

光谱技术结合水分校正与样本增广的棉田土壤盐分精准反演

李佳怿¹, 张翼腾¹, 周宝闯¹, 翁海勇¹, 周蓓蓓², 叶大鹏¹, 瞿芳芳^{1*}

(1. 福建农林大学机电工程学院, 福州 350002; 2. 西安理工大学水利水电学院, 西安 710048)

摘要: 棉田土壤盐分的精准反演对于棉花的种植管理具有重要意义。水分和盐分作为主要环境因素, 共同影响棉田土壤的波谱特征, 两者之间的耦合关系直接影响土壤盐分的检测分析。为了提高基于光谱技术构建的模型对棉田土壤盐分信息解析的准确性与可靠性, 该研究联用可见/短波近红外(400~1 000 nm)和长波近红外(960~1 693 nm)技术, 采集不同含水率与含盐量的新疆地区土壤样本的光谱; 结合外部参数正交法(external parameter orthogonalization, EPO), 校正不同标样集与不同波段光谱中的土壤含水率干扰信息; 引入基于不同卷积步幅的深度卷积对抗网络(deep convolutional generative adversarial networks, DCGAN), 进行样本增广与质量评估; 参考三层残差神经网络设计一维卷积神经网络RNet, 最终构建基于EPO-DCGAN-RNet的优化模型, 用于棉田土壤盐分的反演。结果表明, 与传统机器学习方法和基于VGG或EfficientNet结构一维卷积神经网络相比, 该研究提出的EPO-DCGAN-RNet方法能够有效地滤除水分对盐分反演的影响、提高模型对特征波段的挖掘能力、降低深度学习算法对样本量的依赖性, 并能得到更优的模型预测性能。EPO-DCGAN-RNet的建模集 R^2 和均方根误差分别为0.942、115.420 $\mu\text{S}/\text{cm}$, 验证集 R^2 和均方根误差分别为0.910和136.472 $\mu\text{S}/\text{cm}$ 。研究结果可为新疆棉田土壤盐分快速精准检测提供理论指导和技术支持, 有助于促进盐碱地区棉花种植的水肥科学管理。

关键词: 土壤; 盐分; 光谱技术; 水分校正; 样本增广; 外部参数正交法; 深度卷积对抗网络

doi: 10.11975/j.issn.1002-6819.202307090

中图分类号: S151.9

文献标志码: A

文章编号: 1002-6819(2024)-01-0179-11

李佳怿, 张翼腾, 周宝闯, 等. 光谱技术结合水分校正与样本增广的棉田土壤盐分精准反演[J]. 农业工程学报, 2024, 40(1): 179-189. doi: 10.11975/j.issn.1002-6819.202307090 <http://www.tcsae.org>

LI Jiayi, ZHANG Yiteng, ZHOU Baochuang, et al. Inversing soil salinity in cotton fields using spectroscopy sample augmentation and moisture correction[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(1): 179-189. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202307090 <http://www.tcsae.org>

0 引言

南疆地区盐渍化土壤占灌溉区总面积的49.6%^[1], 土壤盐胁迫已是南疆棉花种植区常见的非生物胁迫, 大力提高盐碱地棉花生产力已成为农业可持续发展的重要研究方向。棉花虽被视为盐渍土壤种植的先锋作物, 然而, 棉花苗期耐盐性较弱, 极易遭受盐分胁迫。土壤过高的含盐量会导致棉花幼苗根系细胞膜结构功能损伤、生物量降低、光合性能受抑制, 最终降低棉花产量^[2]。对于干旱/半干旱地区土壤而言, 盐分和水分同时作为土壤性质的重要影响因子^[3], 两者之间具有耦合关系, 并且土壤盐分的变化与水盐运移有着密切关系^[4]。因此, 在对土壤盐渍化检测时, 校正土壤水分的干扰耦合作用, 对于干旱/半干旱地区棉田土壤盐分的精准反演至关重要, 有助于指导棉田的水肥科学管理。

收稿日期: 2023-07-09 修订日期: 2023-09-27

基金项目: 国家自然基金面上项目(41977007); 福建农林大学杰出青年科研人才计划资助项目(xjq202117); 省部共建西北旱区生态水利国家重点实验室(西安理工大学)开放研究基金资助课题(2021KFKT-6)

作者简介: 李佳怿, 研究方向为光谱数据分析算法和植物表型。

Email: foddeus@fafu.edu.cn

*通信作者: 瞿芳芳, 博士, 副教授, 研究方向为农业信息智能感知与分析决策。Email: ffqf@fafu.edu.cn

土壤盐渍化检测一直是国内外的研究热点, 已有研究表明, 光谱技术结合化学计量学方法以其无损快速的特点, 在土壤理化属性高通量检测中表现出巨大的应用前景^[5]。地物反射光谱的采集根据传感平台高度的不同可分为航空遥感和地面遥感。航空遥感法利用多波段、多时相的遥感数据广泛用于盐渍化和盐生植物的监测, 然而该方法通常受限于空间分辨率、大气干扰、传感器限制等因素, 其检测精度较低^[6-8], 在大田环境中通常需要配合地面遥感平台进一步实现高精度的盐分反演。而对于地面传感平台, 由于土壤含水率会影响盐渍化的光谱响应模式, 有关土壤含水率的干扰校正是土壤盐渍化检测的重难点^[9]。XU等^[10]利用高光谱技术实现了干旱地区土壤水分和盐分的反演, 对土壤水分的预测精度 R^2 为0.951, 然而对于盐分的预测精度($R^2=0.748$)有待提升。针对土壤盐分的精准反演, DING等^[11]特意采集了新疆盐渍化较为严重的艾比湖流域土壤样本的光谱反射率, 并构建了导数预处理后的光谱构建的土壤盐分预测模型, 精度为 R^2 为0.768。陈睿华等^[12]比较了室内和野外条件下采集的银川平原土壤光谱, 并构建土壤含盐量反演模型, 认为野外采集的光谱对土壤含盐量反演精度明显优于室内光谱, 但是采用光谱校正技术可提高室内光谱预测的精度。上述研究结果说明, 室内光谱采集结

合光谱校正技术能有效提高土壤盐分的反演精度。外部参数正交化算法 (external parameter orthogonalisation, EPO) 作为典型光谱校正方法, 在消除土壤水分影响的研究中有着优异的表现^[13-14]。洪永胜等^[15]利用 EPO 校正算法结合支持向量机, 实现了湿土中有机质的稳定预测。陈红艳等^[16]在滨海潮盐土的高光谱盐分反演研究中认为, EPO 结合偏最小二乘法 (partial least squares regression after EPO pre-processing, EPO-PLSR) 可作为土壤盐分校准模型的技术路线之一。然而, EPO 校正方法具有难以解决样本丰度、多样性的局限, 在有限样本资源下想要实现高效准确的盐分反演, 还需进一步结合数据增强方法及模型。

近年来, 深度学习广泛应用于波谱数据下的农产品分级与农情预测^[17], 其中一维卷积神经网络 (one-dimensional convolutional neural network, 1D-CNN) 结合光谱技术, 在水质监测^[18-19]、食品安全检测^[20]等应用领域表现出较好的模型预测性能。然而, 深度学习模型的建立依赖于大样本集, 样本数据的准备所需周期长且工作量大, 为此针对小样本集可采用样本增广的方法来提升深度学习模型的适用度, 实现反演模型的快速构建。基于深度学习技术的生成对抗网络 (generative adversarial networks, GAN)^[21]作为一种生成式模型, 在样本增强效果和模型鲁棒性等方面具有显著优势^[22-23]。何少芳等^[24]利用 GAN 显著提高了多个机器学习模型利用土壤高光谱数据在有机质预测中的精度, 其中 GAN-BPNN 的预测精度 R^2 由 0.692 提升到了 0.868。SANDFORT 等^[25]利用 CycleGAN 对医疗成像数据进行增强, 显著提高了卷积神经网络 U-Net 在分割任务中的泛化能力。李灵巧等^[26]利用深度卷积对抗网络 (deep convolutional generative adversarial networks, DCGAN)^[27]对拉曼光谱样本进行扩充, 将 CNN 模型的预测准确率由 81.85% 提升到了 98.52%, TAN 等^[28]利用 DCGAN 扩增哈密瓜的高光谱数据, 使决策树、支持向量机及随机森林 (random forest, RF) 模型在哈密瓜农药残余检测中的准确率分别提高了 13.13%, 11.25% 和 7.5%。基于 GAN 的数据增强, 能有效用于小样本数据集建模提升泛化能力, 在光谱法检测土壤盐分的应用领域具有一定的潜力。

