doi:10.6041/j.issn.1000-1298.2023.06.037

基于 EnKF 和 PF 的沙壕渠灌域土壤含盐量监测模型研究

张智韬[1,2]　陈　策[1,2]　贾江栋[1,2]　殷皓原[1,2]　姚一飞[1,2]　黄小鱼[1,2]

(1. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100;
2. 西北农林科技大学旱区农业水土工程教育部重点实验室, 陕西杨凌 712100)

摘要: 为探究不同数据同化算法在时空尺度上监测土壤含盐量的可行性,以内蒙古河套灌区沙壕渠灌域为研究区域,采用高分一号卫星遥感图像作为数据源,通过 EnKF 算法和 PF 算法的同化观测算子和模型算子得到时空范围中的土壤含盐量变化情况。其中观测算子分为两步,首先通过 PLS-VIP 准则来筛选光谱指数作为自变量,再使用 ELM 模型建立基于不同时间不同深度的遥感监测土壤含盐量模型;模型算子为基于 Hydrus-1D 模型的数学模拟监测土壤含盐量模型。结果表明,基于 ELM 模型的土壤含盐量模型中,深度 0~20 cm、20~40 cm 和 40~60 cm 的平均 IOA 均在 0.74 以上,平均 ME 在 0.14% 以下,表明反演模型具有良好的精度;基于 Hydrus-1D 的数学模拟监测土壤含盐量模型中,3 个深度平均 IOA 在 0.79~0.89 之间,平均 ME 在 0.128%~0.137% 之间,能够较好地反映土壤盐分在时间序列中的运移情况;EnKF 算法 3 个深度 IOA 在 0.820 以上,ME 在 0.141%~0.157% 之间,NMB 在 0.141~0.252 之间,PF 算法 3 个深度 IOA 在 0.89 以上,ME 在 0.090%~0.142% 之间,NMB 在 0.075~0.097 之间,精度优于 EnKF 算法,能够很好地反映土壤含盐量在时间和空间上的分布情况。本文基于 EnKF 和 PF 算法进行 Hydrus-1D 模型和 ELM 模型的同化方案研究,提高了土壤含盐量的监测精度,可为后续在长时间大范围的时空尺度上监测土壤含盐量提供依据,也可为精准农业防治土壤盐渍化的研究提供参考。

关键词: 土壤含盐量; 数据同化; 集合卡尔曼滤波; 粒子滤波; 极限学习机; Hydrus-1D

中图分类号: S127; S156.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2023)06-0361-12　　**OSID**:

Soil Salinity Monitoring Model of Shahaoqu Irrigation Area Based on EnKF and PF Algorithm

ZHANG Zhitao[1,2]　CHEN Ce[1,2]　JIA Jiangdong[1,2]　YIN Haoyuan[1,2]　YAO Yifei[1,2]　HUANG Xiaoyu[1,2]

(1. *College of Water Resources and Architectural Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Soil and Water Engineering in Arid and Semiarid Areas*, *Ministry of Education*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: In order to explore the feasibility of different data assimilation algorithms in monitoring soil salinity on the spatio-temporal scale, the Shahaoqu Canal Irrigation Area in Hetao Irrigation District of Inner Mongolia was taken as the research area, and the Gaofen-1 satellite remote sensing image was used as the data source. The assimilation observation operator and model operator of EnKF algorithm and PF algorithm were used to obtain the changes of soil salinity in the spatio-temporal range. The observation operator was divided into two steps, firstly, the PLS-VIP criterion was used to filter the spectral index as the independent variable, and then the ELM model was used to establish the remote sensing monitoring soil salinity model based on different depths at different times; the model operator was a mathematical simulation monitoring soil salinity model based on the Hydrus-1D model. The results showed that in the ELM-based soil salinity model, the average IOA at the depths of 0~20 cm, 20~40 cm and 40~60 cm were above 0.74, and the average ME was below 0.14%, indicating that the inversion model had good accuracy; in the Hydrus-1D-based mathematical simulation monitoring soil salinity model, the average IOA at the three depths was between 0.79 and 0.89 and the average ME was between 0.128% and 0.137%, which could better reflect the transport of soil salts in the time series; the EnKF algorithm had IOA above 0.820 for three depths, ME between 0.141% and 0.157% and NMB between 0.141 and

收稿日期: 2022-10-27　修回日期: 2022-12-05

基金项目: 国家重点研发计划项目(2017YFC0403302)和国家自然科学基金项目(51979232、51979234)

作者简介: 张智韬(1976—),男,教授,博士生导师,主要从事遥感技术在节水灌溉及水资源中的应用研究,E-mail: zhitaozhang@126.com

0.252, and the PF algorithm had IOA above 0.89 for three depths and ME ranged from 0.090% to 0.142% and NMB ranged from 0.075 to 0.097, with better accuracy than the EnKF algorithm, which can well reflect the distribution of soil salinity in time and space. The assimilation scheme of Hydrus-1D model and ELM model based on EnKF and PF algorithms improved the accuracy of monitoring soil salinity, which can provide a basis for subsequent monitoring of soil salinity on a long time and large spatial and temporal scale, and can also provide a reference for the research of precision agriculture to control soil salinity.

Key words: soil salinity; data assimilation; ensemble Kalman filtering; particle filtering; extreme learning machine; Hydrus-1D

0 引言

土壤盐渍化已成为世界性问题,受到广泛关注。其严重影响农作物的生产,威胁人类的生存[1-2]。因此,及时大范围地准确监测土壤含盐量从而间接控制土壤盐渍化的方法成为当下的热点之一。

监测土壤含盐量的方法主要有地面观测、数学模型模拟和卫星遥感反演,但在实际运用中,这3种方法各有不足。地面观测方法是建立在实地单点采样的基础上,其虽精度高,但成本大,且难以在大范围的时空尺度上获取数据[3]。使用数学模型,例如 Hydrus-1D 模型模拟长时间大范围的土壤含盐量,模型中的误差会随着时间的增加而不断累积,导致精度降低,需花费大量的时间成本和人力成本,才可能获得具有良好精度的结果[4]。而卫星遥感虽可以通过使用大尺度遥感影像提取相关光谱信息,有效减少地面观测和数学模型模拟的试验时间,但其受限于云、雾等自然条件和卫星传感器的类型,很难获取短时间间隔的遥感图像,不利于长时间高精度的监测研究[5]。因此,本研究为达到在时间和空间尺度下准确监测区域尺度土壤含盐量的目的,使用数据同化的手段来耦合数学模型模拟和卫星遥感反演两种方法优点,并辅以地面观测数据作为验证。

目前,在不同领域,已有学者针对数据同化进行大量研究。例如在土壤湿度方面,CROW 等[6]将遥感数据同化到水文模型中,提高了模型模拟精度;HAN 等[7]发现数据同化有助于提升 SWAT 模型在水文模拟方面的潜力;陈鹤等[3]进一步将同化算法集成到水文模型中,有效减少了水文模型的误差;何涯舟等[8]利用土壤湿度同化提升了径流模拟精度。在作物产量方面,PAUWELS 等[9]同化植被和土壤湿度状态的观测值,改善了 WOFOST 模型效果;CURNEL 等[10]使用基于重新校准的同化方法在全球范围内显著提高了谷物产量的估计精度;程志强等[11]使用集合卡尔曼滤波同化 WOFOST 模型和无人机遥感数据,大幅提高了生物量估算精度;刘正春等[12]采用 4DVAR 和 EnKF 两种算法有效提高了冬小麦区域估产精度;王鹏新等[13]采用粒子滤波算法同化 LAI 和 VTCI 两种参数,提高了夏季玉米产量估计精度。

目前来看,与农业相关的数据同化研究多集中在 EnKF(Ensemble Kalman filtering)算法方面[3,6-12],另一种非线性算法——粒子滤波(Particle filter,PF)研究较少[13-14],且很少有学者研究数据同化监测土壤含盐量领域[5,15]。因此,为了更好地监测土壤含盐量,本文引入与 EnKF 不同的误差处理方法 PF 进行对比[16-17],探讨不同数据同化方法对监测土壤含盐量精度的优化程度,从而确定最佳的土壤含盐量监测方案。

1 材料与方法

1.1 研究区概况

研究区域位于内蒙古自治区河套灌区沙壕渠灌域(40°52′~41°00′N,107°05′~107°10′E),位于河套灌区西北处。南窄北宽,多为平原地形,地势南高北低,海拔为 1 034~1 037 m。灌域所处区域气候为温带大陆性气候,冬季寒冷少雪,夏季炎热干旱,全年平均降水量为 140 mm,蒸发量却为 2 000 mm,当地灌溉用水多取于黄河。长年缺乏降水加上当地不合适的灌溉制度,导致灌域土壤盐渍化情况较为严重[18-19]。

