doi:10.6041/j.issn.1000-1298.2022.07.020

基于遥感数据同化的土壤含盐量估算方法

张智韬[1,2]　黄小鱼[1,2]　陈钦达[1,2]　张珺锐[1,2]　台　翔[1,2]　韩　佳[1,2]

(1. 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;
2. 西北农林科技大学水利与建筑工程学院, 陕西杨凌 712100)

摘要: 为探究同化遥感数据对监测区域尺度土壤含盐量时空信息的适用性,以河套灌区沙壕渠灌域为研究区,以高分一号卫星影像为数据源,通过灰度关联法筛选光谱指数,采用岭回归法构建不同深度的土壤含盐量反演模型,使用集合卡尔曼滤波同化算法将遥感数据应用于 HYDRUS-1D 模型中,开展区域尺度不同深度土壤含盐量的同化研究。结果表明,基于不同深度土壤含盐量的岭回归法模型,其 R^2 均在 0.64 以上,RE 为 0.14~0.22,反演精度较高,得到的反演值较为准确;在单点尺度上,与模拟值、反演值相比,同化值更接近实测值,其 EFF 为 0.84~0.93,NER 为 0.61~0.73,均为正数,且 RMSE 降低到 0.006%~0.011%,提高了 HYDRUS-1D 模型模拟精度;在区域尺度上,不同深度同化值的 r 均为 0.94 以上,NER 为 0.61 以上,优于模拟值和反演值,且同化精度随着深度的增加而降低。本文基于遥感数据和 HYDRUS-1D 模型的集合卡尔曼滤波同化研究,提高了土壤含盐量的模拟精度,对提高监测区域尺度土壤含盐量时空信息的精度具有一定的参考价值。

关键词: 土壤含盐量; 遥感; 数据同化; HYDRUS-1D 模型; 集合卡尔曼滤波

中图分类号: S127; S156.4　**文献标识码:** A　**文章编号:** 1000-1298(2022)07-0197-11　**OSID:**

Estimation Method of Soil Salinity Based on Remote Sensing Data Assimilation

ZHANG Zhitao[1,2]　HUANG Xiaoyu[1,2]　CHEN Qinda[1,2]　ZHANG Junrui[1,2]　TAI Xiang[1,2]　HAN Jia[1,2]

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

Abstract: Soil salinization seriously restricts sustainable agricultural development, and it is a main environmental problem in arid and semiarid regions. Therefore, the method of assimilating remote sensing data is used to monitor spatial and temporal information of soil salinity in a regional scale, which is of great significance to management of soil salinization. The feasibility of soil salinity estimation to assimilate HYDRUS-1D model and remote sensing data was explored by using ensemble Kalman filter. The study area was located in Shahaoqu Irrigation District of Hetao Irrigation District. The remote sensing data was obtained by GF-1 satellite. Spectral indexes were screened by gray correlation method, and inversion models of soil salinity at different depths were constructed by ridge regression models. Then remote sensing data was applied to HYDRUS-1D model by using ensemble Kalman filter to carry out assimilation study of soil salinity of different depths in a regional scale. The main conclusions were as follows: based on ridge regression models of soil salinity at different depths, R^2 were above 0.64 and RE were 0.14~0.22. Inversion accuracies were relatively good and inversion values were relatively accurate. In a single point scale, compared with inversion values and simulation values, assimilation values were closer to measured values. EFF of assimilation values were 0.84~0.93 and their NER were 0.61~0.73. They were all positive values. And their RMSE were reduced to 0.006%~0.011%. These results showed the scheme of data assimilation improved simulation accuracies of HYDRUS-1D model. In a regional scale, r of assimilation values were above 0.94 and their NER were above 0.61. And they were better than r and NER of inversion values and simulation values. Meanwhile, with increase of depth, the accuracy of assimilation was decreased. The results indicated that data assimilation

收稿日期: 2021-08-02　修回日期: 2021-09-17

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,副教授,博士,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

greatly improved simulation accuracies of soil salinity at different depths by using ensemble Kalman filter. The research result can provide certain reference value for improving monitoring accuracy of soil salinity in a regional scale.

Key words: soil salinity; remote sensing; data assimilation; HYDRUS－1D model; ensemble Kalman filter

0 引言

土壤盐渍化是导致干旱半干旱地区土地退化的重要成因,土地退化会引起农作物减产,进而影响国家和社会的可持续性发展[1]。因此,准确连续地监测土壤含盐量对灌区的农业和经济发展有着十分重要的现实意义。

卫星遥感已经成为监测土壤含盐量的重要手段[2],遥感反演具有快速、准确地大面积监测土壤含盐量的优点[3],但是其在时间上不连续,只能反映卫星过境时刻的瞬时状态,并且无法揭示土壤盐分运移的内在机制以及其与气象、土壤、植被等因素的关系。盐分运移模型通过输入气象数据、土壤参数等,在时间序列上能连续模拟单点尺度的土壤含盐量[4],但是其受模型输入数据的不确定性限制,导致模型误差在时间上不断累积,因而模拟精度不高。数据同化能够把遥感信息和盐分运移模型各自的优势相结合,能较为准确地连续监测区域土壤含盐量的时空变化情况,是精准农业的发展趋势。

数据同化就是通过引入时间序列的观测数据来校正模型模拟过程,从而提高模型模拟精度[5]。陈鹤等[6]构建集合卡尔曼滤波数据同化方案,将其输入到HELP模型中,有效地提高了土壤水分的模拟精度。王泽人等[7]以集合卡尔曼滤波为基础,构建太湖叶绿素a质量浓度同化试验系统,提高了太湖蓝藻水华的预测精度。上述研究是基于实测数据在单点尺度的数据同化,而未基于遥感数据开展区域尺度的数据同化研究,因此同化结果具有一定的局限性。文献[8－11]采用同化算法把遥感数据同化到模型中,开展区域尺度数据同化研究,多应用在产量估计、土壤水分等方面,关于区域尺度的土壤含盐量同化研究较少。

本文以高分一号卫星影像为数据源,结合研究区不同深度时间序列的实测土壤含盐量,以岭回归法遥感反演的土壤含盐量模型作为观测算子,采用集合卡尔曼滤波同化算法将遥感反演值引入到HYDRUS－1D模型中,对不同深度的土壤盐分运移过程进行同化模拟,通过对集合数进行敏感性分析,确定单点尺度数据同化方案的最佳集合数,从而得到最佳的单点尺度监测土壤含盐量数据同化方案,并由此扩展到区域尺度监测土壤含盐量的数据同化研究,采用同化遥感数据为连续准确地监测土壤含盐量时空变化提供了可行方案。

1 材料与方法

1.1 研究区概况

研究区位于内蒙古河套灌区沙壕渠灌域(40°52′～41°00′N,107°05′～107°10′E),形状类似于狭长型的倒三角形,整体地势呈南高北低。沙壕渠灌域地处干旱半干旱地区,属于典型的温带大陆性气候,灌域内常见作物有小麦、葵花、玉米等,灌溉用水多数来自于过境的黄河水,年平均降水量约为140 mm,年平均蒸发量约为2 000 mm,降水少、蒸发大的特点以及长期的不合理灌溉方式,使得研究区的土壤盐渍化问题日趋严重。