为了实现棉田土壤盐分的高效精准反演, 本文联用可见/短波近红外 (400~1 000 nm) 和长波近红外 (960~1 693 nm) 波段的高光谱仪器, 采集土壤样本的光谱数据, 选用 EPO 校正土壤水分对光谱信息的影响, 引用 DCGAN 进行样本增广, 并结合 1D-CNN 进行模型训练, 最终构建具有鲁棒性与可靠性的土壤盐分快速、精准反演模型, 以期为实现盐渍化土壤棉花种植的生长调控, 以及推动水肥数字化科学管理提供理论依据与技术支持。

1 材料与方法

1.1 土壤样本制备

土壤样本于 2022 年 3 月取自新疆巴音郭楞蒙古自治州库尔勒市尉犁县, 包括正常棉田及盐渍化棉田 (41°50' N, 86°18' E) (图 1), 取土深度为 0~40 cm, 土壤黏粒、粉粒及砂粒的占比分别为 7.48%、51.19% 和 41.33%, 依据国际制土壤质地分类土壤为粉砂质壤土。试验过程中共调查了约 3 000 m² 正常棉田和 4 000 m² 盐渍化棉田, 取土点位数量分别为 113 和 115, 取样坑位间隔约为 5 m, 共采集了 228 份不同位置的土壤样本。由于当地棉田土壤存在一定的地膜残留污染, 为避免残膜堵住筛孔影响过筛效率, 先采用 24 目 (0.7 mm) 筛网筛除植物根系及塑料残膜, 再用 30 目 (0.6 mm) 筛网获得粒径 0.6 mm 以下的主要土壤颗粒。将 228 份过筛后的土壤完全烘干后, 每份土样取 10 g 样本以土水比 1:5 制取土壤浸提液, 使用带温度校正的 TDS307 电导率仪 (电导率分辨率 0.001 μS/cm, 温度分辨率 0.1 °C) 测量土壤浸提液的电导率 (EC_{1:5}), 作为土壤盐分指示参数。为了得到不同含水率以及不同电导率的土壤样本, 将每份剩余干土分成 2~3 份 (约 50 g) 进行不同程度的湿水处理 (处理后的土壤样本含水率区间为 0~24%), 并迅速密封于直径 100 mm 的圆柱体铝盒中静置 8 h, 最后共获得 467 份不同含水率及含盐量的土壤样本。

N, 86°18' E) (图 1), 取土深度为 0~40 cm, 土壤黏粒、粉粒及砂粒的占比分别为 7.48%、51.19% 和 41.33%, 依据国际制土壤质地分类土壤为粉砂质壤土。试验过程中共调查了约 3 000 m² 正常棉田和 4 000 m² 盐渍化棉田, 取土点位数量分别为 113 和 115, 取样坑位间隔约为 5 m, 共采集了 228 份不同位置的土壤样本。由于当地棉田土壤存在一定的地膜残留污染, 为避免残膜堵住筛孔影响过筛效率, 先采用 24 目 (0.7 mm) 筛网筛除植物根系及塑料残膜, 再用 30 目 (0.6 mm) 筛网获得粒径 0.6 mm 以下的主要土壤颗粒。将 228 份过筛后的土壤完全烘干后, 每份土样取 10 g 样本以土水比 1:5 制取土壤浸提液, 使用带温度校正的 TDS307 电导率仪 (电导率分辨率 0.001 μS/cm, 温度分辨率 0.1 °C) 测量土壤浸提液的电导率 (EC_{1:5}), 作为土壤盐分指示参数。为了得到不同含水率以及不同电导率的土壤样本, 将每份剩余干土分成 2~3 份 (约 50 g) 进行不同程度的湿水处理 (处理后的土壤样本含水率区间为 0~24%), 并迅速密封于直径 100 mm 的圆柱体铝盒中静置 8 h, 最后共获得 467 份不同含水率及含盐量的土壤样本。



注: 黑色标记点为采样点。

Note: Black dots indicate sampling points.

图 1 试验田无人机航拍示意图
Fig.1 Schematic of UAV aerial images of fields

1.2 土壤样本光谱采集

土壤的可见/短波近红外和长波近红外光谱分别由 ASD HandHeld 2 (光谱范围为 380~1 075 nm, 分辨率为 1 nm, Malvern Panalytical, 英国) 和 SW2520-050-NIRA (光谱范围为 900~1 700 nm, 分辨率为 15 nm, 超微光学, 中国台湾) 采集。为了确保 2 台光谱仪同时采集到样本的同一个位置, 利用 Y 型光纤 (SIH400 Y6+1, 鑫锐光子科技有限公司, 中国) 连接接触式卤素灯光源探头 (色温 2 900K) 和 2 台光谱仪。联用仪器信噪比较高的可见/短波近红外 (400~1 000 nm) 和长波近红外 (960~1 693 nm) 波段的光谱信息, 获取更长带宽的土壤盐分光学信息, 因此, 有必要进行波段“拼接”, 获得 400~1 693 nm 的光谱用于后续数据分析, 双波段“

拼接”的方法见文献[29]。

ASD HandHeld 2 和 SW2520-050-NIRA 的积分时间分别设置 50 和 420 ms, 平滑次数均为 15。试验前, 光源预热 15 min, 取每个土壤样本的 3 个不同位置光谱数据的平均值作为该样本光谱值。样本的光谱反射率由式(1)计算得到:

$$R = (I_{\text{original}} - I_{\text{dark}})/(I_{\text{white}} - I_{\text{dark}}) \quad (1)$$

式中 R 为校正后的光谱反射率, %; I_{dark} 为暗电流; I_{original} 为样本原始光谱; I_{white} 为参考板光谱。

1.3 光谱数据校正处理

EPO 在主成分分析的基础上, 把原始光谱数据投影到与外部干扰因素正交的空间, 只需对少数代表性的样本进行分析测试, 有效降低了模型构建的复杂度^[30]。通常, 受水分影响后, 光谱仪采集到的光谱 \mathbf{X} 可表示为

$$\mathbf{X} = \mathbf{XP} + \mathbf{XQ} + \mathbf{r} \quad (2)$$

式中 \mathbf{P} 为 \mathbf{X} 对土壤盐分有用信息的投影矩阵, \mathbf{Q} 为干扰因素(土壤含水率)的投影矩阵, \mathbf{r} 为冗余矩阵, 忽略不计。EPO 求解 \mathbf{P} 的步骤如下:

首先, 计算不同含水率下土壤的差异光谱矩阵 \mathbf{D} :

$$\mathbf{D} = \mathbf{X}_m - \mathbf{X}_0 \quad (3)$$

式中 \mathbf{X}_m 为土壤在不同含水率下的光谱, \mathbf{X}_0 为干样土壤的光谱。进一步, 计算 \mathbf{D} 的协方差矩阵, 并进行奇异值分解, 即:

$$\text{SVD}(\mathbf{D}^T \mathbf{D}) = \mathbf{U} \mathbf{S} \mathbf{V}^T \quad (4)$$

取右奇异矩阵 \mathbf{V} 的前 g 列(即为 EPO 维度或主成分), 得到新的右奇异矩阵 \mathbf{V}_g , 参数 g 的选择受到 \mathbf{S} 矩阵中奇异值的影响, 可通过优化选定 g 值。EPO 维度数值 g 的选定以 \mathbf{S} 矩阵中前 g 个奇异值的累计值达到总体的 99% 为标准。干扰因素(土壤含水率)的投影矩阵 \mathbf{Q} 可表示为

$$\mathbf{Q} = \mathbf{V}_g \mathbf{V}_g^T \quad (5)$$

$$\mathbf{P} = \mathbf{I} - \mathbf{Q} \quad (6)$$

$$\mathbf{X}^* = \mathbf{XP} \quad (7)$$

式中 \mathbf{I} 为单位矩阵, 将光谱仪采集到的土壤原始光谱 \mathbf{X} 投影到子空间 \mathbf{P} , 即可获得去水分影响的光谱 \mathbf{X}^* 。

1.4 代表性标样的制备

选取电导率约为 100 (S100)、300 (S300) 和 500 $\mu\text{S}/\text{cm}$ (S500) 的 3 个梯度样本作为 EPO 算法求解子空间 \mathbf{P} 的代表样本, 并比较它们的适用性。在制作标样时, 向完全干燥的代表性样本中喷洒相应质量的去离子水来增加土壤含水率, 并迅速密封静置 8 h 使去离子水被土壤充分吸收。共得到了 0、3%、9%、13% 和 21% 共 5 个含水率梯度的代表性标样。