1.2 数据来源

1.2.1 土壤样本数据

选取 142 个采样点进行土壤采样,具体位置见图 1。采样时间为 2018 年 4—9 月。采样方法为五点法,用手持 GPS 进行定位,用铝盒将样本带回实验室进行处理。采用干燥法测定土壤含水率。样本经过干燥后,进行研磨,配成土水质量比 1∶5 的溶液,静置后待其沉淀,使用电导率仪(DDS-307A 型,上海佑科仪器公司)测量溶液电导率($EC_{1:5}$)。运用经验公式[20]计算土壤含盐量(Soil salinity content,SSC,单位 g/(100g),后文使用% 代替)。含盐量计算公式为

$$SSC = 0.288\,2EC_{1:5} + 0.018\,3 \quad (1)$$

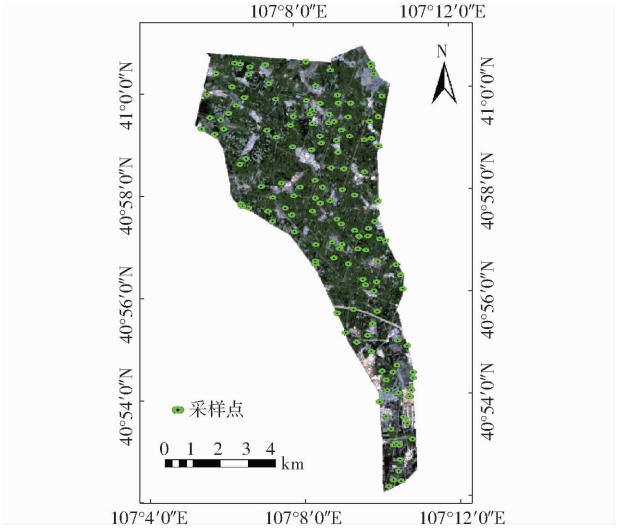

图 1　研究区概况及采样点分布

Fig. 1　Overview of study area and distribution of sampling points

1.2.2　高分一号卫星遥感数据

采用的高分一号卫星 WFV 数据从中国资源卫星应用中心(http://www.cresda.com/CN/)下载。遥感图像分辨率为 16 m×16 m,具有蓝、绿、红、近红外 4 个波段。依据图像少云,且拍摄时间尽量接近实地采样的原则,选取 6 幅图像,具体日期为:2018 年 4 月 14 日、2018 年 5 月 17 日、2018 年 6 月 27 日、2018 年 7 月 27 日、2018 年 8 月 8 日和 2018 年 9 月 21 日。运用 ENVI 5.3.1 软件,通过几何精校正、辐射定标、大气校正等步骤进行图像预处理,获取采样点反射率。

1.2.3　其他数据

所需的气象数据(包括降水量、蒸发量等)以及地下水位数据均由河套灌区沙壕渠试验站提供。

1.3　土壤含盐量遥感反演

共采用 6 个月数据,且每月共有 3 个深度,故一共有 18 组含盐量数据需要建模。以 4 月深度 0~20 cm 为例,将该组数据按照 SSC 从大到小进行排列,以 3 个数据为 1 个单元来将该组 SSC 划分为 47 个单元,且每个单元前 2 个数据作为建模集,后 1 个数据作为验证集,使得建模集与验证集比例为 2∶1。划分之后,选取较为常用的 14 种盐分光谱指数、14 种植被光谱指数和卫星自带的 4 个波段作为自变量,建模集的土壤含盐量数据作为因变量,使用基于偏最小二乘的变量投影重要性(Partial least squares-variable importance for the projection,PLS-VIP)准则进行自变量筛选。当 18 组 SSC 数据中的自变量都被筛选出来后,使用 ELM 模型进行建模,获取 SSC 反演值。

1.3.1　变量筛选

(1)光谱指数

选取表 1 中指数和波段作为备选自变量之一,共同构建遥感反演土壤含盐量模型。

(2)指数筛选方法

一共选取 32 个自变量。为确定不同变量的重要性,并解决变量之间共线性问题,以及减少模型计算时间,选取基于偏最小二乘的变量投影重要性准则进行自变量筛选[43]。PLS-VIP 准则原理为

$$VIP_j = \sqrt{p\dfrac{\sum_{h=1}^{m} R(Y,t_h)\,w_{hj}^2}{\sum_{h=1}^{m} R(Y,t_h)}} \quad (2)$$

式中　p——自变量个数

m——偏最小二乘法从原变量中提取的成分个数

t_h——第 h 个成分

$R(Y,t_h)$——成分 t_h 对因变量 Y 的解释能力,是二者相关系数的平方

w_{hj}——向量 $\boldsymbol{w}_h$ 的第 j 个分量,$\boldsymbol{w}_h$ 为矩阵 $\boldsymbol{X}_{h-1}^{\mathrm{T}}\boldsymbol{Y}_{h-1}\boldsymbol{Y}_{h-1}^{\mathrm{T}}\boldsymbol{X}_{h-1}$ 的特征向量

其中,当某个自变量的 PLS-VIP 值大于 1 时,表示此自变量对于解释因变量 Y 有着重要作用;小于 1 时,重要作用较小[44]。

1.3.2　遥感反演模型

使用极限学习机(Extreme learning machine,ELM)模型作为遥感反演模型。ELM 模型是由 HUANG 等[45]提出的一类性能优良的适用于广义单隐藏层前馈网络。传统神经网络训练模型会因为不适当的学习步长导致其需要花费大量计算资源进行迭代,最终才能获得较好的精度;但 ELM 模型可以通过一步计算得到网络输出的权值,大大减少了计算时间,并提高了网络泛化速度和学习效率[46-47]。

使用 Matlab R2020a 软件调整 ELM 模型参数。其中,通过敏感性分析选出最优隐藏神经元数量(Number of hidden neurons)需小于建模集的样本数;传递函数(Transfer function)选择 Hardlim 函数。

1.4　土壤含盐量数据同化反演

1.4.1　Hydrus-1D 模型

使用土壤水盐运移过程模型(Hydrus-1D)[48]作为数据同化中的模型算子,模拟土壤含盐量。该模型由美国农业部国家盐土实验室开发,可以求解变饱和水流的 Richards 方程和热、溶质输运的平流-弥散型方程。本文使用模型中的水分运移和溶质运移两个模块[13,49]。