1.2 田间实测数据

本研究在沙壕渠灌域内共设置120个采样点,研究区及采样点分布如图1所示。采用五点法对每个采样点深度0～20 cm、20～40 cm、40～60 cm进行分层采样,用手持GPS仪器记录该采样点的具体位置信息,将土样放置到已编号的铝盒中,并带回实验室。采用干燥法测定土壤含水率。把土样研磨配制成土水比为1∶5溶液,经过搅拌、静置、沉淀、过滤等操作后,并使用电导率仪(DDS－307A型,上海佑科仪器公司)测定土壤电导率,取每个采样点的5个电导率平均值作为该采样点的电导率,并通过经验公式[12]计算土壤含盐量(SSC,%)。采样时间分别为2019年4月15日、5月1日、5月15日、6月1日、6月15日、7月1日、7月15日、8月1日、8月15日、9月1日和9月15日,共11次。

1.3 遥感反演土壤含盐量

遥感数据来自于中国卫星资源应用中心(http://www.cresda.com/CN/)的高分一号卫星。遥感数据预处理包括几何精校正、辐射校正、大气校正、裁剪等过程,并提取波段反射率,进而计算光谱指数。本研究采用4个波段反射率组合的光谱指数,共计24个,分别为SI－T、BI、SI、SI1、SI2、SI3[13]、S1、S2、S3、S5、S6、NDSI[14]等12个盐分指数和CRSI[15]、SR、NDVI、EVI、DVI、TVI、SRVI[16]、MSAVI[17]、ARVI[18]、NDWI[19]、NDGI[20]、GRVI[21]等12个植被指数。在

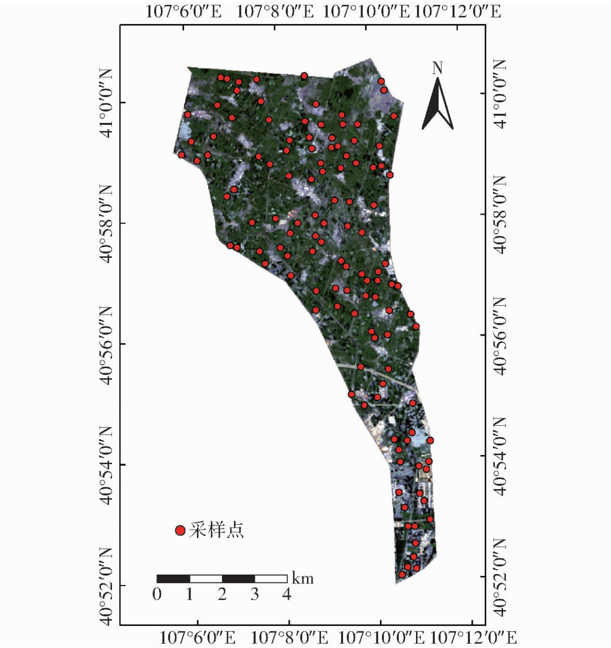

图 1　研究区及采样点分布图

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

模型构建过程中，盐分指数和植被指数分别经过灰度关联法筛选，选取排序前 4 的盐分指数和植被指数的光谱指数组合作为输入反演模型的自变量，以不同深度的实测土壤含盐量为因变量，把所有采样点的土壤含盐量按照从小到大排序，每隔 2 个样本选取出 1 个样本作为验证集，其余则为建模集，分别对建模集和验证集构建基于不同深度土壤含盐量的岭回归法反演模型，得到不同深度的土壤含盐量遥感反演值。卫星遥感影像获取的时间分别为 2019 年 5 月 1 日、5 月 13 日、5 月 30 日、6 月 28 日、7 月 1 日、7 月 30 日、8 月 7 日、8 月 15 日、9 月 1 日和 9 月 18 日。

1.4　HYDRUS－1D 模型

HYDRUS－1D 模型适用于模拟一维条件下饱和–非饱和多孔介质的水分、能量、溶质运移以及根系吸水等[22]。本研究主要使用 HYDRUS－1D 模型的水分运移模块和溶质运移模块，不考虑根系吸水模块。在开展土壤盐分运移模拟时，需要输入的数据包括气象数据、地下水位、初始条件及模型相关参数等。气象数据来自于中国气象数据网（http://data.cma.cn/），包括降水量、蒸发量、气温、风速、日照时数等气象要素。选取河套灌区内的杭锦后旗、临河、五原、磴口、乌拉特前旗等 5 个气象站，对这些站点的逐日气象要素进行克里金插值。根据气象数据，使用 Penman－Monteith 公式计算潜在蒸散发量[23]。模型的土壤水力特征参数、溶质运移参数等的初始值基于已有的研究选定[24－25]，通过比较不同深度的实测土壤含盐量与模拟值的偏差，不断地对模型参数值进行调整，从而确定 HYDRUS－1D 模型主要参数的具体值。选取大气边界作为水分运移模块的上边界，变压力水头作为水分运移模块的下边界；溶质运移模块的上、下边界条件均为浓度边界。初始条件为初始时刻实测的土壤含水率和土壤电导率。

1.5　集合卡尔曼滤波数据同化方案

1.5.1　集合卡尔曼滤波原理

集合卡尔曼滤波作为顺序数据同化算法之一，它以蒙特卡罗方法为基础，采用一组符合高斯分布的随机变量集合，通过模型向前积分，计算下一时刻状态量的统计特征[26]。它很好地解决了卡尔曼滤波在实际应用中误差协方差矩阵的估计，克服了卡尔曼滤波线性化的问题[27]。

（1）进行初始化。假设有 N 个集合数，在 t 时刻，添加高斯白噪声，从而对土壤含盐量进行初始扰动，得到符合高斯分布的状态变量集合 $\boldsymbol{X}_{i,0}$（$i=0,1,\cdots,N$）。

（2）把 t 时刻的土壤含盐量集合输入到 HYDRUS－1D 模型中，得到 $t+1$ 时刻的土壤含盐量预测值集合，计算式为

$$\boldsymbol{X}^f_{i,t+1}=\boldsymbol{M}_{t,t+1}(\boldsymbol{X}^a_{i,t})+\boldsymbol{\omega}_{i,t}\quad(\boldsymbol{\omega}_{i,t}\sim N(0,\boldsymbol{Q}_t)) \tag{1}$$