1.5 样本增广与质量评估

为了尽可能获得多样性更强的样本集, 缓解卷积神经网络的过拟合问题, 引入生成对抗网络模型, 采用深度卷积生成对抗网络 (DCGAN) 增广样本。DCGAN 在

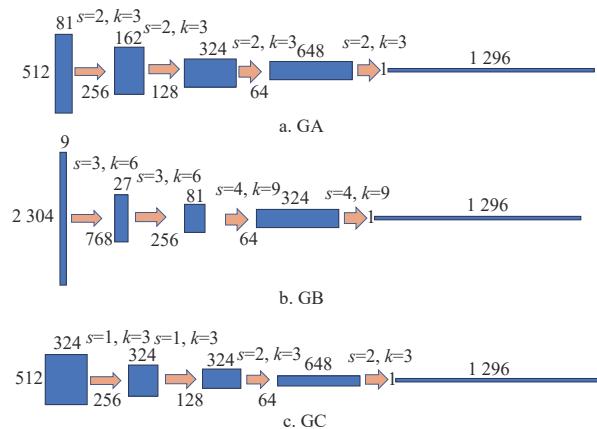
传统生成对抗网络的基础上将卷积层引入到生成器和判别器, 能够更有效地捕捉数据空间关系和局部结构。相较于常见的神经网络的设计, DCGAN 通过剔除所有池化层来避免数据丢失, 并在每个卷积层后接入批归一化层 (batch normalization) 以提升数据鲁棒性。在生成器中, DCGAN 通过转置卷积层对特征图进行上采样, 使得生成器能够精准地生成高分辨率样本。生成对抗过程中, 将生成器生成的伪光谱与真实的样本 1:1 混合后, 由判别器进行真假判断, 并通过判断结果计算损失函数(式(8)和式(9)), 再根据损失函数进行反向传播更新生成器和判别器的参数。为了避免在对抗的迭代过程中, 判别器将真实样本“记住”导致对抗失败, 在真样本和假样本的混合步骤设置了 25% 的概率翻转, 即随机取 25% 的真样本标签设置为假样本, 随机取 25% 的生成样本标签设置为真样本。

$$G_{\text{loss}} = -\frac{1}{m} \sum_{i=1}^m \lg(D(G(z^i))) \quad (8)$$

$$D_{\text{loss}} = -\frac{1}{m} \sum_{i=1}^m \lg(D(x^i)) + \lg(1 - D(G(z^i))) \quad (9)$$

式(8)和式(9)分别为生成器的损失函数(G_{loss})和判别器的损失函数(D_{loss}), 其中 z^i 为输入噪声, x^i 为输入的真实样本, G 和 D 分别代表生成器和判别器。

目前, 针对一维波谱数据的生成对抗网络的研究尚少, 有必要对 DCGAN 进行一定的优化及对比。本文根据不同的卷积步幅和卷积核大小以及采样步长设计了 3 种生成器, 分别为 Generator A (GA)、Generator B (GB) 和 Generator C (GC), 如图 2 所示。GA 采用主流的设计思路, 卷积核大小为 3, 步幅为 2, 而 GB 和 GC 则分别采用较高和较低的反向卷积步幅策略。判别器首先通过随机失活函数对数据进行处理, 失活率为 0.5, 卷积参数与生成器对称, 激活函数使用 Leaky ReLU, 泄露率为 0.2, 最后使用卷积核代替神经元将结果输出至 Sigmoid 函数。



注: s 为卷积步长; k 为转置卷积核的大小($k \times k$)。方体代表数据, 其上侧及左侧的数值分别代表该阶段数据的大小, 下同。

Note: s is convolution step size; k is size of transposed convolution kernel ($k \times k$). Cube represents data, and the value on the upper and left sides of the cube represent the data size at that stage, same below.

图 2 根据不同卷积步幅和卷积核大小设计的生成器 A、B 和 C
Fig.2 Generators A (GA), B (GB), and C (GC) designed according to different convolution strides and convolution kernel sizes

不同生成器和判别器产生的生成样本通过 FID (fréchet inception distance)^[31] 得分进行生成质量评估。相较于 IS (inception score)^[32], FID 得分考虑了真实样本的语义特征, 同时对样本的伪影和失真的判断更具鲁棒性, 因此更适合具有特定语义属性的一维光谱数据。构建 FID 得分方法时, 先将长度为 1 296 的一维光谱数据排列至 36×36 的二维平面中, 再利用线性插值将 36×36 的二维平面上采样至 299×299 平面上, 在通道维度进行复制至 $299 \times 299 \times 3$ 的尺度, 输送到公开的 InceptionNet-V3^[33] 预训练模型进行特征提取, 最后将 InceptionNet-V3 的池化层作为尺度为 2 048 的特征输出, FID 计算 2 个多元高斯分布之间的 Fréchet 距离^[34], 其中每个分布的均值和协方差分别根据真实数据和生成数据的特征值计算, FID 得分越小, 表征生成样本质量越好, 越接近真实数据的分布。FID 得分 (S) 计算式如下:

$$S(x, \hat{x}) = \| \mu_x - \mu_{\hat{x}} \|^2 + Tr(\Sigma_x + \Sigma_{\hat{x}} - 2(\Sigma_x \Sigma_{\hat{x}})^{\frac{1}{2}}) \quad (10)$$

式中 μ_x 和 $\mu_{\hat{x}}$ 分别为真实样本和生成样本的特征均值, Σ_x 和 $\Sigma_{\hat{x}}$ 分别为真实样本和生成样本特征矩阵的协方差, $Tr()$ 为矩阵求迹。

1.6 反演模型构建及评价

利用 Kennard-Stone (KS) 算法从经 EPO 校正后的光谱 X^* 中, 按照 3:1 的比例划分建模集和预测集, 样本数量分别为 311 和 156。本研究分别构建线性模型偏最小二乘回归 (partial least squares regression, PLSR) 和非

线性模型随机森林^[35], 以及两种不同结构的卷积神经网络进行对比分析。PLSR 是经典的线性建模方法, 结合了主成分分析和典型相关分析, 能解决自变量之间的多重相关性的问题, 在数据量小或者样本数比特征维数小的建模情形中也能适用^[36]。RF 模型采用自助法 (bootstrap) 重采样技术, 引入随机特征选择, 有放回地从训练样本集 N 中重复随机抽取 k 个样本构成新的训练集, 并由此构建 k 棵决策树, 能够有效解决由异常值和噪声产生的模型过拟合的问题, 对多元共线性的数据不敏感, 对缺失数据和非平衡的数据表现出稳健的预测能力, 具有较好的鲁棒性^[35]。本文选用的 3 种不同结构的 1D-CNN, 分别参考了 VGG、ResNet 和 EfficientNet 的主干网络进行设计, 记为 VNet、RNet 和 ENet。基于 VGG 主干网络设计的 VNet 参考了陈庆等^[18] 的优化结构, 卷积核大小为 4, 包含 6 个卷积深度, 并在每个平均池化层后引入一个比例为 0.3 的随机失活层 (dropout layer) 防止过拟合。ENet 采用 Swish 激活函数, 引入了跳跃连接与 SE (squeeze and excitation) 注意力机制, 其不仅能有效实现更深的卷积深度, 还能对通道方向上的数据特征进行感知^[37]。RNet 由 3 层残差网络模块构成, 其结构相较于 ENet 较为精简, 模型容量更少 (如图 3 所示)。各模型的预测性能采用决定系数 (R^2) 与均方根误差 (root mean square error, RMSE) 进行评价, R^2 和 RMSE 的值分别越靠近 1 和 0, 说明拟合程度越高, 模型性能越好。