模型所需的输入数据包括气象数据、地下水数

表 1 光谱指数与计算公式

Tab.1 Spectral indices and calculation formulae

指数类型	指数/波段	计算公式	文献序号
遥感数据	波段 1（Band1，b1）	$b_1 = B$	
	波段 2（Band2，b2）	$b_2 = G$	
	波段 3（Band3，b3）	$b_3 = R$	
	波段 4（Band4，b4）	$b_4 = NIR$	
盐分光谱指数	亮度指数（Brightness index，BI）	$BI = \sqrt{b_2^2 + b_4^2}$	[21]
	盐分指数（Salinity index，包括 SI－T、SI、SI1、SI2、SI3、S1、S2、S3、S5、S6）	$SI - T = 100(b_3 - b_4)$	[22]
		$SI = \sqrt{b_1 b_3}$	[21]
		$SI_1 = \sqrt{b_2 b_3}$	
		$SI_2 = \sqrt{b_2^2 + b_3^2 + b_4^2}$	[23]
		$SI_3 = \sqrt{b_2^2 + b_3^2}$	
		$S_1 = b_1 / b_3$	
		$S_2 = (b_1 - b_3)/(b_1 + b_3)$	
		$S_3 = b_2 b_3 / b_4$	[24]
		$S_5 = b_1 b_3 / b_2$	
		$S_6 = b_3 b_4 / b_2$	
	强度指数（Strength index，包括 Int1、Int2）	$Int_1 = (b_2 + b_3)/2$	
		$Int_2 = (b_2 + b_3 + b_4)/2$	[25]
	归一化盐分指数（Normalized salt index，NDSI）	$NDSI = (b_3 - b_4)/(b_3 + b_4)$	[21]
植被光谱指数	归一化植被指数（Normalized difference vegetation index，NDVI）	$NDVI = (b_4 - b_3)/(b_4 + b_3)$	[26]
	增强型植被指数（Enhanced vegetation index，包括 EVI、EVI2）	$EVI = \dfrac{2.5(b_4 - b_3)}{b_4 + 6b_3 - 7.5b_1 + 1}$	[27]
		$EVI_2 = \dfrac{2.5(b_4 - b_3)}{b_4 + 2.4b_3 + 1}$	[28－29]
	差值植被指数（Difference vegetation index，DVI）	$DVI = b_4 - b_3$	[30]
	修正土壤调节植被指数（Modified soil-adjusted vegetation index，MSAVI）	$MSAVI = \dfrac{2b_4 + 1 - \sqrt{(2b_4 + 1)^2 - 8(b_4 - b_3)}}{2}$	[31－32]
	大气阻抗植被指数（Atmospherically resistant vegetation index，ARVI）	$ARVI = \dfrac{b_4 - (2b_3 - b_1)}{b_4 + 2b_3 - b_1}$	[33]
	归一化水体指数（Normalized difference water index，NDWI）	$NDWI = (b_2 - b_4)/(b_2 + b_4)$	[34]
	简单比率（Simple ratio，SR）	$SR = b_4 / b_3$	[35]
	绿色叶绿素植被指数（Green chlorophyll vegetation index，GCVI）	$GCVI = (b_4 - b_2) - 1$	[36－37]
	优化后土壤调整植被指数（Optimized soil adjusted vegetation index，OSAVI）	$OSAVI = (b_4 - b_3)/(b_4 + b_3 + 0.16)$	[38]
	绿色简单比率（Green simple ratio，GSR）	$GSR = b_4 / b_2$	[39]
	绿色归一化植被指数（Green NDVI，GNDVI）	$GNDVI = (b_4 - b_2)/(b_4 + b_2)$	[40]
	重整化差异植被指数（Renormalized difference vegetation index，RDVI）	$RDVI = (b_4 - b_3)/\sqrt{b_4 + b_3}$	[41]
	转化植被指数 Transformed（Vegetative index，TVI）	$TVI = \sqrt{(b_4 - b_3)/(b_4 + b_3) + 0.5}$	[42]

注：$b_1 \sim b_4$ 分别为遥感数据波段 1～4，数值分别为 0.45～0.52 μm、0.52～0.59 μm、0.63～0.69 μm、0.77～0.89 μm。

据、相关参数和初始条件等。气象数据和地下水埋深数据由沙壕渠试验站提供。相关参数中包括溶质运移参数和土壤水力特性曲线参数等，使用参数反演优化法来确定。通过设定样本土壤实测参数作为初始值，分析这些参数对模型模拟结果的影响，确定 Hydrus－1D 模型敏感参数，与模型自带的标准参数结合，提高模型模拟结果与实测土壤含盐量之间的吻合程度，确定适用于研究区域不同地点的模型参数。

1.4.2 集合卡尔曼滤波同化算法

EnKF 属于顺序同化算法，同样基于 Monte Carlo 算法。EnKF 分为预测和更新两个模块[50－51]。预测模块为

$$\boldsymbol{X}_{i,k+1}^{f} = \boldsymbol{M}_{k,k+1}(\boldsymbol{X}_{i,k}^{a}) + \boldsymbol{w}_{i,k} \tag{3}$$

式中 $\boldsymbol{X}_{i,k+1}^{f}$——$k+1$ 时刻第 i 个集合的状态预测值

$\boldsymbol{M}_{k,k+1}$——k 时刻到 $k+1$ 时刻的状态变化关系

$\boldsymbol{X}_{i,k}^{a}$——k 时刻第 i 个集合的状态分析值

$\boldsymbol{w}_{i,k}$——模型误差

当 $k+1$ 时刻有观测值时，需要对每个集合的状

态进行更新，计算增益矩阵，更新同化参量计算误差，计算公式分别为

$$\boldsymbol{K}_{k+1}=\boldsymbol{P}^{f}_{k+1}\boldsymbol{H}^{\mathrm{T}}\left(\boldsymbol{H}\boldsymbol{P}^{f}_{k+1}\boldsymbol{H}^{\mathrm{T}}+\boldsymbol{R}_{k}\right)^{-1} \tag{4}$$

$$\boldsymbol{P}^{a}_{k+1}=\frac{1}{N-1}\sum_{i=1}^{N}\left(\boldsymbol{X}^{a}_{i,k+1}-\overline{\boldsymbol{X}}^{a}_{i,k+1}\right)\left(\boldsymbol{X}^{a}_{i,k+1}-\overline{\boldsymbol{X}}^{a}_{i,k+1}\right) \tag{5}$$

式中　$\boldsymbol{K}_{k+1}$——增益矩阵

$\boldsymbol{P}^{f}_{k+1}$——状态预测值的误差方差矩阵

$\boldsymbol{H}$——单位矩阵

$\boldsymbol{R}_{k}$——观测误差扰动的误差协方差矩阵

$\boldsymbol{P}^{a}_{k+1}$——最优估计值的误差方差矩阵

N——集合数

$\boldsymbol{X}^{a}_{i,k+1}$——状态分析值

$\overline{\boldsymbol{X}}^{a}_{i,k+1}$——所有集合的均值

1.4.3　粒子滤波同化算法

PF 是一种基于蒙特卡洛(Monte Carlo)模拟的贝叶斯(Bayes)滤波算法[52-53]。PF 步骤为：

(1)重要性采样。给定任意分布的随机噪声，扰动产生模型初始状态变量，获得 $k-1$ 时刻的模型状态 x^{i}_{k-1}，即

$$x^{i}_{k-1}=x_{k-1}+\eta^{i}_{k-1} \tag{6}$$

式中　η^{i}_{k-1}——第 i 个粒子 $k-1$ 时刻模型过程噪声

采用均匀采样的方式分配粒子权重 w^{i}_{k-1}，最后进行模型预测。公式为

$$w^{i}_{k-1}=1/T \tag{7}$$

式中　T——初始模型状态 x^{i}_{k-1} 的个数

(2)更新权值。PF 依靠模型随时间演进得到的观测预测和实际观测，计算每个粒子的重要性权重，并以此估算和更新状态粒子，公式为

$$w^{i*}_{k}=\frac{w^{i*}_{k-1}p(y_{k}\mid x^{i}_{k})p(x^{i}_{k}\mid x^{i}_{k-1})}{q(x^{i}_{k}\mid x^{i}_{k-1},y_{k})} \tag{8}$$

式中　w^{i*}_{k}——粒子重要性权重

$q(x^{i}_{k}\mid x^{i}_{k-1},y_{k})$——重要性采样函数

$p(y_{k}\mid x^{i}_{k})$——似然性，表示 k 状态下与观测值的相似程度

$p(x^{i}_{k}\mid x^{i}_{k-1})$——$k$ 时刻的先验概率分布函数

更新后计算权值归一化使权值总和为 1，公式为

$$\overline{w}^{i*}_{k}=w^{i*}_{k}\Big/\sum_{i=1}^{N_{k}}w^{i}_{k} \tag{9}$$

式中　N_{k}——k 时刻的粒子总数

(3)重采样阶段。此阶段为解决粒子退化问题，提高估计性能。采用多项式重采样，其基本解决了粒子滤波的粒子退化问题。

1.5　试验方案

基于土壤含盐量的数据同化方案的 3 部分包括观测算子、模型算子和同化算法。其中，观测算子为多时相的 ELM 土壤含盐量反演模型，模型算子为 Hydrus-1D 模型，用于模拟土壤盐分运移，同化算法则为 EnKF 算法和 PF 算法，作为耦合观测算子和模型算子的媒介，获取长时间序列的区域尺度土壤含盐量的时空特性变化信息。技术路线见图 2。采用 ELM 模型和 Hydrus-1D 模型分别得到 k 时刻的 3 个深度土壤含盐量后，使用 EnKF 同化算法和 PF 同化算法进行同化，得到 k 时刻土壤含盐量同化值。当该时刻存在实测土壤含盐量时，则将 3 个深度土壤含盐量同化值作为 Hydrus-1D 模型运行的初始条件，进行模拟，得到 $k+1$ 时刻的模型模拟土壤含盐量。重复上面步骤，继续与 ELM 模型反演土壤含盐量进行同化。若同化结束后没有下一时刻实测土壤含盐量，则同化结束，进行评价。