式中　$\boldsymbol{X}^f_{i,t+1}$——$t+1$ 时刻第 i 个土壤含盐量预测值

$\boldsymbol{X}^a_{i,t}$——t 时刻第 i 个土壤含盐量分析值

$\boldsymbol{M}_{t,t+1}$——模型算子，本研究为 HYDRUS－1D 模型

$\boldsymbol{\omega}_{i,t}$——模型误差，服从期望为 0、方差为 $\boldsymbol{Q}_t$ 的高斯分布

$\boldsymbol{Q}_t$——t 时刻模型误差扰动所对应的误差协方差矩阵

（3）计算 $t+1$ 时刻土壤含盐量预测值集合的均值和误差协方差矩阵，计算式为

$$\overline{\boldsymbol{X}}^f_{t+1}=\frac{1}{N}\sum_{i=1}^{N}\boldsymbol{X}^f_{i,t+1} \tag{2}$$

$$\boldsymbol{P}^f_{t+1}=\frac{1}{N-1}\sum_{i=1}^{N}(\boldsymbol{X}^f_{i,t+1}-\overline{\boldsymbol{X}}^f_{t+1})(\boldsymbol{X}^f_{i,t+1}-\overline{\boldsymbol{X}}^f_{t+1})^{\mathrm{T}} \tag{3}$$

式中　$\overline{\boldsymbol{X}}^f_{t+1}$——$t+1$ 时刻土壤含盐量预测值集合均值

$\boldsymbol{P}^f_{t+1}$——$t+1$ 时刻土壤含盐量预测值的误差协方差矩阵

（4）计算 $t+1$ 时刻卡尔曼增益，计算式为

$$\boldsymbol{K}_{t+1}=\boldsymbol{P}^f_{t+1}\boldsymbol{H}^{\mathrm{T}}_{t+1}(\boldsymbol{H}_{t+1}\boldsymbol{P}^f_{t+1}\boldsymbol{H}^{\mathrm{T}}_{t+1}+\boldsymbol{R}_{t+1})^{-1} \tag{4}$$

$$\boldsymbol{P}^f_{t+1}\boldsymbol{H}^{\mathrm{T}}_{t+1} = \frac{1}{N-1}\sum_{i=1}^{N}(\boldsymbol{X}^f_{i,t+1} - \bar{\boldsymbol{X}}^f_{t+1})[\boldsymbol{H}_{t+1}(\boldsymbol{X}^f_{i,t+1}) - \boldsymbol{H}_{t+1}(\bar{\boldsymbol{X}}^f_{t+1})]^{\mathrm{T}} \quad (5)$$

$$\boldsymbol{H}_{t+1}\boldsymbol{P}^f_{t+1}\boldsymbol{H}^{\mathrm{T}}_{t+1} = \frac{1}{N-1}\sum_{i=1}^{N}[\boldsymbol{H}_{t+1}(\boldsymbol{X}^f_{i,t+1}) - \boldsymbol{H}_{t+1}(\bar{\boldsymbol{X}}^f_{t+1})]\cdot[\boldsymbol{H}_{t+1}(\boldsymbol{X}^f_{i,t+1}) - \boldsymbol{H}_{t+1}(\bar{\boldsymbol{X}}^f_{t+1})]^{\mathrm{T}} \quad (6)$$

式中 $\boldsymbol{K}_{t+1}$——$t+1$ 时刻的卡尔曼增益

$\boldsymbol{H}_{t+1}$——$t+1$ 时刻的观测算子

$\boldsymbol{R}_{t+1}$——$t+1$ 时刻观测误差扰动所对应的误差协方差矩阵

(5)计算 $t+1$ 时刻土壤含盐量分析值集合的均值和误差协方差矩阵,计算式为

$$\boldsymbol{X}^a_{i,t+1} = \boldsymbol{X}^f_{i,t+1} + \boldsymbol{K}_{t+1}[\boldsymbol{Y}^o_{t+1} - \boldsymbol{H}_{t+1}(\boldsymbol{X}^f_{i,t+1}) + \boldsymbol{\nu}_{i,t+1}] \quad (\boldsymbol{\nu}_{i,t+1} \sim N(0,\boldsymbol{R}_{t+1})) \quad (7)$$

$$\bar{\boldsymbol{X}}^a_{t+1} = \frac{1}{N}\sum_{i=1}^{N}\boldsymbol{X}^a_{i,t+1} \quad (8)$$

$$\boldsymbol{P}^a_{t+1} = \frac{1}{N-1}\sum_{i=1}^{N}(\boldsymbol{X}^a_{i,t+1} - \bar{\boldsymbol{X}}^a_{t+1})(\boldsymbol{X}^a_{i,t+1} - \bar{\boldsymbol{X}}^a_{t+1})^{\mathrm{T}} \quad (9)$$

式中 $\boldsymbol{X}^a_{i,t+1}$——$t+1$ 时刻第 i 个土壤含盐量分析值

$\boldsymbol{Y}^o_{t+1}$——$t+1$ 时刻土壤含盐量观测值

$\bar{\boldsymbol{X}}^a_{t+1}$——$t+1$ 时刻土壤含盐量分析值集合均值

$\boldsymbol{P}^a_{t+1}$——$t+1$ 时刻土壤含盐量分析值误差协方差矩阵

$\boldsymbol{\nu}_{i,t+1}$——观测误差,服从期望为 0、方差为 $\boldsymbol{R}_{t+1}$ 的高斯分布

1.5.2 不同深度土壤含盐量集合卡尔曼滤波数据同化方案

数据同化系统由观测算子、模型算子和同化算法 3 部分组成,在本研究中,观测算子为时间序列上基于不同深度土壤含盐量的岭回归法反演模型,模型算子为 HYDRUS-1D 模型,模拟时间序列上不同深度土壤盐分运移,同化算法则为耦合观测算子(遥感数据)和模型算子(模型模拟数据)的集合卡尔曼滤波,在考虑集合数、观测误差以及模型误差等同化条件的基础上,通过同化遥感数据到 HYDRUS-1D 模型中,开展单点尺度不同深度土壤含盐量数据同化方案,进而将单点同化方案扩展到不同深度的区域尺度土壤含盐量数据同化方案。其流程如图 2 所示。

(1)开始进行 HYDRUS-1D 模型模拟,得到 t 时刻不同深度土壤含盐量模拟值。

(2)$t+1$ 时刻分 2 种情况:①当 $t+1$ 时刻不存在反演值时,t 时刻的不同深度土壤含盐量模拟值继续输入 HYDRUS-1D 模型中,得到 $t+1$ 时刻的不同深度土壤含盐量模拟值。②当 $t+1$ 时刻存在反演值时,开始数据同化的计算流程。对 t 时刻不同深度土壤含盐量模拟值进行初始化,并输入到 HYDRUS-1D 模型中,再加上模型误差生成不同深度土壤含盐量预测值集合;利用 $t+1$ 时刻不同深度土壤含盐量反演值加上观测误差生成不同深度土壤含盐量观测值集合;通过预测值集合和观测值集合计算卡尔曼增益,更新得到不同深度土壤含盐量分析值集合,并计算其均值,即为同化值。