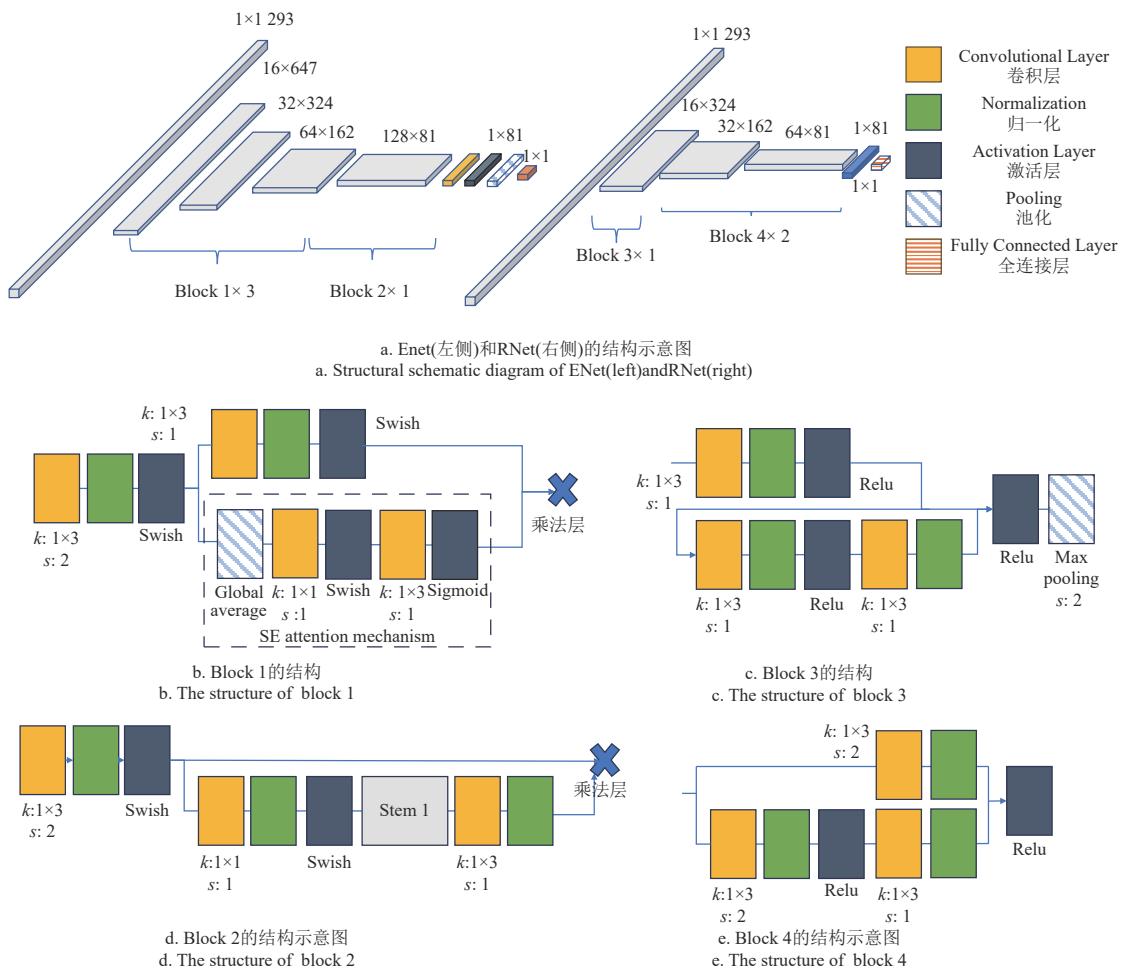


图 3 网络模型结构示意图
Fig.3 Schematic diagram of network model structure

2 结果与分析

2.1 试验棉田土壤电导率的统计特征

试验棉田土壤电导率的统计特征如表1所示。样本全集的电导率变化范围为 $177.8\sim 1920 \mu\text{S}/\text{cm}$, 均值为 $962.1 \mu\text{S}/\text{cm}$, 变异系数为47.6%, 其中盐渍化田块与正常田块的土壤样本浸溶液的电导率分布均值分别为1408.6和354.6 $\mu\text{S}/\text{cm}$, 土壤电导率具有较强的变异性, 不属于同一正态分布, 这与杨未静等^[38]调查的北疆棉田、及唐茂松等^[39]不同灌溉梯度设置的试验棉田盐分分布特点相似, 灌溉水的含盐量与排水策略的不同也会使同一区域不同地块的土壤的含盐量呈现显著差异^[4,40], 是新疆次生盐渍化的成因之一^[41]。建模集和预测集的均值分别为1019.1和848.4 $\mu\text{S}/\text{cm}$, 变异系数为43.8%和54.3%。数据总体分布不均匀。全集数据的偏度为-0.19, 呈现左偏态分布。建模集的偏度为-0.34, 数据分布也呈现左偏态, 而验证集的偏度为0.12, 呈现右偏态分布。全集、建模集和验证集的峰度分别为1.71、1.90和1.55, 均小于3, 说明未出现极值。此外, 在样本全集中土壤水分梯度与对应浸提液电导率的皮尔逊相关系数为0.143, 两者分布相关性弱, 含水率梯度设置较为合理。

2.2 土壤含水率对土壤光谱反射率的影响

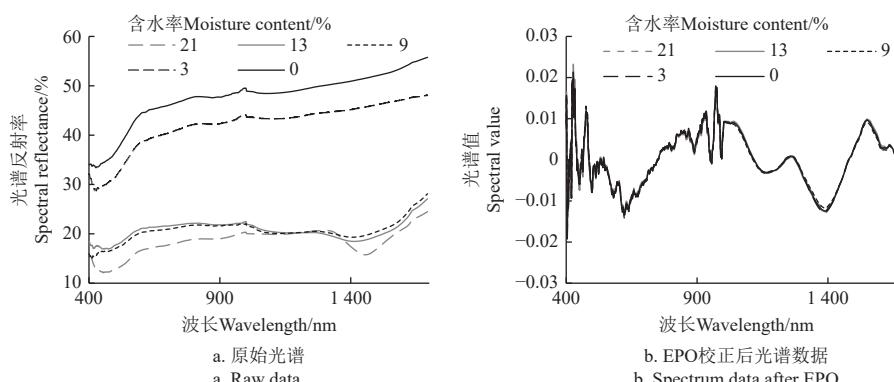
图4a展示了土壤电导率为 $303 \mu\text{S}/\text{cm}$ 的棉田土壤样

本中, 5个不同含水率土壤的平均光谱反射率。在全光谱区域内($400\sim 1693 \text{ nm}$), 随着土壤含水率的增加, 当含水率未超过土壤所能容纳的最大含水率时, 土壤的光谱反射率整体呈现降低趋势, 与前人研究结果一致^[5], 这主要与光在湿润的土壤颗粒间的折射增加有关, 考虑土壤水分对盐分及光谱的影响, 有必要校正去除光谱中的含水率信息, 从而有助于建立更加稳健的模型。如图4b所示, 经EPO校正后, 不同含水率的土壤反射率光谱之间的差异几乎被消除, 趋于一致, 数据重复性变好。说明土壤的光谱信息经EPO校正后, 能够有效消减土壤含水率波动所产生的扰动信息。

表1 棉田土壤电导率的统计特征

Table 1 Statistical characteristics of soil electrical conductivity of cotton field

指标 Indexes	全集 Total	建模集 Model	验证集 Validation dataset
样本数 Sample size	467	311	156
最小值 Minimum/($\mu\text{S}\cdot\text{cm}^{-1}$)	177.8	177.8	193.6
最大值 Maximum/($\mu\text{S}\cdot\text{cm}^{-1}$)	920.0	1920.0	1670.0
均值 Mean/($\mu\text{S}\cdot\text{cm}^{-1}$)	962.1	1019.1	848.4
标准差 Standard deviation/($\mu\text{S}\cdot\text{cm}^{-1}$)	457.8	446.4	460.5
变异系数 Coefficient of variation/%	47.6	43.8	54.3
偏度 Skewness	-0.19	-0.34	0.12
峰度 Kurtosis	1.71	1.90	1.55



注: EPO校正采用混合标样集(S100+S300+S500), 主成分为7。

Note: The EPO was performed using a mixed sample set (S100+S300+S500) with a principal component of 7.