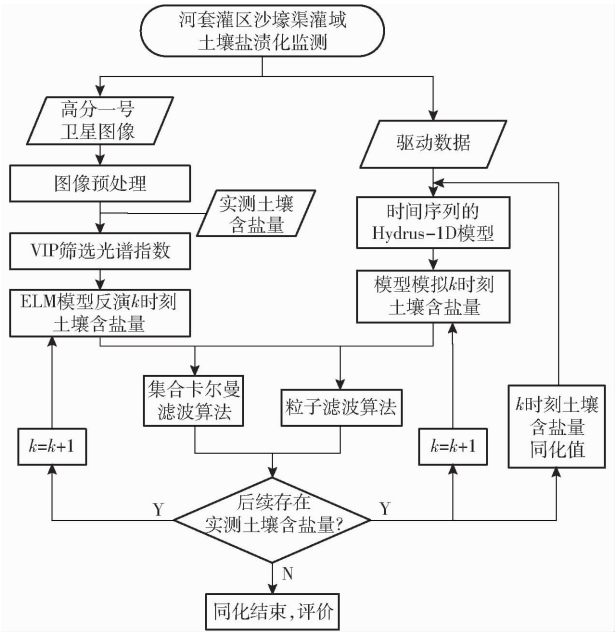

图 2　技术路线图

Fig. 2　Technology roadmap

1.6　评价指标

本文采用一致性系数(Index of agreement, IOA)和平均误差(Mean error, ME)对模型和数据同化过程中的误差进行评价。其中，IOA 越接近 1，精度越高；ME 越接近于 0，误差越小。为了更好地衡量不同方法之间的差异，增加归一化平均偏差(Normalized mean bias, NMB)进行评价，NMB 越接近于 0，误差越小。

2　结果与分析

2.1　遥感反演结果与分析

2.1.1　变量筛选

本研究采用基于 VIP 准则的筛选方法，用于确定包括 4 个遥感波段、14 种盐分光谱指数和 14 种

植被光谱指数在内的变量对于不同深度实测含盐量的重要性。本研究将 VIP 值大于 1 的变量视为对土壤实测含盐量重要的变量,并作为遥感反演模型的自变量,结果如图 3 所示。

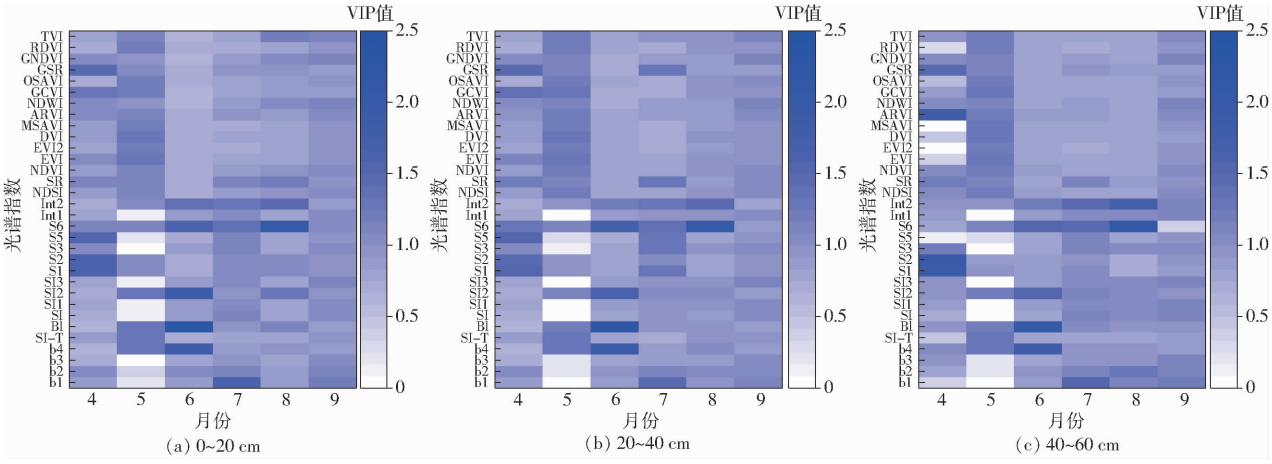

图 3 PLS - VIP 计算结果

Fig. 3 PLS - VIP calculation results

由图 3 可知,在研究时段内每月选取 3 个深度进行 18 次筛选。其中,由于土壤取样深度以及生育期内自然环境和人工作业等因素共同作用下,18 个模型的自变量并不一致。试验选取的 32 个变量在不同的筛选试验后均有所出现,证明试验选取的变量在不同时间和不同深度中对土壤含盐量都有显著重要性。从各个变量来看,变量 S6 通过筛选次数最多,为 15 次;变量 b3、SI - T、EVI2、DVI、MSAVI、RDVI 6 个变量通过筛选次数最低,仅有 3 次。这表示变量 S6 在 4—9 月的 0 ~ 60 cm 3 个深度中,对反演土壤含盐量起着极其重要且普遍性的作用;而变量 b3 等 6 个变量只在特定时间特定深度对含盐量有重要作用,但不具有普遍性。

从各个月份来看,5 月所筛选出的变量个数最多,按 0 ~ 20 cm、20 ~ 40 cm、40 ~ 60 cm 分别为 21、20、20 个;6 月最少,分别为 6、5、5 个。原因在于,5 月处于灌域农作物生育期初期,在复杂的环境因子作用下,需要更多的光谱变量用于构建反演模型,从而更为准确地反演土壤含盐量。而 6 月已处于植被生长旺盛期,环境因子较为简单。5 月和 6 月的光谱指数的 VIP 值亦能反映其中原因。在 6 月 3 个深度中,光谱指数 BI 的 VIP 值均大于 2,可以很好地反映土壤含盐量的空间分布;而在 5 月 3 个深度中通过筛选的光谱指数,最大 VIP 值为 1.280 ~ 1.332,远小于 6 月,因此需要引入较多的光谱变量用于监测土壤含盐量,提高反演精度。其余月份中,7、8 月因植被生长茂盛且农作物种类增多,引入光谱变量个数较少,但多于 6 月。4 月与 9 月的光谱变量数目差别不大,原因在于这 2 个月处于裸土期和农作物生长末期,环境因子基本相似,但较植被生长旺盛期复杂,因此略多于 6—8 月。

2.1.2 遥感反演

选取通过 VIP 准则筛选的光谱变量作为自变量,4—9 月 0 ~ 60 cm 3 个深度实测土壤含盐量作为因变量,构建基于 ELM 模型的不同月份不同深度的土壤含盐量反演模型,模型建模结果如图 4 所示。

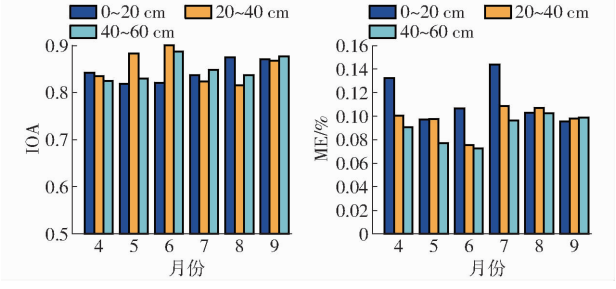

图 4 ELM 模型建模集评价结果

Fig. 4 ELM modeling set evaluation results

从图 4 可知,18 个反演模型中,建模集 IOA(IOA_C)均大于 0.8;建模集 ME(ME_C)均小于 0.15%。这表明 ELM 模型在反演土壤含盐量中具有较好的监测精度。其中,IOA_C 精度最高的前 3 个模型分别是 6 月深度 20 ~ 40 cm、6 月深度 40 ~ 60 cm 和 5 月深度 20 ~ 40 cm,分别为 0.901、0.887 和 0.883;ME_C 前 3 个模型分别是 6 月深度 40 ~ 60 cm、6 月深度 20 ~ 40 cm 和 5 月深度 40 ~ 60 cm,分别为 0.073%、0.076% 和 0.077%。同理,IOA_C 精度最低的后 3 个模型分别为 8 月深度 20 ~ 40 cm、5 月深度 0 ~ 20 cm 和深度 0 ~ 20 cm,为 0.815、0.819 和 0.820;ME_C 后 3 个模型分别为 7 月深度 0 ~ 20 cm、4 月深度 0 ~ 20 cm 和 7 月深度 20 ~ 40 cm,为 0.144%、0.133% 和 0.109%。

从深度方面看,深度 0 ~ 20 cm 中,平均 IOA_C 为 0.844,深度 20 ~ 40 cm 为 0.854,深度 40 ~ 60 cm 为 0.851。3 个深度的平均 ME_C 分别为 0.113%、