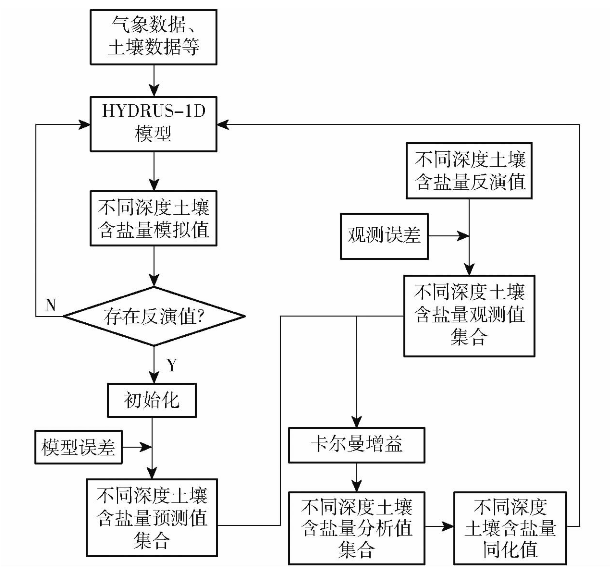

图 2 数据同化流程图

Fig. 2 Flow diagram of data assimilation

进入下一时刻,重复步骤(2)的计算流程,直至整个同化研究结束。

本研究以不同深度土壤含盐量作为数据同化方案的状态变量,以多时相岭回归法反演模型为观测算子,通过集合卡尔曼滤波同化算法将其引入 HYDRUS-1D 模型中,HYDRUS-1D 模型模拟时间为 2019 年 4 月 15 日至 9 月 21 日,共 160 d,在 2019 年 4 月 15 日对 HYDRUS-1D 模型输入初始时刻不同深度土壤含盐量实测值,模拟时间序列上不同深度土壤盐分运移。模型运行到 2019 年 5 月 1 日,即第 1 次出现遥感反演值时,开始进行数据同化,同化时间取为 2019 年 5 月 1 日至 9 月 21 日,共 144 d。

1.6 评价指标

本研究采用决定系数 R^2、相对误差(RE)对遥感反演结果进行评价;采用均方根误差(RMSE)、同化效率系数(EFF)[28] 和归一化还原误差指数(NER)[29] 对单点尺度同化结果进行评价;采用相关系数 r 和 NER 对区域尺度同化结果进行评价。其中,EFF 和 NER 的计算公式分别为

$$EFF = 1 - \frac{\sum_{t=1}^{n}(S^a_t - O_t)^2}{\sum_{t=1}^{n}(S^b_t - O_t)^2} \quad (10)$$

$$NER = 1 - \frac{e^a_{\mathrm{RMSE}}}{e^b_{\mathrm{RMSE}}} \tag{11}$$

式中　EFF——同化效率系数

NER——归一化还原误差指数

S^a_t——t 时刻的土壤含盐量同化值/反演值

S^b_t——t 时刻的土壤含盐量模拟值

O_t——t 时刻的土壤含盐量实测值

e^a_{RMSE}——同化值/反演值的均方根误差

e^b_{RMSE}——模拟值的均方根误差

EFF 的取值范围为 $-\infty \sim 1$，当 EFF 大于 0 时，HYDRUS－1D 模型模拟结果的精度提高，当 EFF 小于 0 时，HYDRUS－1D 模型模拟结果精度降低。EFF 越接近 1，精度越高。

NER 的取值范围为 $-\infty \sim 1$，当 NER 大于 0 时，表明改善了 HYDRUS－1D 模型模拟结果；当 NER 小于 0 时，表明降低了 HYDRUS－1D 模型模拟结果。NER 越接近 1，精度越高。

2　结果与分析

2.1　基于光谱指数的土壤含盐量估算

以 2019 年 6 月 28 日的高分一号卫星遥感图像为例，使用灰色系统把 120 个采样点不同深度土壤含盐量实测值分别与 12 个盐分指数、12 个植被指数进行灰度关联分析，它们的灰色关联度和排序如表 1、2 所示。本研究分别选取关联度排序前 4 的盐分指数和植被指数构成的光谱指数组合作为自变量，以不同深度的实测土壤含盐量作为因变量，构建基于岭回归法的不同深度土壤含盐量反演模型。模型的建模和验证结果如表 3 所示。

表 1　不同深度盐分指数与土壤含盐量的灰色关联度

Tab. 1　Gray correlation degree between salinity index and soil salinity at different depths

盐分指数	土层深度/cm					
	0～20		20～40		40～60	
	排序	关联度	排序	关联度	排序	关联度
SI－T	11	0.637	11	0.617	11	0.605
BI	10	0.646	10	0.641	10	0.635
SI	5	0.744	5	0.765	5	0.775
SI1	6	0.739	6	0.757	6	0.764
SI2	9	0.689	9	0.682	9	0.674
SI3	2	0.815	2	0.835	2	0.841
S1	8	0.733	7	0.720	7	0.718
S2	1	0.879	1	0.900	1	0.924
S3	3	0.795	4	0.796	4	0.806
S5	4	0.788	3	0.815	3	0.829
S6	12	0.511	12	0.511	12	0.511
NDSI	7	0.734	8	0.707	8	0.694

表 2　不同深度植被指数与土壤含盐量的灰色关联度

Tab. 2　Gray correlation degree between vegetation index and soil salinity at different depths

植被指数	土层深度/cm					
	0～20		20～40		40～60	
	排序	关联度	排序	关联度	排序	关联度
CRSI	4	0.773	4	0.761	2	0.761
SR	10	0.650	11	0.629	11	0.617
NDVI	7	0.734	7	0.707	7	0.694
EVI	3	0.791	3	0.765	4	0.755
DVI	1	0.829	1	0.814	1	0.799
TVI	9	0.678	9	0.652	10	0.637
SRVI	2	0.796	2	0.770	3	0.760
MSAVI	6	0.740	6	0.724	5	0.720
ARVI	5	0.772	5	0.737	6	0.719
NDWI	8	0.703	8	0.683	8	0.674
NDGI	12	0.546	12	0.544	12	0.543
GRVI	11	0.638	10	0.649	9	0.659

表 3　基于不同深度土壤含盐量的岭回归法模型

Tab. 3　Ridge regression models based on soil salinity at different depths

土层深度/cm	建模		验证	
	R^2_C	RE_C	R^2_V	RE_V
0～20	0.678	0.142	0.669	0.158
20～40	0.661	0.194	0.651	0.207
40～60	0.650	0.218	0.641	0.214

由表 3 可知，同一深度上，岭回归法模型的建模集和验证集的决定系数 R^2 和相对误差 RE 相差不大，并且随着深度的增加，模型精度随之降低。0～20 cm 模型反演精度最高，其次是 20～40 cm，模型反演精度最差的是 40～60 cm。在 3 个深度上，岭回归法模型的建模集和验证集的 R^2 均达到 0.64 以上，拟合精度较高，建模集和验证集的 RE 介于 0.14～0.22 之间，表明使用岭回归法模型得到的遥感反演值与实测值的误差相对较小，模型反演精度较高。

使用岭回归法模型得到其余时刻的不同深度土壤含盐量遥感反演值，并把时间序列上的不同深度土壤含盐量遥感反演模型作为数据同化方案的观测算子，开展不同深度的土壤含盐量数据同化研究。