图4 土壤电导率为 $303 \mu\text{S}\cdot\text{cm}^{-1}$ 时不同含水率土壤的光谱曲线

Fig.4 Spectral curves of soils with different moisture with soil electrical conductivity of $303 \mu\text{S}\cdot\text{cm}^{-1}$

2.3 EPO算法校正前后的模型性能对比分析

对比了EPO算法校正前后的光谱($400\sim 1693 \text{ nm}$), 建立不同的模对土壤电导率预测性能的影响, 其中PLSR的主成分因子为15; RF中决策树的棵数和节点处分类属性的个数分别为30和50; 卷积神经网络训练过程中, 学习率为0.008, 最小批次为64, 最大训练轮数为200, 优化器采用Adam。根据选择奇异值大小占总体的99%以上的原则, 采用混合标样集(S100+S300+S500)进行EPO校正, 其主成分数为7(后续试验均为该参数)。模型预测结果如表2所示, 对于预测不同土壤含水率条件下的土壤电导率, 经EPO校正后的光谱数据建立的模型, 表现出较强的校正作用, 且非线性模型的预测性能优于

线性模型。EPO-RNet的预测效果最佳, 预测集的RMSE和 R^2 分别为 $186.291 \mu\text{S}/\text{cm}$ 和0.844, 较EPO-PLSR分别降低了14.4%和提高了11.5%, 相较于仅用RNet分别降低了8.9%和提高了11.1%。对比2个不同架构的1D-CNN模型(VNet和ENet), RNet结合EPO校正算法可在较少的模型参数(33.7×10^3)下实现更佳的预测效果, VNet的综合表现较差, 而E-net模型结合EPO算法后出现了较严重的过拟合问题, 最终EPO-RNet的模型精度对比两者均有较大的提高。结果表明, EPO-RNet算法在棉田土壤含水率校正及盐分快速反演中具有较好的预测性能, 利用1D-CNN对一维数据预测时采用较少容量的残差网络设计, 有助于构建更为精准的模型。

表 2 采用 EPO 校正前后光谱建立的电导率模型的性能

Table 2 Performance of electrical conductivity models trained on spectra with and without EPO adjustment

模型 Models	参数量 Parameter size/(×10 ³)	建模集 Model establishment		验证集 Validation dataset	
		RMSE/(μS·cm ⁻¹)	R ²	RMSE/(μS·cm ⁻¹)	R ²
随机森林 (RF) Random forest	-	243.402	0.696	254.416	0.679
EPO-RF	-	211.839	0.761	231.787	0.727
偏最小二乘法 (PLSR)	-	232.877	0.734	241.115	0.695
Partial least squares regression	-	222.415	0.743	217.728	0.757
EPO-PLSR	-	118.984	0.937	232.126	0.721
基于 VGG 设计的一维神经网络 (VNet)	350.1	148.659	0.897	213.920	0.762
1D-CNN based on VGG	350.1	135.823	0.910	221.355	0.741
EPO-VNet	170.4	107.988	0.946	207.507	0.785
基于 EfficientNet 设计的一维神经网络 (ENet)	170.4	152.304	0.872	227.451	0.758
1D-CNN based on EfficientNet	33.7	127.136	0.930	186.291	0.844
EPO-ENet	33.7				
基于 ResNet 设计的一维神经网络 (RNet)					
1D-CNN based on ResNet					
EPO-RNet					

注: RMSE 为均方根误差。

Note: RMSE is root mean square error

进一步对比不同校正标样集和不同波段的光谱对土壤电导率预测的适用性, 如表 3 所示, 本文进行了消融试验, 即分别采用不同标样集进行 EPO-RNet 的建模。结果表明, 采用不同标样集对模型总体影响较小, 其中 EPO 采用混合标样集 (S100+S300+S500) 求解转换矩阵, 校正得到光谱并建立模型的综合表现相对其他独立标样集较好。采用可见/短波近红外或长波近红外的光谱进行建模分析 (表 4), 经 EPO 校正后, 基于可见/长波近红外 (400~1 693 nm) 建立的 EPO-RNet 模型预测效果最佳, RMSEP 和 R² 表现总体优于基于长波近红外 (966~1 693 nm) 的 191.500 μS/cm 和 0.809, 及可见/短波近红外 (400~1 000 nm) 的 204.304 μS/cm 和 0.847。

表 3 采用不同标样集的 EPO 算法校正 400~1 693 nm 范围内光谱建立的 RNet 对土壤电导率的预测性能

Table 3 Prediction performance of soil electrical conductivity using RNet with EPO adjusted spectra in the range of 400~1 693 nm based on different standard sample sets

标样集 Standard set	建模集 Model establishment		验证集 Validation dataset	
	RMSE/(μS·cm ⁻¹)	R ²	RMSE/(μS·cm ⁻¹)	R ²
S100	0.927	130.068	0.822	191.659
S300	0.913	134.703	0.817	192.133
S500	0.951	103.412	0.836	187.540
S100+S300+S500	0.933	127.138	0.844	186.291

表 4 采用混合标样集的 EPO 算法校正不同波段光谱建立的 RNet 对土壤电导率的预测性能

Table 4 Prediction performance of soil electrical conductivity using RNet with EPO adjusted spectra in different wavebands based on mixed standard samples

波段 Band/nm	建模集 Model establishment		验证集 Validation dataset	
	RMSE/(μS·cm ⁻¹)	R ²	RMSE/(μS·cm ⁻¹)	R ²
400~1 000	0.922	127.972	0.847	204.304
966~1 693	0.913	141.390	0.809	191.500
400~1 693	0.933	127.138	0.844	186.291

2.4 样本扩增对模型预测性能的影响分析

为了缓解 CNN 模型的过拟合问题, 进一步提高模型的预测性能、优化泛化差异, 采用生成式对抗网络进行进一步的数据增强。为了保证生成数据的稳定性, 利用 KS 算法从 2 000 个随机生成样本中筛选出 311 个用于样本扩增。在利用 3 种不同参数的深度卷积生成对抗网络训

练后, 按 1:1 的比例将生成的假样本加入到训练集中, 使训练集样本数由 311 增加至 622。随后, 利用 RNet 对扩充后的数据进行学习, 结果如表 5 所示, 其中 FID 得分建立于 467 个原始样本数据与 311 个扩增的生成样本数据。结果表明, 无论是否进行 EPO 校正, 使用生成对抗网络扩充增样本后, 模型预测能力得到了一定提升, 生成样本在一定程度上优化了预测模型的泛化能力。EPO 校正后, 利用生成器 GB 的 FID 得分最优, 相较于生成器 GA 和生成器 GC 分别低了 7.9% 和 13.4%。EPO-DCGAN (GB)-RNet (简称为 EPO-DCGAN-RNet) 模型在验证集的 RMSE 和 R² 分别为 136.472 μS/cm 和 0.910。原因可能是在相同转置卷积深度的生成器中, 对反向卷积步幅和反向卷积核大小进行合适的扩大, 有助于提高一维光谱数据的生成效果, 更高的步幅和更大的反向卷积核大小能够生成较长的特征结构, 使生成数据更贴合光谱曲线的语义。同时, 为了进一步讨论 DCGAN 提高模型预测性能的作用机制, 采用 SG 滤波法 (Savitzky Golay Filter) 作为对比, 在进行样本扩充前对光谱数据的平滑降噪处理 (SG 滤波的多项式次方参数为 4, 平滑帧长为 7)。经 SG 平滑处理后, 模型过拟合的现象同样有所缓解, 其验证集 R² 由 0.844 提高至 0.877。先对光谱数据进行 SG 平滑再利用 DCGAN 进行样本扩增, 则对模型预测性能的提升不显著, 预测集的 RMSE 与 R² 分别为 159.501 和 0.885, 较未作平滑处理训练生成的模型表现更差。使用 FID 对比 SG 平滑前后的数据集差异, 平滑后数据的 FID 值为 36.50, 说明平滑后的数据特征存在一定程度的丢失和改变。结果表明, 利用 DCGAN 生成的数据较 SG 平滑处理在样本特征上有着更大的变化尺度, 但扩增样本能在不改变原始数据特征的情况下, 通过增加样本多样性和训练量来提升 CNN 模型对数据特征与噪声的判别能力, 在训练样本量有限的情况下具有一定的优势。从信息论的角度进行分析, DCGAN 在基于先验知识 (真实样本) 的条件下尽可能地生成接近真实的样本, 这一过程并不会创造新信息, 无法通过对抗过程来增加

训练集基本特征的多样性。但对于样本多样性而言, DCGAN 具有基于现有特征进行缩放及组合以形成更多具有特异性高级特征的能力, 因此它可以强化预测模型的泛化能力, 提高模型对特征挖掘和学习能力, 这也导致 DCGAN 在过少的训练集(基本特征不足)或足够丰富的训练集(高级特征充足)的场景下, 很难带来显著的预测性能效果提升^[42]。而水盐耦合场景下的土壤高光谱训练集具有较多的基本特征, 可以通过 DCGAN 降低训练模型对于样本丰度的依赖, 来提升模型挖掘特征的能力, 从而减少土壤样本制备的工作量。基于 EPO-DCGAN-RNet 与空间插值算法建立的土壤实际分布图和预测分布图如图 5 所示, 结果表明, 在盐分数值和空间分布形态上的预测结果与真实的棉田盐分状态基本一致, 结合采样点的坐标信息后, EPO-DCGAN-RNet 可以进一步实现土壤盐分分布的高效反演。综上, 可采用 EPO-DCGAN-RNet 作为棉田土壤盐分(土壤浸提液电导率)反演的高效策略。