0.098% 和 0.090%。可以看出，模型精度随着深度的递增而递增。从时间方面看，4—9 月平均 IOA_C 分别为 0.834、0.844、0.869、0.836、0.842 和 0.872，平均 ME_C 分别为 0.108%、0.091%、0.085%、0.116%、0.104% 和 0.097%。衡量以上信息，ELM 模型中 6 月建模精度最高，7 月最低。原因在于 6 月研究区经济作物品种单一，7 月相对来说作物品种进一步增加。且 7 月深度 0～20 cm 的 ME_C 最高则是因为此时处于农作物茂盛生长期，遥感图像所获取的信息多是植被表层反射波段，表层土壤信息被遮盖，模型因此无法较为精确反映地面实测信息。

ELM 模型验证集精度见表 2。

表 2　ELM 模型验证集评价结果

Tab.2　ELM model validation set evaluation results

土壤深度/cm	月份	IOA	ME/%
0～20	4	0.811	0.164
	5	0.877	0.123
	6	0.830	0.161
	7	0.851	0.166
	8	0.831	0.114
	9	0.840	0.118
20～40	4	0.848	0.097
	5	0.763	0.124
	6	0.859	0.166
	7	0.837	0.120
	8	0.854	0.133
	9	0.841	0.109
40～60	4	0.839	0.087
	5	0.851	0.085
	6	0.306	0.095
	7	0.766	0.089
	8	0.836	0.104
	9	0.848	0.100

从表 2 可以得出，综合两个评价指标，ELM 模型均能较好地验证模型精度。验证集 IOA（IOA_V）精度最高的前 3 个模型分别为 5 月深度 0～20 cm、6 月深度 20～40 cm 和 8 月深度 20～40 cm，分别为 0.877、0.859 和 0.854；精度最低 3 个为 6 月深度 40～60 cm、5 月深度 20～40 cm 和 7 月深度 40～60 cm，为 0.306、0.763 和 0.766。验证集 ME（ME_V）精度最高为 5 月深度 40～60 cm、4 月深度 40～60 cm 和 7 月深度 40～60 cm，分别为 0.085%、0.087% 和 0.089%；精度最低 3 个为 7 月深度 0～20 cm、6 月深度 20～40 cm 和 4 月深度 0～20 cm，分别为 0.166%、0.166% 和 0.164%。

各深度平均 IOA_V 分别为 0.840、0.834 和 0.741，ME_V 分别为 0.141%、0.125% 和 0.093%。可以看出，在前两层深度中两种评价指标差别不大，但在 40～60 cm 处 IOA_V 有较为明显的下降，主要原因在于 6 月深度 40～60 cm 处的低精度。然而与其他模型相比，该深度的 ME_V 无明显的精度降低趋势，推测原因在于研究区所种植的农作物根系所处深度主要位于 20～40 cm，遥感提取的地表反射率较难反映深层土壤含盐量。

4—9 月平均 IOA_V 分别为 0.833、0.830、0.665、0.818、0.840 和 0.843，平均 ME_V 分别为 0.116%、0.111%、0.141%、0.125%、0.117% 和 0.109%。与建模集相比，精度略有下降，但依然能较好反映实测土壤含盐量。

综上所述，在 3 个深度中，ELM 模型能够较好地反演灌区多时相土壤含盐量。其中，6 月深度 20～40 cm 模型精度最高，原因在于其在建模集中的两个评价指标均排在前 3，并且其 IOA_V 同样排在前 3；7 月深度 0～20 cm 模型精度最高，原因在于其 ME_C 和 ME_V 均处于后 1/3。

2.2　模型模拟结果

基于 Hydrus－1D 模型进行 4—9 月不同深度土壤含盐量模拟，使用 4 月 14 日地面实测值作为模型初始模拟值，确定剩余遥感反演时间点各天的模拟土壤含盐量，以计算评价指标 IOA 和 ME，结果如表 3 所示。从表 3 可以看出，就整体精度而言，模型模拟精度较好，可以较好反映长时间上的土壤含盐量变化情况。

表 3　Hydrus－1D 模型模拟精度评价

Tab.3　Hydrus－1D model simulation accuracy evaluation

土壤深度/cm	月份	IOA	ME/%
0～20	5	0.915	0.133
	6	0.868	0.186
	7	0.871	0.131
	8	0.868	0.135
	9	0.931	0.099
20～40	5	0.931	0.116
	6	0.882	0.128
	7	0.886	0.134
	8	0.835	0.143
	9	0.846	0.135
40～60	5	0.909	0.103
	6	0.845	0.104
	7	0.656	0.200
	8	0.768	0.102
	9	0.786	0.133

从不同土壤深度来看，3 个深度各平均 IOA 分别为 0.891、0.876 和 0.793，各平均 ME 分别为 0.137%、0.131% 和 0.128%。表明 Hydrus－1D 模型在深度 0～20 cm 中模拟精度最高，20～40 cm 次之，40～60 cm 最差。从时间角度看，5—9 月各月平均 IOA 分别为 0.918、0.865、0.805、0.824 和 0.855，

平均 ME 分别为 0.117%、0.139%、0.155%、0.127% 和 0.122%。综合评价指标,Hydrus－1D 模型模拟精度随着时间增加,表现为先减后增,但 9 月的 Hydrus－1D 模型模拟精度均较 5 月有所下降。其主要原因在于模型运行过程会导致误差不断积累,从而致使模型模拟精度下降。

IOA 在深度 0～20 cm 中随着时间的递增先下降后上升,在深度 20～40 cm 和 40～60 cm 中总体均随时间递增呈下降趋势。ME 在 0～20 cm 深度中,6 月的模型模拟精度有下降,但在后续月份中精度有所提升;深度 20～40 cm 中,模型模拟精度在随时间的推移而下降;深度 40～60 cm 中,模型随时间递增精度先降后升。

2.3 同化算法结果

基于 2018 年 4—9 月的实际土壤样本测定的土壤含盐量,开展不同时空的区域尺度土壤含盐量数据同化研究。分别通过引入 EnKF 和 PF 两种同化算法,将观测算子(即 ELM 模型反演结果)和模拟算子(即 Hydrus－1D 模型模拟结果)进行耦合,建立数据同化方案,获取基于不同数据同化算法的长时间区域土壤含盐量的时空变化情况。使用 IOA、ME 和 NMB 对同化方案分别进行精度评价,结果如图 5 所示。

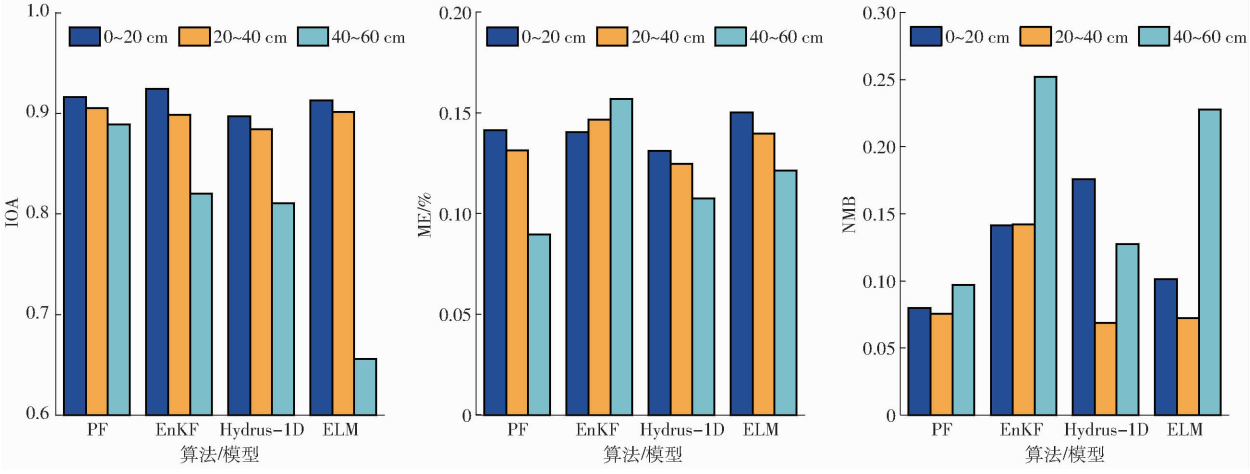

图 5 综合评价结果

Fig. 5 Comprehensive evaluation results

从图 5 可以看出,4 种方法都能较好地监测时间尺度下的土壤含盐量,IOA 大多在 0.8～0.9 范围浮动;ME 基本小于 0.15%;NMB 除 EnKF 算法和 ELM 模型的 40～60 cm 外,均小于 0.2。综合各个评价指标,PF 算法效果最优,Hydrus－1D 模型模拟精度次之,EnKF 算法精度第 3,ELM 模型反演精度表现最差。