2.2　单点数据同化方案

2.2.1　集合数的敏感性分析

基于不同深度土壤含盐量的集合卡尔曼滤波数据同化方案，集合数是影响数据同化模拟精度的重要因素。本研究设置的集合数分别为 10、25、50、75、100，对不同深度的土壤盐分运移进行同化模拟，分析集合数对同化结果的影响，如图 3 所示。

由图 3a 可知，随着集合数的增大，每个深度土壤含盐量同化值的均方根误差 RMSE 都随之减小。当集合数小于等于 50 时，RMSE 降低速度较大；当

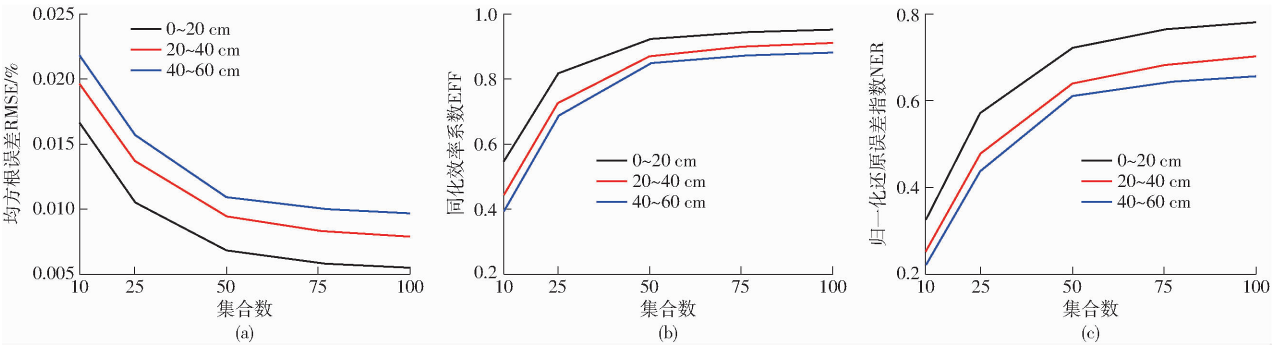

图3 不同集合数对同化结果的影响

Fig. 3 Effects of different ensemble numbers on assimilation results

集合数大于50时,RMSE降低速度相对较小。当集合数为10和25时,RMSE均高于0.01%;当集合数为50时,RMSE介于0.006%~0.011%之间;当集合数为50、75和100时,其RMSE相差不大。由图3b可知,每个深度土壤含盐量同化值的同化效率系数EFF都大于0,说明在不同的集合数条件下,均具有同化效果。各深度的EFF都随着集合数增加而增加,增加的速度在减小,当集合数为10时,同化效果最差,各深度的EFF都小于0.55;当集合数为25时,同化效果相对较差;当集合数为50时,各深度的EFF均达到0.8以上,表明经过数据同化后,提高了HYDRUS-1D模型模拟精度,同化效果较好;当集合数为75和100时,各深度的EFF与集合数为50时的EFF相差不大。由图3c可知,每个深度土壤含盐量同化值的归一化还原误差指数NER均大于0,说明在不同的集合数条件下,土壤含盐量模拟精度均得以提高。各深度的NER变化趋势表现为随着集合数的增加而增加,增加的趋势在减缓,当集合数为10和25时,各深度的NER均低于0.6,表明同化方案对改善模型模拟精度的能力较差;随着集合数的增加,当集合数为50时,NER介于0.61~0.73之间;当集合数为75和100时,与集合数为50时的NER相差不大。综上所述,为了提高同化运算效率和满足同化精度的要求,本研究的最佳集合数为50。

由图3可知,当集合数相同时,各深度同化值的RMSE均表现为随着深度的增加而增大,而各深度同化值的EFF和NER都表现为随着深度的增加而减小。在3个深度上,0~20 cm同化值的RMSE最小,EFF最大,NER最大,0~20 cm同化效果最好;20~40 cm次之;40~60 cm最差,其RMSE最大,EFF最小,NER最小。故同化精度是随着深度的增加而降低。

2.2.2 单点同化结果分析

根据上述研究,集合数取为50,观测误差和模型误差分别设置为0.01、0.01,对单点尺度不同深度土壤含盐量开展集合卡尔曼滤波同化研究。基于不同深度的土壤含盐量实测数据(简称实测值),采用HYDRUS-1D模型模拟得到土壤含盐量模拟值(简称模拟值)、采用岭回归法模型反演得到土壤含盐量遥感反演值(简称反演值)、采用集合卡尔曼滤波同化算法得到土壤含盐量同化值(简称同化值),比较不同深度土壤含盐量的模拟值、反演值、同化值和实测值,如图4所示,并进行误差分析,如表4所示。

由图4可知,在同一深度上,模拟值与实测值的误差最大,其次是反演值,同化值最接近实测值;在不同深度上,模拟值、反演值和同化值与实测值的误差都随着深度的增加而增加。由表4可知:①从同化误差的角度分析,在同一深度上,与模拟值、反演值相比,同化值与实测值的误差最小,其在3个深度

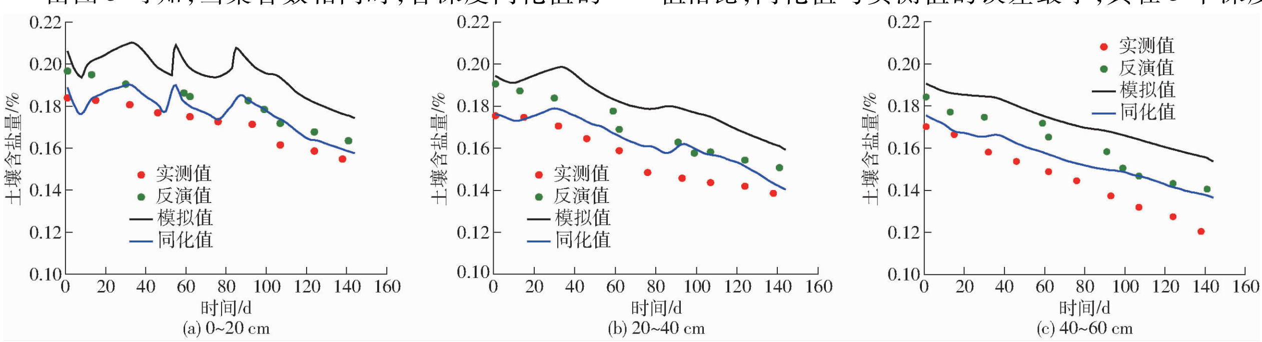

图4 不同深度土壤含盐量的模拟值、反演值、同化值与实测值的比较

Fig. 4 Comparisons of simulated values, inversion values, assimilation values and measured values of soil salinity at different depths

表 4　不同深度土壤含盐量的模拟值、反演值、同化值与实测值的误差分析

Tab. 4　Error analysis of simulated values, inversion values, assimilation values and measured values of soil salinity at different depths