表 5 样本增广后构建的 RNet 模型对土壤电导率的预测性能

Table 5 Performance of RNet for predicting soil electrical conductivity after sample augmentation

模型 Model	生成器 参数量 Parameter size of generator $(\times 10^6)$	FID	建模集 Model establishment		预测集 Validation dataset	
			RMSE $(\mu\text{S}\cdot\text{cm}^{-1})$	R^2	RMSE $(\mu\text{S}\cdot\text{cm}^{-1})$	R^2
EPO-RNet	-	-	127.138	0.933	186.291	0.844
EPO-						
DCGAN(GA)-RNet	4.706	85.12	97.082	0.960	153.058	0.861
EPO-						
DCGAN(GB)-RNet	14.042	78.35	115.420	0.942	136.472	0.910
EPO-						
DCGAN(GC)-RNet	17.272	90.47	125.750	0.928	177.272	0.892
EPO-SG-RNet	14.042	117.25	167.718	0.860	204.91	0.782
EPO-SG-						
DCGAN(GB)-RNet	-	36.50	127.440	0.941	166.041	0.877

2.5 土壤电导率预测的光谱指示性波段

为了探讨不同波长数据对 1D-CNN 模型预测土壤电导率影响的重要性, 利用梯度加权类映射激活法(gradient-weighted class activation mapping, Grad CAM)计算

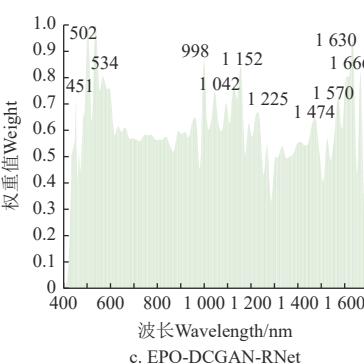
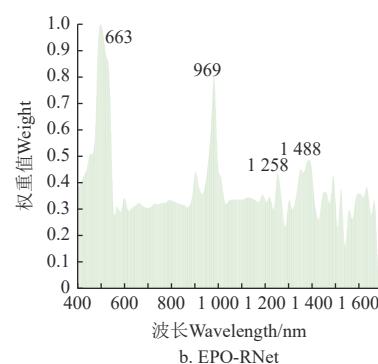
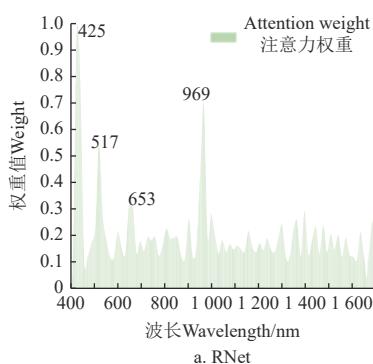


图 6 土壤电导率预测中不同方法对不同波段光谱的归一化注意力权重分布

Fig.6 Normalized attention weight distribution of different methods on different band spectra for soil electrical conductivity prediction

RNet 在所有预测集中各个波段的注意力权重的均值^[43]。将各波段注意力权重自归一化如图 6 所示, 利用原始光谱(未经 EPO 校正), RNet 对 420~435、500~530、645~655、950~980 nm 范围的反射率的注意力权重分布较高(图 6a)。相较于原始光谱数据, 经过 EPO 校正后, RNet 对光谱注意力分布得到优化(图 6b)。经过 DCGAN(GB) 进行样本扩充后, 在 451、502、534、998、1152、1225、1474、1570、1630 和 1666 nm 处出现了明显波峰, 相较于样本扩增前, RNet 模型在噪声相对较高的 400~1 000 nm 注意力权重相对降低(图 6c), 这与上述结论吻合。在其敏感的波段中, 分布于 450~460、530~540、和 1 630~1 640 nm 的反射率与土壤的 Cl^- 、 Na^+ 和 Ca^{2+} 含量相关, 1 220~1 225 nm 和 1 615~1 630、1 665~1 675 nm 反射率分别与土壤中的 CO_3^{2-} 和 SO_4^{2-} 含量相关, 盐分特征波段与前人研究的基本吻合^[44-45], 说明 RNet 预测土壤盐分含量主要依赖 Cl^- 、 Ca^{2+} 、 CO_3^{2-} 、 SO_4^{2-} 等离子的特征光谱。

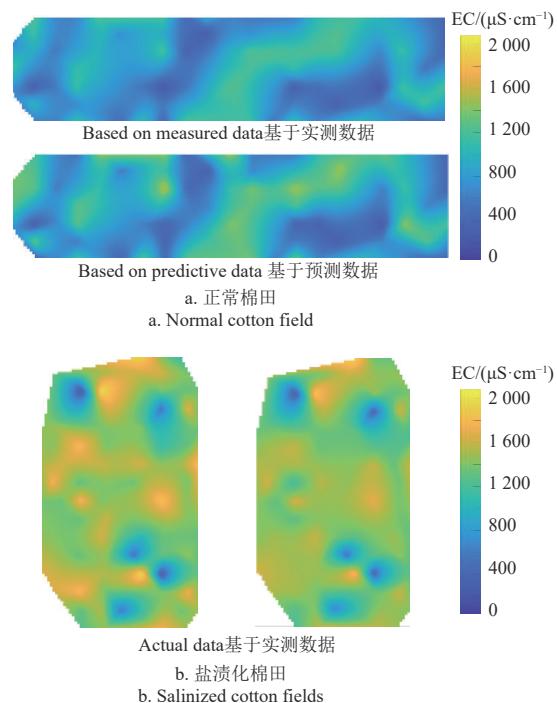


图 5 基于三角剖分的自然邻点插值的土壤电导率分布图

Fig.5 Distribution of soil electrical conductivity based on natural neighbor interpolation using triangulation

3 结 论

本文联用可见/短波近红外(400~1 000 nm)和长波近红外(960~1 693 nm)光谱仪,采集新疆地区棉田中不同含水率与含盐量土壤样本的光谱数据,采用光谱校正法消减土壤含水率干扰信息,结合样本增广方法扩充样本集实现模型的快速构建,同时对比了多种机器学习模型及1D-CNN设计思路的性能表现,解析模型预测精度提升的优化机制,并进一步挖掘土壤盐分的波谱指纹。结果表明:

1) 外部参数正交化校正(external parameter orthogonalization, EPO)能够有效地滤除水分对盐分的干扰,结合机器学习模型或卷积神经网络可以使模型的预测精度得到进一步提升,比校正前模型EPO-PLSR, EPO-RF、EPO-VNet、EPO-ENet及EPO-RNet的预测表现均有提高,1D-CNN的注意力权重分布较EPO校正前得到改善。其中,采用ResNet主干网络和较少参数量设计的1D-CNN(RNet)综合表现最好,其设计思路和结构可为其他光谱模型的建立提供参考。

2) 针对序列较长的高光谱数据,适当增加深度卷积对抗生成网络的卷积步幅和卷积核长度有助于获得更优质的生成样本。基于较大卷积步幅和卷积核大小设计的生成器B(Generator B),相较于生成器A和生成器C在生成的扩增样本集中获得更优异的FID得分,其FID得分较GA和GC分别降低了7.9%和13.4%。结合深度卷积生成对抗网络(deep convolutional generative adversarial networks, DCGAN)和基于残差神经网络设计的EPO-DCGAN-RNet模型,从而在训练样本存在一定限制的条件下,进一步提高模型对土壤含盐量预测的稳定性和精度。

3) EPO-DCGAN(GB)-RNet在验证集的均方根误差和 R^2 分别为136.472 $\mu\text{S}/\text{cm}$ 和0.910,优于使用SG滤波降噪的EPO-SG-RNet和未采用样本扩增的EPO-RNet等模型。同时1D-CNN结合Grad CAM有助于棉田土壤浸溶液电导率的特征波段挖掘及分析,也可为土壤盐分组成分析提供指导。

[参 考 文 献]