从同化精度的角度分析,就 IOA 而言,4 种方法的精度随着深度的递增而降低。其中,深度 0～20 cm 中,EnKF 算法精度最高,PF 算法较其降低 0.89%,Hydrus－1D 模型和 ELM 模型分别降低 2.96% 和 1.26%。深度 20～40 cm 中,PF 算法精度最高,EnKF 算法、Hydrus－1D 模型和 ELM 模型分别降低 0.75%、2.36% 和 0.46%。深度 40～60 cm 中,与深度 20～40 cm 类似,PF 算法精度最高,其余方法精度均有所下降,分别为 7.78%、8.82% 和 26.19%。从基于两种同化算法的模型精度均高于数学模型模拟和遥感模型反演可以看出,同化算法在耦合二者并降低误差方面具有很大优势。

从同化误差的角度分析,就 ME 而言,PF 算法、Hydrus－1D 模型和 ELM 模型的精度随着深度的递增而上升,但 EnKF 算法精度表现与在 IOA 中类似,精度随着深度的递增而降低。其中,深度 0～20 cm 和 20～40 cm 中,Hydrus－1D 模型模拟精度最高,40～60 cm 中,PF 算法精度最高。ELM 模型反演精度在表层深度最低,其余深度 EnKF 算法精度最低。NMB 中,各种方法在深度 20～40 cm 精度最高,深度 40～60 cm 精度最低。

在深度 0～20 cm,相较于 EnKF 同化算法,PF 同化算法的 IOA 和 ME 分别下降 0.9% 和 0.6%,差距很小,可以忽略不计;NMB 中,PF 较 EnKF 提高 43.8%。在深度 20～40 cm,IOA、ME 和 NMB 中,PF 同化算法较 EnKF 同化算法分别提高 0.8%、10.3% 和 46.8%。在深度 40～60 cm,3 个评价指标(IOA、ME、NMB)中,PF 同化算法较 EnKF 同化算法分别提高 8.4%、42.9% 和 61.5%。因此,在 3 个深度上,与 EnKF 算法相比,PF 算法对于提高土壤含盐量的同化精度有着更为显著的优势。

以 2018 年 7 月为例,使用 PF 算法数据同化方案得出的不同深度土壤含盐量如图 6 所示。

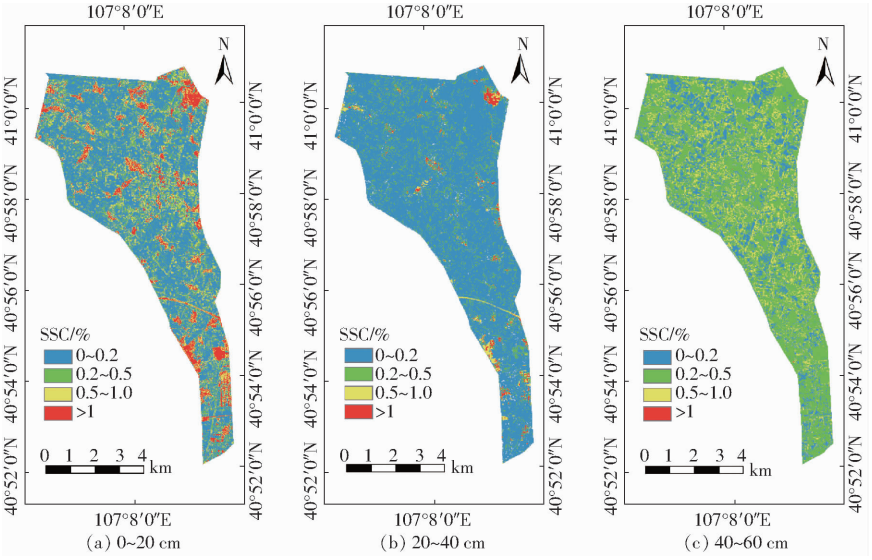

图 6　不同深度土壤含盐量同化结果

Fig. 6　Results of soil salt assimilation at different depths

3　讨论

大范围的土壤含盐量监测受到很多人为因素和自然因素的限制，如地面采样点的位置受地面建筑和灌溉时间的影响，遥感卫星图像受大气云层覆盖面积的影响等。这些不利的影响被称为噪声，而本研究使用两种不同同化算法的目的就是尽可能地减小过程噪声。

本研究使用两种同化算法——EnKF 同化算法和 PF 同化算法来同化观测算子和模型算子。观测算子中，使用 PLS－VIP 准则筛选不同种类的光谱变量，选取 VIP 值大于 1 的变量作为观测算子的自变量，目的在于减少自变量个数并缩减模型计算时间[54]。筛选结果中，由于研究区主要种植的经济作物如葵花、小麦、玉米和蔬菜等生长期各不相同[20]，导致遥感光谱图像所获得的反射率差异较为明显，进而影响 4—9 月 3 个深度的自变量个数和种类。建立反演模型中，ELM 模型采用筛选后的自变量建立了 18 个不同时间不同深度的遥感反演土壤含盐量模型，能够较好反映土壤含盐量的空间分布特征。相较于以往的线性回归模型，ELM 模型能够很好地反映非线性条件下的光谱信息[45]，能够更好地提升反演精度。模型算子中，土壤水力特征参数和溶质运移参数等会极大影响模型模拟的精度，为了更好地反映实际情况，本研究使用不同模型参数来模拟土壤含盐量，从而取得较好的精度。

以 Hydrus－1D 模型为代表的土壤水盐运移模型通常采用微分方程来计算溶质运移过程，但这会导致结构不够稳定，误差会随着时间的增加而不断累积，这从本文的 Hydrus－1D 模型模拟 9 月土壤含盐量精度可以看出。数据同化算法通过在观测时间点加入观测模型数据，及时更新土壤水盐运移模型的初始场域数据和参数，将原本的模型初始场域的使用时间缩短到一个观测周期内，有效降低了模型模拟误差的累积[55]，提高了精度。

两种同化算法对比来看，综合 3 个评价指标，PF 算法同化精度高于 EnKF 算法，其同化值更接近地面实测数据，因此 PF 算法在 ELM 模型和 Hydrus－1D 模型的同化系统中表现更好，同化效果更好。这可能是由于 PF 算法是基于统计和贝叶斯公式发展而来，其同时结合先验和后验概率密度分布来更新粒子状态，能够更好地解决非线性问题[16,53]。而 EnKF 算法使用蒙特卡洛方程积分控制的概率密度函数来描述先验的假设和误差统计，但针对高度非线性的模型，其在算法迭代中有很大的概率无法收敛，继而影响模型中误差协方差的准确性，最终导致精度降低[50]。但比较二者算法的状态更新步骤，即 EnKF 算法对每个集合使用卡尔曼增益计算状态变量的更新，而在 PF 算法中使用重采样的手段[56]进行状态更新，EnKF 算法在更新步骤中不需要计算指数密度函数，与 PF 相比降低了计算成本[57]。此外，EnKF 算法中集成滤波器的状态相关不确定性信息和集成构建能力，能够更好利用遥感信息[12]。这说明 EnKF 算法仍有改进的余地。

本研究只探究了两种单一同化算法对区域土壤含盐量的监测能力，对于复杂的环境存在一定的限制。在后续的研究中，可以构建耦合不同同化算法的同化方案，此外，本研究只使用土壤含盐量作为唯一的状态变量，在后续研究中可以将 Hydrus－1D 模

型参数引入同化方案中,建立基于土壤含盐量和 Hydrus-1D 模型参数的多状态变量同化方案,进一步提升精度。

4 结论

(1)基于 ELM 模型的遥感监测土壤含盐量模型中,6 月深度 20~40 cm 模型在所有模型中精度最高,7 月深度 0~20 cm 模型在所有模型中精度最低,3 个深度的平均 IOA 均在 0.74 以上,平均 ME 在 0.14% 以下,建模集和验证集之间精度相差较小。表明反演模型在 2018 年 4—9 月各层土壤含盐量监测中具有良好的精度。

