措施均能显著地降低表层土壤盐渍化水平,其中SM+OM措施对土壤含盐量的抑制效果最好;而BM+OM措施对pH、钠吸附比和碱化度的调控效果最佳。(2) 土壤盐渍化程度显著受气象条件和土壤性质的影响,其中土壤含盐量与大气温度、土壤温度、降水量、蒸发量、土壤含水量、风速和土壤容重均存在显著相关关系;pH与大气温度、降水量、风速、土壤温度和土壤容重存在显著相关关系;SAR和ESP则均与蒸发量、风速、土壤含水量和土壤容重显著相关。(3) 在预测模型中,RF模型对土壤含盐量、pH、SAR和ESP的综合预测精度明显优于BP-ANN和MLR,主要体现在随机森林模型具有较高的 R^2 和NSE,以及较低的RMSE。

参考文献 (References)

- [1] Zhang J B, Yang J S, Yao R J, et al. Dynamics of soil water, salt and crop growth under farmyard manure and mulching in coastal tidal flat soil of northern Jiangsu Province[J]. Transactions of the Chinese Society of Agricultural Engineering, 2013, 29 (15): 116—125. [张建兵, 杨劲松, 姚荣江, 等. 有机肥与覆盖方式对滩涂围垦农田水盐与作物产量的影响[J]. 农业工程学报, 2013, 29 (15): 116—125.]
- [2] Gao S, Yang J S, Yao R J, et al. Effects of soil amelioration measures mitigating soil salinity and improving crop P uptake in coastal area of north Jiangsu[J]. Acta Pedologica Sinica, 2020, 57 (5): 1219—1229. [高珊, 杨劲松, 姚荣江, 等. 改良措施对苏北盐渍土盐碱障碍和作物磷素吸收的调控[J]. 土壤学报, 2020, 57 (5): 1219—1229.]
- [3] Li J G, Pu L J, Zhu M, et al. The present situation and hot issues in the salt-affected soil research[J]. Acta Geographica Sinica, 2012, 67 (9): 1233—1245. [李建国, 濮励杰, 朱明, 等. 土壤盐渍化研究现状及未来研究热点[J]. 地理学报, 2012, 67 (9): 1233—1245.]
- [4] Shen H Y, Xie X F, Pu L J, et al. Dynamics of soil water-salt as affected by different improvement measures in coastal reclamation: A case study of Rudong in Jiangsu Province[J]. Chinese Journal of Soil Science, 2019, 50 (2): 316—322. [沈洪运, 解雪峰, 濮励杰, 等. 不同