- [1] WEI F, WANG C. Soil salinity prediction based on scale-dependent relationships with environmental variables by discrete wavelet transform in the Tarim Basin[J]. *Catena*, 2021, 196(1): 104939.
- [2] SHARIF I, ALEEM S, FAROOQ J, et al. Salinity stress in cotton: effects, mechanism of tolerance and its management strategies[J]. *Physiology Molecular Biology of Plants*, 2019, 25(4): 807-20.
- [3] 王全九,毕磊,张继红.新疆包头湖灌区农田土壤水盐热特性空间变异特征[J].*农业工程学报*,2018,34(18): 138-145.
WANG Quanjiu, BI Lei, ZHANG Jihong. Spatial variability analysis of large-scale soil water, salt and heat characteristics in Baotou lake irrigation area of Xinjiang[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(18): 138-145. (in Chinese with English abstract)
- [4] 郭全恩,南丽丽,李保国,等.灌溉水盐分组成对土壤水盐迁移参数的影响[J].*农业工程学报*,2017,33(23): 123-128.
GUO Quan'en, NAN Lili, LI Baoguo, et al. Effect of salt ion composition of irrigation water on parameters of soil water and salt movement[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2017, 33(23): 123-128. (in Chinese with English abstract)
- [5] SHARMA V, CHAUHAN R, KUMAR R. Spectral characteristics of organic soil matter: A comprehensive review[J]. *Microchemical Journal*, 2021, 171: 106836.
- [6] YU H, KONG B, WANG Q, et al. Hyperspectral remote sensing applications in soil: A review[J]. *Hyperspectral Remote Sensing*, 2020, 14: 269-291.
- [7] 赵文举,马芳芳,马宏,等.基于无人机多光谱影像的土壤盐分反演模型[J].*农业工程学报*,2022,38(24): 93-101.
ZHAO Wenju, MA Fangfang, MA Hong, et al. Soil salinity inversion model based on the multispectral images of UAV[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(24): 93-101. (in Chinese with English abstract)
- [8] 孙亚楠,李仙岳,史海滨,等.基于高光谱数据的盐荒地和耕地土壤盐分遥感反演优化[J].*农业工程学报*,2022,38(23): 101-111.
SUN Yanan, LI Xianyue, SHI Haibin, et al. Optimizing the inversion of soil salt in salinized wasteland using hyperspectral data from remote sensing[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2022, 38(23): 101-111. (in Chinese with English abstract)
- [9] 陈睿华,王怡婧,张俊华,等.利用正交信号校正消除水分影响的银川平原土壤盐分高光谱反演[J].*农业工程学报*,2023,39(19): 122-130.
CHEN Ruihua, WANG Yijing, ZHANG Junhua, et al. Hyperspectral inversion of soil salinity after correcting moisture effect in Yinchuan Plain using orthogonal signals[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(19): 122-130. (in Chinese with English abstract)
- [10] XU C, ZENG W, HUANG J, et al. Prediction of soil moisture content and soil salt concentration from hyperspectral laboratory and field data[J]. *Remote Sensing*, 2016, 8(1): 42.
- [11] DING J L, NURMEMET Ilyas, WANG, J Z, et al. Quantitative estimating salt content of saline soil using laboratory

- hyperspectral data treated by fractional derivative [J]. *Journal of Spectroscopy*, 2016, 2016:1081674.
- [12] 陈睿华, 尚天浩, 张俊华, 等. 不同光谱类型对银川平原土壤含盐量反演精度的影响与校正[J]. 应用生态学报, 2022, 33(4): 922-930.
CHEN Ruihua, SHANG Tiaohao, ZHANG Junhua, et al. Effects of different spectra types on the accuracy and correction of soil salt content inversion in Yinchuan Plain, China[J]. *Chinese Journal of Applied Ecology*, 2022, 33(4): 922-930. (in Chinese with English abstract)
- [13] ROGER J M, CHAUCHARD F, CHEMOMETRICS V B M J, et al. EPO-PLS external parameter orthogonalisation of PLS application to temperature-independent measurement of sugar content of intact fruits [J]. *Chemometrics and Intelligent Laboratory Systems*, 2003, 66(2): 191-204.
- [14] WIJEWARDANE K N, GE Y, MORGAN C L S, et al. Moisture insensitive prediction of soil properties from VNIR reflectance spectra based on external parameter orthogonalization[J]. *Geoderma*, 2016, 267(1): 92-101.
- [15] 洪永胜, 于雷, 朱亚星, 等. 基于EPO算法去除水分影响的土壤有机质高光谱估算[J]. 土壤学报, 2017, 54(5): 1068-1078.
HONG Yongsheng, YU Lei, ZHU Yaxing, et al. Removing the effect of soil moisture on prediction of soil organic matter with hyperspectral reflectance using external parameter orthogonalization[J]. *Acta Pedologica Sinica*, 2017, 54(5): 1068-1078. (in Chinese with English abstract)
- [16] 陈红艳, 赵庚星, 李玉环, 等. 消除水分因素影响的野外原状土壤盐分高光谱建模估测[J]. *农业工程学报*, 2018, 34(12): 119-125.
CHEN Hongyan, ZHAO Gengxing, LI Yuhuan, et al. Modeling and estimation of field undisturbed soil salt based on hyperspectra under removal of moisture factor[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2018, 34(12): 119-125. (in Chinese with English abstract)
- [17] WANG C, LIU B, LIU L, et al. A review of deep learning used in the hyperspectral image analysis for agriculture [J]. *Artificial Intelligence Review*, 2021, (3): 5205-5253.
- [18] 陈庆, 汤斌, 龙邹荣, 等. 卷积神经网络的紫外-可见光谱水质分类方法[J]. *光谱学与光谱分析*, 2023, 43(3): 731-736.
CHEN Qing, TANG Bin, LONG Zuorong, et al. Water quality classification using convolution neural network based on UV-Vis Spectroscopy[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(3): 731-736. (in Chinese with English abstract)
- [19] EWUZIE U, BOLADE O P, EGBEDINA A O. Application of deep learning and machine learning methods in water quality modeling and prediction: A Review[J]. *Current Trends and Advances in Computer-Aided Intelligent Environmental Data Engineering*, 2022: 185-218.
- [20] SAHA D, SENTHILKUMAR T, SINGH C B, et al. Quantitative detection of metanil yellow adulteration in chickpea flour using line-scan near-infrared hyperspectral imaging with partial least square regression and one-dimensional convolutional neural network[J]. *Journal of Food Composition and Analysis*, 2023, 120: 105290.
- [21] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. In *Advances in Neural Information Processing Systems*, 2014, 27: 139-144.
- [22] 范黎. 基于生成对抗网络的图像数据增强技术研究及应用[M]. 杭州: 浙江大学, 2022.
LI Li. *Research and Application of Image Data Augmentation Technology Based on Generative Adversarial Networks*[M]. Hangzhou: Zhejiang University, 2022. (in Chinese with English abstract)
- [23] 杨森, 张新奡, 王振民, 等. 基于近红外光谱和深度学习数据增强的大米品种检测[J]. *农业工程学报*, 2023, 39(19): 250-257.
YANG Sen, ZHANG Xin'ao, WANG Zhenmin, et al. Rice variety detection based on near-infrared spectroscopy and deep learning data augmentation[J]. *Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE)*, 2023, 39(19): 250-257. (in Chinese with English abstract)
- [24] 何少芳, 沈陆明, 谢红霞. 生成式对抗网络的土壤有机质高光谱估测模型[J]. *光谱学与光谱分析*, 2021, 41(6): 1905-1911.
HE Shaofang, SHEN Luming, XIE Hongxia. Hyperspectral estimation model of soil organic matter content using generative adversarial networks[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(6): 1905-1911. (in Chinese with English abstract)
- [25] SANDFORT V, YAN K, PICKHARDT P J, et al. Data augmentation using generative adversarial networks (CycleGAN) to improve generalizability in CT segmentation tasks[J]. *Scientific Reports*, 2019, 9(1): 16884.
- [26] 李灵巧, 李彦晖, 殷琳琳, 等. 基于DCGAN的拉曼光谱样本扩充及应用研究[J]. *光谱学与光谱分析*, 2021, 41(2): 400-407.
LI Lingqiao, LI Yanhui, YIN Linlin, et al. Data augmentation of Raman spectral and its application research based on DCGAN[J]. *Spectroscopy and Spectral Analysis*, 2021, 41(2): 400-407. (in Chinese with English abstract)
- [27] RADFORD A, METZ L, CHINTALA S. Unsupervised representation learning with deep convolutional generative adversarial networks[EB/OL]. arXiv. 2015, <https://doi.org/>