(2)基于 Hydrus-1D 的数学模拟监测土壤含盐量模型中,3 个深度平均 IOA 在 0.79~0.89 之间,平均 ME 在 0.128%~0.137% 之间,精度随深度递增呈下降趋势;5—9 月各月平均 IOA 在 0.805~0.918 之间,平均 ME 在 0.117%~0.155% 之间,模型准确性随时间推移逐渐下降。综合各评价指标,Hydrus-1D 模型能够较好地反映土壤含盐量在时间序列中的运移情况。

(3)基于 EnKF 算法和 PF 算法的数据同化监测土壤含盐量模型中,EnKF 算法 3 个深度 IOA 分别为 0.924、0.898、0.820,ME 分别为 0.141%、0.147%、0.157%,NMB 分别为 0.141、0.142、0.252;PF 算法 3 个深度 IOA 分别为 0.916、0.905、0.889,ME 分别为 0.142%、0.131%、0.090%,NMB 分别为 0.080、0.075、0.097。比较二者同化方案,PF 算法同化方案在 3 个深度中精度均高于 EnKF 算法同化方案。且相较于 ELM 模型和 Hydrus-1D 模型,PF 算法同化方案也具有明显的优势,因此 PF 算法能够很好地反映土壤含盐量在时间和空间上的分布情况。

参 考 文 献

[1] WANG F, PENG S, FAN L, et al. Improved sulfate reduction efficiency of sulfate-reducing bacteria in sulfate-rich systems by acclimatization and multiple-grouting[J]. Alexandria Engineering Journal, 2022,61(12):9993-10005.

[2] LIU D, YU H, GAO H, et al. Insight into structural composition of dissolved organic matter in saline-alkali soil by fluorescence spectroscopy coupled with self-organizing map and structural equation modeling[J]. Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy, 2022,279:121311.

[3] 陈鹤, 杨大文, 刘钰, 等. 集合卡尔曼滤波数据同化方法改进土壤水分模拟效果[J]. 农业工程学报, 2016,32(2):99-104.
CHEN He, YANG Dawen, LIU Yu, et al. Data assimilation technique based on ensemble Kalman filter for improving soil water content estimation[J]. Transactions of the CSAE, 2016,32(2):99-104. (in Chinese)

[4] 王鹏新, 胡亚京, 李俐, 等. 基于 EnKF 和随机森林回归的玉米单产估测[J]. 农业机械学报, 2020,51(9):135-143.
WANG Pengxin, HU Yajing, LI Li, et al. Estimation of maize yield based on ensemble Kalman filter and random forest for regression[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(9):135-143. (in Chinese)

[5] 张智韬, 黄小鱼, 陈钦达, 等. 基于遥感数据同化的土壤含盐量估算方法[J]. 农业机械学报, 2022,53(7):197-207.
ZHANG Zhitao, HUANG Xiaoyu, CHEN Qinda, et al. Estimation method of soil salinity based on remote sensing data assimilation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(7):197-207. (in Chinese)

[6] CROW W T, WOOD E F. The assimilation of remotely sensed soil brightness temperature imagery into a land surface model using ensemble Kalman filtering: a case study based on ESTAR measurements during SGP97[J]. Advances in Water Resources, 2003,26(2):137-149.

[7] HAN E J, MERWADE V, HEATHMAN G C. Implementation of surface soil moisture data assimilation with watershed scale distributed hydrological model[J]. Journal of Hydrology, 2012,416:98-117.

[8] 何涯舟, 张珂, 晁丽君, 等. 基于多源遥感土壤湿度与模型同化的中小流域径流模拟研究[J]. 水资源保护, 2023, 39(2):145-151,189.
HE Yazhou, ZHANG Ke, CHAO Lijun, et al. Watershed simulation based on multi-source remotely sensed soil moisture and data assimilation[J]. Water Resources Protection, 2023, 39(2): 145-151,189. (in Chinese)

[9] PAUWELS V, VERHOEST N, DE LANNOY G, et al. Optimization of a coupled hydrology-crop growth model through the assimilation of observed soil moisture and leaf area index values using an ensemble Kalman filter[J]. Water Resources Research, 2007, 430(4):244-247.

[10] CURNEL Y, DE WIT A, DUVEILLER G, et al. Potential performances of remotely sensed LAI assimilation in WOFOST model based on an OSS experiment[J]. Agricultural and Forest Meteorology, 2011,151(12):1843-1855.

[11] 程志强, 蒙继华, 纪甫江, 等. 基于 WOFOST 模型与 UAV 数据的玉米生长后期地上生物量估算[J]. 遥感学报, 2020, 24(11):1403-1418.
CHENG Zhiqiang, MENG Jihua, JI Fujiang, et al. Aboveground biomass estimation of late-stage maize based on the WOFOST model and UAV observations[J]. Journal of Remote Sensing, 2020,24(11):1403-1418. (in Chinese)

[12] 刘正春, 徐占军, 毕如田, 等. 基于 4DVAR 和 EnKF 的遥感信息与作物模型冬小麦估产[J]. 农业机械学报, 2021, 52(6):223-231.
LIU Zhengchun, XU Zhanjun, BI Rutian, et al. Winter wheat yield estimation based on assimilated remote sensing date with

crop growth model using 4DVAR and EnKF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(6): 223 – 231. (in Chinese)

[13] 王鹏新, 胡亚京, 李俐, 等. 基于双参数和粒子滤波同化算法的夏玉米单产估测[J]. 农业机械学报, 2021,52(3):168 – 177.
WANG Pengxin, HU Yajing, LI Li, et al. Estimation of summer maize yield based on bi-variables and particle filter assimilation algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021,52(3):168 – 177. (in Chinese)

[14] 解毅, 王鹏新, 张树誉, 等. 基于粒子滤波和多变量权重的冬小麦估产研究[J]. 农业机械学报, 2017,48(10):148 – 155.
XIE Yi, WANG Pengxin, ZHANG Shuyu, et al. Winter wheat yield estimation based on particle filter algorithm and weights of multi-variables[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017,48(10):148 – 155. (in Chinese)

[15] 姚荣江, 杨劲松, 郑复乐, 等. 基于表观电导率和 Hydrus 模型同化的土壤盐分估算[J]. 农业工程学报, 2019, 35(13):91 – 101.
YAO Rongjiang, YANG Jinsong, ZHENG Fule, et al. Estimation of soil salinity by assimilating apparent electrical conductivity data into Hydrus model[J]. Transactions of the CSAE, 2019,35(13):91 – 101. (in Chinese)

[16] VAN LEEUWEN P J. Efficient nonlinear data-assimilation in geophysical fluid dynamics[J]. Computers & Fluids, 2011, 46(1):52 – 58.

[17] 李科, 苑福利, 刘厂. 基于海气耦合模式的均权重粒子滤波与集合卡尔曼滤波比较研究[J]. 海洋通报, 2021,40(4): 417 – 424.
LI Ke, YUAN Fuli, LIU Chang. Comparison of particle filter and EAKF based on the ocean-atmosphere coupled model[J]. Marine Science Bulletin, 2021,40(4):417 – 424. (in Chinese)

[18] 李彦, 魏占民, 张圣微, 等. 基于遥感的沙壕渠控制区作物种植结构与空间分布研究[J]. 中国农村水利水电, 2012 (8):20 – 23.
LI Yan, WEI Zhanmin, ZHANG Shengwei, et al. Spatial analysis and visualization of soil salinization based on ArcGIS[J]. China Rural Water and Hydropower, 2012(8):20 – 23. (in Chinese)

[19] 郝爱枝, 张晓红, 李正中. 河套灌区沙壕渠典型区现有灌溉制度灌溉用水效率评价[J]. 内蒙古水利, 2014(4):55 – 57.
HAO Aizhi, ZHANG Xiaohong, LI Zhengzhong. Irrigation water efficiency evaluation of existing irrigation system in typical Shahao canal area of Hetao Irrigation District[J]. Inner Mongolia Water Resources, 2014(4):55 – 57. (in Chinese)

[20] 黄权中, 徐旭, 吕玲娇, 等. 基于遥感反演河套灌区土壤盐分分布及对作物生长的影响[J]. 农业工程学报, 2018, 34(1):102 – 109.
HUANG Quanzhong, XU Xu, LÜ Lingjiao, et al. Soil salinity distribution based on remote sensing and its effect on crop growth in Hetao Irrigation District[J]. Transactions of the CSAE, 2018,34(1):102 – 109. (in Chinese)

[21] KHAN N M, RASTOSKUEV V V, SATO Y, et al. Assessment of hydrosaline land degradation by using a simple approach of remote sensing indicators[J]. Agricultural Water Management, 2005,77(1 – 3):96 – 109.