- 改良方式下滩涂围垦区土壤水盐动态——以江苏如东为例[J]. 土壤通报, 2019, 50 (2): 316—322.]
- [5] Xie X F, Pu L J, Zhu M, et al. Spatio-temporal variability of soil salinity and sodicity in agricultural reclaimed coastal wetlands, Eastern China[J]. Archives of Agronomy and Soil Science, 2020, 66 (12): 1639—1650.
- [6] Zhang J B, Yang J S, Yao R J, et al. The effects of farmyard manure and mulch on soil physical properties in a reclaimed coastal tidal flat salt-affected soil[J]. Journal of Integrative Agriculture, 2014, 13 (8): 1782—1790.
- [7] Yin A J, Zhang M, Gao C, et al. Salinity evolution of coastal soils following reclamation and intensive usage, Eastern China[J]. Environmental Earth Sciences, 2016, 75 (18): 1—11.
- [8] Xie X F, Pu L J, Zhu M, et al. Linkage between soil salinization indicators and physicochemical properties in a long-term intensive agricultural coastal reclamation area, Eastern China[J]. Journal of Soils and Sediments, 2019, 19 (11): 3699—3707.
- [9] Xie X F, Pu L J, Zhu M, et al. Differential effects of various reclamation treatments on soil characteristics: an experimental study of newly reclaimed tidal mudflats on the east China coast[J]. Science of the Total Environment, 2021, 768: 144996.
- [10] Shen H, Abuduwaili J. Spatial distribution of soil moisture and salinity and their influence factors in the farmland of Manas River catchment, Northwest China[J]. Chinese Journal of Applied Ecology, 2015, 26 (3): 769—776. [沈浩, 吉力力·阿不都外力. 玛纳斯河流域农田土壤水盐空间分布特征及影响因素[J]. 应用生态学报, 2015, 26 (3): 769—776.]
- [11] Yao R J, Yang J S, Zou P, et al. Bp neural network model for spatial distribution of regional soil water and salinity[J]. Acta Pedologica Sinica, 2009, 46 (5): 788—794. [姚荣江, 杨劲松, 邹平, 等. 区域土壤水盐空间分布信息的BP神经网络模型研究[J]. 土壤学报, 2009, 46 (5): 788—794.]
- [12] Xie X F, Pu L J, Zhu M, et al. Evolution and prospects in modeling of water and salt transport in soils[J]. Scientia Geographica Sinica, 2016, 36(10): 1565—1572. [解雪峰, 濮励杰, 朱明, 等. 土壤水盐运移模型研究进展及展望[J]. 地理科学, 2016, 36(10): 1565—1572.]
- [13] Guo X H, Bi Y J, Sun X H, et al. Prediction model of soil water and salt transport on yield of summer squash under mulch drip irrigation with brackish water[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35 (8): 167—175. [郭向红, 毕远杰, 孙西欢, 等. 西葫芦微咸水膜下滴灌土壤水盐运移对产量影响的预测模型[J]. 农业工程学报, 2019, 35 (8): 167—175.]
- [14] Guo Y, Yin X W, Li Y, et al. Soil water and salt dynamics and its coupling model at cropland-treebelt-desert compound system[J]. Transactions of the Chinese Society of Agricultural Engineering, 2019, 35 (17): 87—101. [郭勇, 尹鑫卫, 李彦, 等. 农田-防护林-荒漠复合系统土壤水盐运移规律及耦合模型建立[J]. 农业工程学报, 2019, 35 (17): 87—101.]
- [15] 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.
- [16] Wu W C, Zucca C, Muhaimeed A S, et al. Soil salinity prediction and mapping by machine learning regression in Central Mesopotamia, Iraq[J]. Land Degradation & Development, 2018, 29 (11): 4005—4014.
- [17] Yang A X, Ding J L. Comparative assessment of two methods for estimation of soil organic carbon content by Vis-NIR spectra in Xinjiang Ebinur Lake Wetland[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31 (18): 162—168. [杨爱霞, 丁建丽. 新疆艾比湖湿地土壤有机碳含量的光谱测定方法对比[J]. 农业工程学报, 2015, 31 (18): 162—168.]
- [18] Vermeulen D, van Niekerk A. Machine learning performance for predicting soil salinity using different combinations of geomorphometric covariates[J]. Geoderma, 2017, 299: 1—12.
- [19] Wang Y Y, Qi Y B, Chen Y, et al. Prediction of soil organic matter based on multi-resolution remote sensing data and random forest algorithm[J]. Acta Pedologica Sinica, 2016, 53 (2): 342—354. [王茵茵, 齐雁冰, 陈洋, 等. 基于多分辨率遥感数据与随机森林算法的土壤有机质预测研究[J]. 土壤学报, 2016, 53 (2): 342—354.]
- [20] Xie X F, Wu T, Zhu M, et al. Comparison of random forest and multiple linear regression models for estimation of soil extracellular enzyme activities in agricultural reclaimed coastal saline land[J]. Ecological Indicators, 2021, 120: 106925.
- [21] Xie X F, Pu L J, Shen H Y, et al. Effects of soil reclamation on the oat cultivation in the newly reclaimed coastal land, Eastern China[J]. Ecological Engineering, 2019, 129: 115—122.
- [22] Bao S D. Soil and agricultural chemistry analysis[M]. 3rd. ed. Beijing: China Agriculture Press, 2000. [鲍士旦. 土壤农化分析[M]. 3 版. 北京: 中国农业出版社, 2000.]
- [23] Xie X F, Pu L J, Zhu M, et al. Relationship between landscape patterns and soil salinity based on canonical correspondence analysis in coastal reclamation area[J]. Geographical Research, 2017, 36 (3): 495—505. [解雪峰, 濮励杰, 朱明, 等. 基于典范对应分析的滨海滩涂围垦区景观格局与土壤盐渍化关系[J]. 地理研究, 2017, 36 (3): 495—505.]
- [24] Thompson J A, Pena-Yewtukhiw E M, Grove J H. Soil-landscape modeling across a physiographic region:

- Topographic patterns and model transportability[J]. *Geoderma*, 2006, 133 (1/2): 57—70.
- [25] Lagos-Avid M P, Bonilla C A. Predicting the particle size distribution of eroded sediment using artificial neural networks[J]. *Science of the Total Environment*, 2017, 581/582: 833—839.
- [26] Yuan Y, Tan D, Yu S J, et al. A prediction model for shale gas organic carbon content based on improved BP neural network using Bayesian regularization[J]. *Geology and Exploration*, 2019, 55 (4): 1082—1091. [袁颖, 谭丁, 于少将, 等. 基于贝叶斯正则化改进BP神经网络的页岩气有机碳含量预测模型[J]. 地质与勘探, 2019, 55 (4): 1082—1091.]
- [27] Zhao Y G, Li Y Y, Wang J, et al. Buried straw layer plus plastic mulching reduces soil salinity and increases sunflower yield in saline soils[J]. *Soil and Tillage Research*, 2016, 155: 363—370.
- [28] Abd El-Mageed T A, Semida W M, Abd El-Wahed M H. Effect of mulching on plant water status, soil salinity and yield of squash under summer-fall deficit irrigation in salt affected soil[J]. *Agricultural Water Management*, 2016, 173: 1—12.
- [29] Zhao Y G, Pang H C, Wang J, et al. Effects of straw mulch and buried straw on soil moisture and salinity in relation to sunflower growth and yield[J]. *Field Crops Research*, 2014, 161: 16—25.
- [30] Lu S Y, Chen F X, Ngo H H, et al. Effect of straw and polyacrylamide on the stability of land/water ecotone soil and the field implementation[J]. *Ecological Engineering*, 2016, 94: 12—21.
- [31] Chowdhury N, Nakatani A S, Setia R, et al. Microbial activity and community composition in saline and non-saline soils exposed to multiple drying and rewetting events[J]. *Plant and Soil*, 2011, 348 (1/2): 103—113.
- [32] Wang Z R, Zhao G X, Gao M X, et al. Spatial variability of soil salinity in coastal saline soil at different scales in the Yellow River Delta, China[J]. *Environmental Monitoring and Assessment*, 2017, 189 (2): 1—12.
- [33] Wang T T, Zhai J H, He H, et al. Applicability of BP neural network model and SVM model to predicting soil moisture under incorporation of biochar into soils[J]. *Research of Soil and Water Conservation*, 2017, 24 (3): 86—91. [王彤彤, 翟军海, 何欢, 等. 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[J]. 水土保持研究, 2017, 24 (3): 86—91.]
- [34] Xie E Z, Zhao Y C, Lu F Y, et al. Comparison analysis of methods for prediction of spatial distribution of soil organic matter contents in farmlands south Jiangsu, China[J]. *Acta Pedologica Sinica*, 2018, 55 (5): 1051—1061. [谢恩泽, 赵永存, 陆访仪, 等. 不同方法预测苏南农田土壤有机质空间分布对比研究[J]. 土壤学报, 2018, 55 (5): 1051—1061.]
- [35] Yu G Q, Li Z B, Zhang X, et al. Dynamic simulation of soil water-salt using BP neural network model and grey correlation analysis[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2009, 25 (11): 74—79. [于国强, 李占斌, 张霞, 等. 土壤水盐动态的BP神经网络模型及灰色关联分析[J]. 农业工程学报, 2009, 25 (11): 74—79.]

(责任编辑: 檀满枝)