- 10.48550/arXiv.1511.06434.
- [28] TAN H, HU Y, MA B, et al. An improved DCGAN model: Data augmentation of hyperspectral image for identification pesticide residues of Hami melon[J]. *Food Control*, 2024, 157: 110168.
- [29] 王文秀, 彭彦昆, 孙宏伟, 等. 基于可见/近红外光谱生鲜肉多品质参数检测装置研发[J]. *农业工程学报*, 2016, 32(23): 290-296.
WANG Wenxiu, PENG Yankun, SUN Hongwei, et al. Development of simultaneous detection device for multi-quality parameters of meat based on Vis/NIR spectroscopy[J]. *Transactions of the Chinese Society of Agricultural Engineering*, 2016, 32(23): 290-296. (in Chinese with English abstract)
- [30] MINASNY B, MCBRATNEY A B, BELLON-MAUREL V, et al. Removing the effect of soil moisture from NIR diffuse reflectance spectra for the prediction of soil organic carbon[J]. *Geoderma*, 2011, 167/168: 118-124.
- [31] HEUSEL M, RAMSAUER H, UNTERTHINER T, et al. Gans Trained By A Two Time-scale Update Rule Converge to A Local Nash Equilibrium[M]. *Advances in Neural Information Processing Systems*. Newyork: The MIT Press, 2017: 30.
- [32] BARRATT S, SHARMA R. A note on the inception score [EB/OL]. arXiv, 2018
<https://doi.org/10.48550/arXiv.1801.01973>.
- [33] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, NV, USA: IEEE, 2016: 2818-2826.
- [34] DOWSON D C, LANDAU B V. The Fréchet distance between multivariate normal distributions[J]. *Journal of Multivariate Analysis*, 1982, 12(3): 450-455.
- [35] BREIMAN L. Random forests[J]. *Machine Learning*, 2001, 45: 5-32.
- [36] HANG C, RUILI S, YIYUN C, et al. Estimating heavy metal concentrations in suburban soils with reflectance spectroscopy[J]. *Geoderma*, 2019, 336(15): 59-67.
- [37] TAN M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks [J]. *Machine Learning*, 2019, arXiv: 1905.11946.
- [38] 杨未静, 虎胆·吐马尔白, 米力夏提·米那多拉. 膜下滴灌棉田盐分空间分布特征分析[J]. 节水灌溉, 2020 (9): 58-63.
YANG Weijing, HUDAN . Tumarerba', MILLISHATI. Menadora. Spatial Distribution Characteristics of Salt in Drip Irrigation Cotton Field Under Mulch[J]. *Water Saving Irrigation*, 2020(9): 58-63. (in Chinese with English abstract)
- [39] 唐茂松, 张楠, 李国辉, 等. 基于机器学习算法的棉田土壤钾、钠离子量预测[J]. *灌溉排水学报*, 2023, 42(9): 32-39.
TANG Maosong, ZHANG Nan, LI Guohui, et al. Predicting soil K⁺and Na⁺contents in cotton field using machine learning algorithm[J]. *Journal of Irrigation and Drainage*, 2023, 42(9): 32-39. (in Chinese with English abstract)
- [40] 刘玉国, 杨海昌, 王开勇, 等. 新疆浅层暗管排水降低土壤盐分提高棉花产量[J]. *农业工程学报*, 2014, 30(16): 84-90.
LIU Yuguo, YANG Haichang, WANG Kaiyong, et al. Shallow subsurface pipe drainage in Xinjiang lowers soil salinity and improves cotton seed yield[J]. *Transactions of the Chinese Society of Agricultural Engineering(Technology of the CSAE)*, 2014, 30(16): 84-90. (in Chinese with English abstract)
- [41] 胡明芳, 田长彦, 赵振勇, 等. 新疆盐碱地成因及改良措施研究进展[J]. *西北农林科技大学学报(自然科学版)*, 2012, 40(10): 111-117.
HU Mingfang, TIAN Changyan, ZHAO Zhenyong, et al. Salinization causes and research progress of technologies improving saline-alkali soil in Xinjiang[J]. *Journal of Northwest A & F University(Natural Science Edition)*, 2012, 40(10): 111-117. (in Chinese with English abstract)
- [42] DURGADEVIK S M. Generative Adversarial Network (GAN): A general review on different variants of GAN and applications[C]. Coimbatore, India: 2021 6th International Conference on Communication and Electronics Systems (ICCES), 2021: 1-8.
- [43] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[J]. *International Journal of Computer Vision*, 2020, 128(2): 336-359.
- [44] 陈睿华, 孙媛, 尚天浩, 等. 基于光谱变换的宁夏银北地区可溶性阴离子反演[J]. *中国土壤与肥料*, 2022, (8): 94-103.
CHEN Ruihua, SUN Yuan, SHANG Tianhao, et al. Retrieval of soluble anions in northern Yinchuan area of Ningxia region based on spectral transformation[J]. *Soil and Fertilizer Sciences in China*, 2022, (8): 94-103. (in Chinese with English abstract)
- [45] 马利芳, 熊黑钢, 张芳. 基于野外 VIS-NIR 光谱的土壤盐分主要离子预测 [J]. *土壤学报*, 2020, 52 (1): 188-194.
MA Lifang, XIONG Heigang, ZHANG Fang. Prediction of major ions in soil salinity based on field VIS-NIR spectroscopy[J]. *Soils*, 2020, 52(1): 188-194. (in Chinese with English abstract)

Inversing soil salinity in cotton fields using spectroscopy sample augmentation and moisture correction

LI Jiayi¹, ZHANG Yiteng¹, ZHOU Baochuang¹, WENG Haiyong¹, ZHOU Beibei², YE Dapeng¹, QU Fangfang^{1*}

(1. School of Mechanical and Electrical Engineering, Fujian A & F University, Fuzhou 350002, China; 2. School of Water Resources and Hydropower, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Rapidly inverting soil salinity is crucial to the soil water and salt migration for the prevention of the secondary salinization. However, the accuracy and efficiency of soil salinity inversion models are hindered to the coupling relationship between water and salt in soil, particularly for time-consuming and labor-intensive soil collection. This study aims to reduce the interference of soil moisture for obtaining better sample diversity and further improving the robustness of soil salinity inversion models by using spectral technology. A total of 113 normal and 115 saline soil samples were collected in the Xinjiang cotton fields. These samples were further subjected to different levels of wetting treatment, and subsequently 467 soil samples with varying salt and moisture contents were obtained. Soil salt content was calibrated using the conductivity of soil leaching solution. Spectral data of samples was captured using an ASD ground object spectrometer (400-1000 nm) and a near-infrared spectrometer (960-1693 nm). The soil moisture was also corrected using the external parameter orthogonalization (EPO). Additionally, deep convolutional generative adversarial networks (DCGAN) with different transposed convolution stride strategies were designed to evaluate the sample set using Fréchet Inception Distance (FID) scores. Machine learning models were employed to invert the soil salinity, including partial least squares regression (PLSR), random forest (RF), and one-dimensional convolutional neural network (1D-CNN) models using VGG (VNet), EfficientNet (ENet), and ResNet (RNet) architectures. The results demonstrated that the EPO can effectively reduce the interference of moisture on the salinity, indicating the better prediction performance of different models. RNet outperformed PLSR, RF, VNet, ENet, RNet, and exhibited the best performance to predict the soil salinity in cotton fields. The lightweight residual neural network without attention mechanism was more suitable for one-dimensional hyperspectral data. There was an increase in the convolution stride and kernel length of the deep convolutional adversarial generative network. The better samples were obtained for the hyperspectral data with long sequences. The superior FID scores were achieved in the generated augmented sample set using Generator B (designed with the larger convolution stride and kernel size), compared with the rest. Specifically, the FID scores were reduced by 7.9% and 13.4%, respectively, compared with GA and GC. The weight distribution of attention was optimized after expanding the training set by DCGAN. The stability and accuracy of the model were further enhanced to predict the soil salinity under certain constraints on training samples. The EPO-DCGAN(GB)-RNet (called EPO-DCGAN-RNet) model was achieved in the superior RMSEP and R₂ values of 136.472 μS/cm and 0.910, respectively, on the validation set, compared with the EPO-SG-RNet (using SG filtering denoising) and EPO-RNet (without sample augmentation). Furthermore, 1D-CNN with Grad CAM was employed to identify the characteristic bands of soil conductivity in the soil leaching solution of cotton field. In summary, an accurate inversion model EPO-DCGAN-RNet was constructed for inverting soil salinity in the cotton fields using spectral technology. Water correction and sample augmentation were incorporated for the soil salt composition. The improved model has the promising potential to the salt-tolerant cotton varieties and irrigation strategies using slightly salty water in cotton fields.

Keywords: soils; salinity; spectroscopy; moisture correction; sample augmentation; external parameter orthogonalization; deep convolutional adversarial networks