[22] TRIPATHI N K, RAI B K, DWIVEDI P. Spatial modeling of soil alkalinity in GIS environment using IRS data[C]// Proceedings of the 18th Asian Conference in Remote Sensing, ACRS Kuala Lumpur, Malaysia. 1997: 8186.

[23] DOUAOUI A E K, NICOLAS H, WALTER C. Detecting salinity hazards within a semiarid context by means of combining soil and remote-sensing data[J]. Geoderma, 2006,134(1 – 2):217 – 230.

[24] KHAN S, ABBAS A. Using remote sensing techniques for appraisal of irrigated soil salinity [C]// Congress on Modelling and Simulation, 2007:2632 – 2638.

[25] WANG J, DING J, YU D, et al. Capability of Sentinel – 2 MSI data for monitoring and mapping of soil salinity in dry and wet seasons in the Ebinur Lake region, Xinjiang, China[J]. Geoderma, 2019,353:172 – 187.

[26] ROUSE J W, HAAS R H, DEERING D W, et al. Monitoring the vernal advancement and retrogradation (green wave effect) of natural vegetation[R]. 1974.

[27] LIU H Q, HUETE A. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise[J]. IEEE Transactions on Geoscience and Remote Sensing, 1995,33(2):457 – 465.

[28] NGUY-ROBERTSON A, GITELSON A, PENG Y, et al. Green leaf area index estimation in maize and soybean: combining vegetation indices to achieve maximal sensitivity[J]. Agronomy Journal, 2012,104(5):1336 – 1347.

[29] JIANG Z Y, HUETE A R, DIDAN K, et al. Development of a two-band enhanced vegetation index without a blue band[J]. Remote Sensing of Environment, 2008,112(10):3833 – 3845.

[30] BIRTH G S, MCVEY G R. Measuring the color of growing turf with a reflectance spectrophotometer[J]. Agronomy Journal, 1968,60(6):640 – 643.

[31] QI J, CHEHBOUNI A, HUETE A R, et al. A modified soil adjusted vegetation index[J]. Remote Sensing of Environment, 1994,48(2):119 – 126.

[32] HABOUDANE D, MILLER J R, PATTEY E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: modeling and validation in the context of precision agriculture[J]. Remote Sensing of Environment, 2004,90(3):337 – 352.

[33] KAUFMAN Y J, TANRE D. Atmospherically resistant vegetation index (ARVI) for EOS – MODIS[J]. IEEE Transactions on Geoscience and Remote Sensing, 1992,30(2):261 – 270.

[34] MCFEETERS S K. The use of the normalized difference water index (NDWI) in the delineation of open water features[J].

International Journal of Remote Sensing, 1996,17(7):1425 - 1432.
[35] JORDAN C F. Derivation of leaf-area index from quality of light on the forest floor[J]. Ecology, 1969,50(4):663 - 666.
[36] GITELSON A A, VINA A, ARKEBAUER T J, et al. Remote estimation of leaf area index and green leaf biomass in maize canopies[J]. Geophysical Research Letters, 2003,30(5):1248 - 1251.
[37] GITELSON A A, VINA A, CIGANDA V, et al. Remote estimation of canopy chlorophyll content in crops[J]. Geophysical Research Letters, 2005,32(8):403 - 406.
[38] RONDEAUX G, STEVEN M, BARET F. Optimization of soil-adjusted vegetation indices[J]. Remote Sensing of Environment, 1996,55(2):95 - 107.
[39] SRIPADA R P, HEINIGER R W, White J G, et al. Aerial color infrared photography for determining early in-season nitrogen requirements in corn[J]. Agronomy Journal, 2006,98(4):968 - 977.
[40] GITELSON A, MERZLYAK M N. Spectral reflectance changes associated with autumn senescence of aesculus-hippocastanuml and acer-platanoidesl leaves-spectral features and relation to chlorophyll estimation[J]. Journal of Plant Physiology, 1994, 143(3):286 - 292.
[41] ROUJEAN J, BREON F. Estimating PAR absorbed by vegetation from bidirectional reflectance measurements[J]. Remote Sensing of Environment, 1995,51(3):375 - 384.
[42] ROUSE J W, HAAS R W, SCHELL J A, et al. Monitoring vegetation systems in the Great Plains with ERTS[J]. NASA Spec. Publ., 1974, 351(1): 309.
[43] WANG M Q, WANG J R, CHEN J W, et al. Effect of commercial yeast starter cultures on cabernet sauvignon wine aroma compounds and microbiota[J]. Foods, 2022,11(12): 1725.
[44] 曾涛, 琚存勇, 蔡体久, 等. 利用变量投影重要性准则筛选郁闭度估测参数[J]. 北京林业大学学报, 2010,32(6):37 - 41.
ZENG Tao, JU Cunyong, CAI Tijiu, et al. Selection of parameters for estimating canopy closure density using variable importance of projection criterion[J]. Journal of Beijing Forestry University, 2010,32(6):37 - 41. (in Chinese)
[45] HUANG G, WANG D H, LAN Y. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011,2(2):107 - 122.
[46] 杨锡运, 关文渊, 刘玉奇, 等. 基于粒子群优化的核极限学习机模型的风电功率区间预测方法[J]. 中国电机工程学报, 2015,35(增刊 1):146 - 153.
YANG Xiyun, GUAN Wenyuan, LIU Yuqi, et al. Prediction intervals forecasts of wind power based on PSO - KELM [J]. Proceedings of the CSEE, 2015,35(Supp. 1):146 - 153. (in Chinese)
[47] 徐睿, 梁循, 齐金山, 等. 极限学习机前沿进展与趋势[J]. 计算机学报, 2019,42(7):1640 - 1670.
XU Rui, LIANG Xun, QI Jinshan, et al. Advances and trends in extreme learning machine[J]. Chinese Journal of Computers, 2019,42(7):1640 - 1670. (in Chinese)
[48] KUMAR H, SRIVASTAVA P, LAMBA J, et al. Site-specific irrigation scheduling using one-layer soil hydraulic properties and inverse modeling[J]. Agricultural Water Management, 2022,273: 107877.
[49] 张桂欣, 祝善友, 郝振纯. 同化 AMSR2 数据提高 HYDRUS - 1D 模型土壤湿度模拟精度[J]. 农业工程学报, 2019, 35(17):79 - 86.
ZHANG Guixin, ZHU Shanyou, HAO Zhenchun. Assimilation of AMSR2 data improving simulation accuracy of soil moisture by using HYDRUS - 1D model[J]. Transactions of the CASE, 2019,35(17):79 - 86. (in Chinese)
[50] LORENTZEN R J, NAEVDAL G. An iterative ensemble kalman filter[J]. IEEE Transactions on Automatic Control, 2011, 56(8):1990 - 1995.
[51] EVENSEN G. Sequential data assimilation with a nonlinear quasi-geostrophic model using monte-carlo methods to forecast error statistics[J]. Journal of Geophysical Research-oceans, 1994,99(C5):10143 - 10162.
[52] 王法胜, 鲁明羽, 赵清杰, 等. 粒子滤波算法[J]. 计算机学报, 2014,37(8):1679 - 1694.
WANG Fasheng, LU Mingyu, ZHAO Qingjie, et al. Particlefilter algorithm[J]. Chinese Journal of Computers, 2014,37(8): 1679 - 1694. (in Chinese)
[53] ARULAMPALAM M S, MASKELL S, GORDON N, et al. A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking[J]. IEEE Transactions on Signal Processing, 2002,50(2):174 - 188.
[54] XING Z, CHEN J, ZHAO X, et al. Quantitative estimation of wastewater quality parameters by hyperspectral band screening using GC, VIP and SPA[J]. PEERJ, 2019,7: e8255.
[55] 李港, 陈诚, 何欣霞, 等. 湖泊藻类动态模型数据同化模式的改进[J]. 水资源保护, 2021,37(4):156 - 165.
LI Gang, CHEN Cheng, HE Xinxia, et al. Modify of data assimilation model for lake algae dynamic model[J]. Water Resources Protection, 2021,37(4):156 - 165. (in Chinese)
[56] LEISENRING M, MORADKHANI H. Snow water equivalent prediction using Bayesian data assimilation methods[J]. Stochastic Environmental Research and Risk Assessment, 2011,25(2):253 - 270.
[57] CHITRALEKHA S B, PRAKASH J, RAGHAVAN H, et al. A comparison of simultaneous state and parameter estimation schemes for a continuous fermentor reactor[J]. Journal of Process Control, 2010,20(8):934 - 943.