土层深度/cm	均方根误差 RMSE/%			同化效率系数 EFF		归一化还原误差指数 NER	
	模拟值	反演值	同化值	反演值	同化值	反演值	同化值
0 ~ 20	0.024 5	0.010 0	0.006 8	0.834	0.922	0.592	0.721
20 ~ 40	0.026 2	0.013 0	0.009 4	0.752	0.870	0.502	0.640
40 ~ 60	0.027 9	0.015 6	0.010 9	0.690	0.848	0.443	0.610

的 RMSE 均低于 0.011%，反演值次之，反演值的 RMSE 与同化值的 RMSE 相差不大，模拟值与实测值的误差最大，其在 3 个深度的 RMSE 为 0.024% ~ 0.028%；在 3 个深度上，同化值、反演值和模拟值的误差随着深度的增加而增加，表明无论是模型模拟、遥感反演还是同化模拟对土壤含盐量的作用都是表层优于深层。②就同化效率系数而言，在同一深度上，同化值和反演值的 EFF 大于 0.65，并且同化值的 EFF 更接近于 1，表明引入反演值到 HYDRUS - 1D 模型中进行同化模拟，能较好地改善模型模拟精度，使同化值更接近实测值；在 3 个深度上，同化值和反演值的 EFF 都为正值，同化值的 EFF 大于反演值的 EFF，它们的 EFF 随着深度的增加而降低，表明引入遥感数据对 0 ~ 20 cm 土壤含盐量的同化作用优于 20 ~ 40 cm、40 ~ 60 cm。③从提高模型精度程度来看，在同一深度上，同化值和反演值的 NER 均大于 0.4，并且同化值大于反演值，表明同化遥感数据，使得模型的模拟轨迹更加接近实测值，减小了模拟值与实测值的误差，提高了 HYDRUS - 1D 模型的模拟精度；在 3 个深度上，同化值和反演值的 NER 都为正值，随着深度的增加，同化值和反演值的 NER 逐渐减少，表明同化遥感数据对每个深度土壤含盐量的模拟精度均能提高，并且对于每个深度的土壤含盐量，同化作用随着深度的增加而减小。

综上所述，在同一深度上，同化值与实测值最为接近，反演值次之，模拟值和实测值相差最大。在 3 个深度上，同化值、反演值和模拟值的精度都是随着深度的增加而降低。在单点尺度上，开展不同深度的集合卡尔曼滤波数据同化方案，结合了遥感反演和模型模拟各自的优势，通过集合卡尔曼滤波同化算法把时间序列上的不同深度土壤含盐量反演值应用到 HYDRUS - 1D 模型，提高了土壤剖面模拟精度，得到了较为准确的同化值。并且引入遥感数据对各深度土壤含盐量的同化作用随着深度的增加而减小，0 ~ 20 cm 土壤含盐量的同化模拟优于 20 ~ 40 cm，40 ~ 60 cm 最差。

2.3　区域数据同化方案

本研究开展区域尺度的不同深度土壤含盐量集合卡尔曼滤波数据同化模拟，在不同采样时间，基于区域尺度的实测值、反演值、模拟值以及同化值，通过 r 和 NER 计算它们与实测值之间的误差，以 2019 年 6 月 15 日为例，由表 5 可知，在 3 个深度上，模拟值的精度随着深度的增加而减小，表明 HYDRUS - 1D 模型对于 0 ~ 20 cm 的土壤含盐量模拟精度较高，而 20 ~ 40 cm、40 ~ 60 cm 的土壤含盐量模拟精度相对较差。在 3 个深度上，反演值的精度随着深度的增加而减少，表明岭回归法模型对 0 ~ 20 cm 的土壤含盐量反演精度最高，20 ~ 40 cm 反演精度次之，40 ~ 60 cm 深度最差，但是 20 ~ 40 cm、40 ~ 60 cm 反演值的 r 和 NER 均较大，它们的模型反演精度较高。在 3 个深度上，同化值的同化精度随着深度的增加而降低，表明区域尺度的集合卡尔曼滤波数据同化方案对于 0 ~ 20 cm 土壤含盐量的同化效果最好，高于 0 ~ 20 cm 的反演值和模拟值。与 0 ~ 20 cm 相比，20 ~ 40 cm 和 40 ~ 60 cm 同化值的 r 和 NER 相对较差，但仍优于同一深度的反演值和模拟值。它们的 r 和 NER 都是随着深度的增加而减小，表明 0 ~ 20 cm 同化值、反演值、模拟值的精度均为最高，它们在 20 ~ 40 cm 精度相对较差，在 40 ~ 60 cm 精度最差。在同一深度上，同化值与实测值的误差最小，其 r 为 0.94 ~ 0.97，NER 为 0.61 ~ 0.69，反演值的精度次之，其与同化值的 r 相差较小，其 NER 为 0.31 ~ 0.35，模拟值与实测值的误差最大，其 r 为 0.65 ~ 0.72。在 3 个深度上，反演值和同化值的 NER 均大于 0，并且同化值远高于反演值，表明区域尺度的集合卡尔曼滤波数据同化方案把遥感数据引入 HYDRUS - 1D 模型中，能较好地监测区域尺度每个深度的土壤含盐量。

表 5　区域尺度不同深度土壤含盐量模拟值、反演值、同化值与实测值的误差分析

Tab. 5　Error analysis of simulated values, inversion values, assimilation values and measured values of soil salinity at different depths in regional scale

土层深度/cm	相关系数 r			归一化还原误差指数 NER	
	模拟值	反演值	同化值	反演值	同化值
0 ~ 20	0.712	0.823	0.969	0.341	0.685
20 ~ 40	0.685	0.813	0.955	0.320	0.626
40 ~ 60	0.657	0.806	0.940	0.312	0.613

故基于集合卡尔曼滤波同化算法开展区域尺度的数据同化研究，使得在区域尺度上，同化值优于反演值和模拟值，能更好地模拟区域尺度时间序列上

不同深度土壤含盐量时空变化，从而更加接近实际情况。

以 2019 年 6 月 15 日为例，不同深度土壤含盐量同化图如图 5 所示。

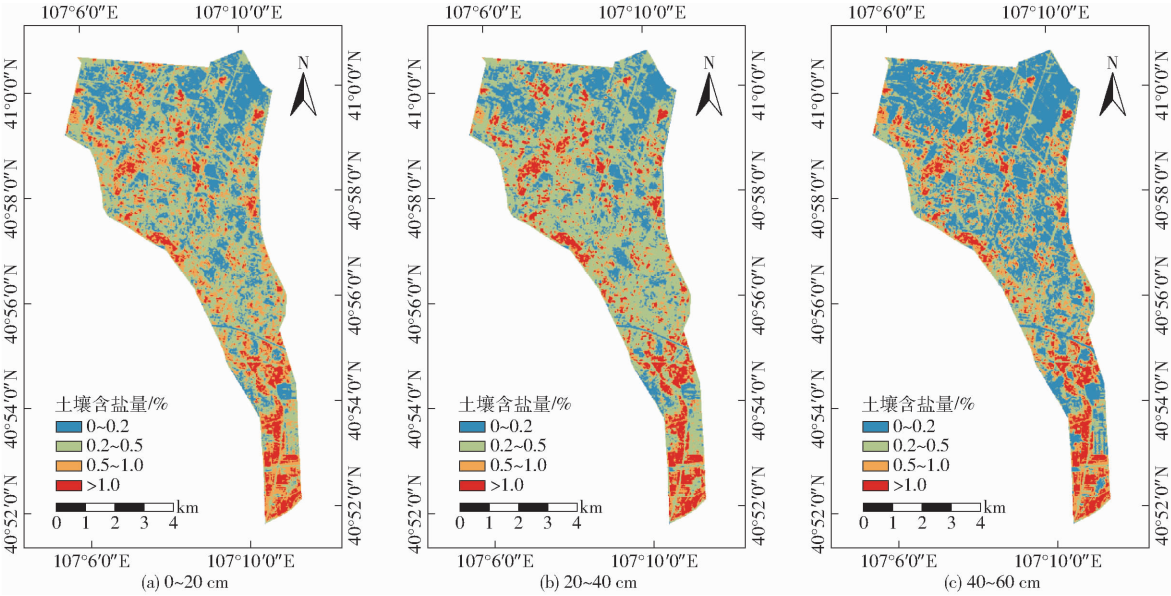

图 5 不同深度土壤含盐量同化图

Fig. 5 Assimilation maps of soil salinity at different depths

3 讨论

在单点尺度上，与不同深度的模拟值和反演值相比，同化值与实测值更为接近，这是因为基于集合卡尔曼滤波同化算法把遥感数据同化到 HYDRUS－1D 模型中，提高了土壤剖面模型模拟精度，得到了更为准确的同化值，使得同化值与实测值的误差最小。同化精度随着深度的增加而减小，0～20 cm 同化效果最好，20～40 cm 次之，40～60 cm 最差。本研究探究了集合数对单点尺度集合卡尔曼滤波数据同化方案的敏感性，结果表明集合数对同化模拟过程较为敏感，在各深度上均表现为随着集合数的增加，RMSE 先大幅度降低，而 EFF 和 NER 则是先大幅度增加，然后达到相对稳定，故最佳的集合数为 50，既能保证同化精度，又能提高同化运算效率。此外，还可以从同化频率[30]、观测误差[31]和引入不同深度的实测数据[32]等方面对数据同化方案进行敏感性分析，找到对数据同化方案的较为敏感性因素。

在区域尺度上，各深度的同化值与实测值的 r 均达到 0.94 以上，高于反演值和模拟值，并且各深度同化值的 NER 均在 0.61 以上，皆为正值，表明本研究能较好地应用于区域尺度的同化模拟，得到较为准确的时间序列区域尺度土壤含盐量时空变化信息。在区域尺度的集合卡尔曼滤波数据同化方案中，同化精度最好的深度为 0～20 cm，其次是 20～40 cm，40～60 cm 最差，与单点尺度数据同化方案的结论一致。这是因为随着深度的增加，HYDRUS－1D 模型的输入数据等对 20～40 cm、40～60 cm 土壤含盐量模拟的作用较小，导致它们与实测值的误差随着深度的增加而增加，并且岭回归法模型的反演精度随着深度的增加，也随之降低，在二者作用下，同化精度表现为随着深度的增加而降低。

本研究通过集合卡尔曼滤波同化遥感反演和模型模拟的土壤含盐量，开展区域尺度的不同深度土壤含盐量数据同化研究，有效地提高了时间序列的区域尺度土壤剖面含盐量模拟精度。一方面模型模拟弥补了遥感数据的不连续性问题，另一方面同化遥感数据可以提高模型模拟精度，但是同化结果仍存在误差，主要来源于遥感反演模型、HYDRUS－1D 模型数据的不确定性和同化算法带来的误差。本研究使用的遥感反演模型为统计回归模型，未来研究可以采用机器学习模型提高遥感监测的精度[33]，把遥感数据引入到 HYDRUS－1D 模型中，对区域尺度的各深度土壤含盐量进行同化模拟，从而提高同化精度。在 HYDRUS－1D 模型中，土壤水力特征参数、溶质运移参数等都会对同化结果产生较大的影响。因此，为提高同化精度，不仅需提高反演模型精度，也需提高模型参数的精度，从而更为准确地监测区域尺度各深度土壤含盐量的时空变化，使同化结果更具有可靠性。

本研究只考虑了土壤含盐量作为状态变量，在开展区域尺度的同化模拟时，尚未考虑其他状态变量随时间变化的特性是否会对同化结果造成一定影响。因此，今后研究可以探讨多状态变量的数据同

化方案，如同时同化状态变量和模型参数[34-35]，进一步准确地提高区域尺度土壤含盐量的同化精度，或是将来基于遥感数据与盐分运移模型的数据同化研究重点。此外，单一的同化算法仍存在一定的局限性，结合多种不同类型的同化算法，如集合-变分数据同化算法[36-37]，发展基于遥感数据的耦合多种同化算法的数据同化方案，或是未来利用数据同化方法获取大面积土壤含盐量时空信息的一个重要研究方向。并且，植被覆盖和人工作业等影响含盐量因素也是本研究考虑不足的地方。在植被覆盖阶段，遥感反演受植被覆盖度、土壤质地、作物种类等多种因素的影响，从而导致同化精度的降低。对于人工作业，如灌溉等，对土壤含盐量造成淋洗，同时它具有局部、粗化效应，从而对同化结果造成一定的影响。上述不足有待进一步深入研究。

4　结论

（1）在进行遥感反演时，各深度岭回归法模型的 R^2 均达到 0.64 以上，RE 在 0.14 以上，反演精度较好，能得到比较准确的不同深度土壤含盐量遥感反演值。

（2）基于单点尺度的数据同化方案最佳集合数为 50，不同深度土壤含盐量同化值的 RMSE 均小于 0.011%、EFF 均大于 0.8、NER 均大于 0.6，优于反演值和模拟值，表明单点尺度集合卡尔曼滤波数据同化方案能提高土壤剖面含盐量模型模拟精度。

（3）在区域尺度的不同深度土壤含盐量集合卡尔曼滤波数据同化方案中，不同深度土壤含盐量同化值与实测值的相关性较强，r 均为 0.94 以上，NER 均为 0.61 以上，能较好地模拟在时间序列上区域尺度的不同深度土壤含盐量时空变化趋势。

（4）集合卡尔曼滤波数据同化方案在单点尺度和区域尺度上，对 3 个深度的土壤含盐量进行数据同化，均取得较好的同化效果。对比 3 种不同深度同化结果可知，同化效果最佳的是 0 ~ 20 cm，其次是 20 ~ 40 cm，40 ~ 60 cm 最差。

参　考　文　献

[1]　REN D, WEI B, XU X, et al. Analyzing spatiotemporal characteristics of soil salinity in arid irrigated agro-ecosystems using integrated approaches[J]. Geoderma, 2019, 356: 113935.

[2]　张智韬，韩佳，王新涛，等. 基于全子集-分位数回归的土壤含盐量反演研究[J]. 农业机械学报, 2019, 50(10): 142-152.
ZHANG Zhitao, HAN Jia, WANG Xintao, et al. Soil salinity inversion based on subsets-quantile regression model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(10): 142-152. (in Chinese)

[3]　LIU Y, ZHANG F, WANG C, et al. Estimating the soil salinity over partially vegetated surfaces from multispectral remote sensing image using non-negative matrix factorization[J]. Geoderma, 2019, 354: 113887.

[4]　KANZARI S, NOUNA B B, MARIEM S B, et al. Hydrus-1D model calibration and validation in various field conditions for simulating water flow and salts transport in a semi-arid region of Tunisia[J]. Sustainable Environment Research, 2018, 28(6): 350-356.

[5]　黄健熙，高欣然，黄海，等. 基于 MODIS 与 WOFOST 模型同化的区域冬小麦成熟期预测[J]. 农业机械学报, 2019, 50(9): 186-193.
HUANG Jianxi, GAO Xinran, HUANG Hai, et al. Regional winter wheat maturity date prediction based on MODIS and WOFOST model data assimilation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(9): 186-193. (in Chinese)

[6]　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)

[7]　王泽人，马荣华，段洪涛，等. 基于集合卡尔曼滤波的太湖叶绿素 a 浓度同化试验系统设计及实现[J]. 中国科学院大学学报, 2013, 30(5): 628-636.
WANG Zeren, MA Ronghua, DUAN Hongtao, et al. Design and implementation of an experimental data assimilation system for chlorophy-a lake based on the ensemble Kalman fliter[J]. Journal of University of Chinese Academy of Sciences, 2013, 30(5): 628-636. (in Chinese)

[8]　黄健熙，李昕璐，刘帝佑，等. 顺序同化不同时空分辨率 LAI 的冬小麦估产对比研究[J]. 农业机械学报, 2015, 46(1): 240-248.
HUANG Jianxi, LI Xinlu, LIU Diyou, et al. Comparison of winter wheat yield estimation by sequential assimilation of different spatio-temporal resolution remotely sensed LAI datasets[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(1): 240-248. (in Chinese)

[9]　解毅，王鹏新，李俐，等. 应用粒子滤波同化条件植被温度指数的土壤水分估测[J]. 干旱地区农业研究, 2018, 36(3): 236-243.
XIE Yi, WANG Pengxin, LI Li, et al. Soil moisture estimation by using particle filter assimilatied conditional vegetation temperature index[J]. Agricultural Research in the Arid Areas, 2018, 36(3): 236-243. (in Chinese)

[10]　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)

[11] 朱鹤, 赵红莉, 蒋云钟. 基于 Noah LSM 的河套灌区土壤含水量同化研究[J]. 科学技术与工程, 2016, 16(10): 102-108.
ZHU He, ZHAO Hongli, JIANG Yunzhong. Research on soil moisture assimilation based on Noah LSM in Hetao Irrigation District[J]. Science Technology and Engineering, 2016, 16(10): 102-108. (in Chinese)

[12] 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 distribute based remote sensing and its effect on crop growth in Hetao irrigation district[J]. Transactions of the CSAE, 2018, 34(1): 102-109. (in Chinese)

[13] ZHANG J, ZHANG Z, CHEN J, et al. Estimating soil salinity with different fractional vegetation cover using remote sensing [J]. Land Degradation and Development, 2020, 32(2): 597-612.

[14] 姚志华, 陈俊英, 张智韬, 等. 覆膜对无人机多光谱遥感反演土壤含盐量精度的影响[J]. 农业工程学报, 2019, 35(19): 89-97.
YAO Zhihua, CHEN Junying, ZHANG Zhitao, et al. Effect of plastic film milching soil salinity inversion by using UAV multispectral remote sensing[J]. Transactions of the CSAE, 2019, 35(19): 89-97. (in Chinese)

[15] SCUDIERO E, SKAGGS T, CORWIN D L. Regional scale soil salinity evaluation using Landsat 7, western San Joaquin Valley, California, USA[J]. Geoderma Regional, 2014, 2-3: 82-90.

[16] 张智韬, 魏广飞, 姚志华, 等. 基于无人机多光谱遥感的土壤含盐量反演模型研究[J]. 农业机械学报, 2019, 50(12): 151-160.
ZHANG Zhitao, WEI Guangfei, YAO Zhihua, et al. Soil salt inversion model based on UAV multispectral remote sensing[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 151-160. (in Chinese)

[17] CHO K H, BEON M S, JEONG J C. Dynamics of soil salinity and vegetation in a reclaimed area in Saemangeum, Republic of Korea[J]. Geoderma, 2018, 321: 42-51.

[18] 冯娟, 丁建丽, 杨爱霞, 等. 干旱区土壤盐渍化信息遥感建模[J]. 干旱地区农业研究, 2018, 36(1): 266-273.
FENG Juan, DING Jianli, YANG Aixia, et al. Remote sensing modeling of soil salinization information in arid areas[J]. Agricultural Research in the Arid Areas, 2018, 36(1): 266-273. (in Chinese)

[19] 毛海颖, 冯仲科, 巩垠熙, 等. 多光谱遥感技术结合遗传算法对永定河土壤归一化水体指数的研究[J]. 光谱学与光谱分析, 2014, 34(6): 1649-1655.
MAO Haiying, FENG Zhongke, GONG Yinxi, et al. Research of soil normalized different water index(NDWI) of Yongding River based on multispectral remote sensing technology combined with genetic algorithm[J]. Spectroscopy and Spectral Analysis, 2014, 34(6): 1649-1655. (in Chinese)

[20] YANG W, KOBAYASHI H, WANG C, et al. A semi-analytical snow-free vegetation index for improving estimation of plant phenology in tundra and grassland ecosystems[J]. Remote Sensing of Environment, 2019, 228: 31-44.

[21] 奚雪, 赵庚星, 高鹏, 等. 基于 Sentinel 卫星及无人机多光谱的滨海冬小麦种植区土壤盐分反演研究——以黄三角垦利区为例[J]. 中国农业科学, 2020, 53(24): 5005-5016.
XI Xue, ZHAO Gengxing, GAO Peng, et al. Inversion of soil salinity in coastal winter wheat growing area based on Sentinel satellite andunmanned aerial vehicle multi-spectrum—a case study in Kenli district of the Yellow River delta[J]. Scientia Agricultura Sinica, 2020, 53(24): 5005-5016. (in Chinese)

[22] 王国帅, 史海滨, 李仙岳, 等. 基于 HYDRUS-1D 模型的荒漠绿洲水盐运移模拟与评估[J]. 农业工程学报, 2021, 37(8): 87-98.
WANG Guoshuai, SHI Haibin, LI Xianyue, et al. Simulation and evaluation of soil water and salt transport in desert oases of Hetao Irrigation District using HYDRUS-1D model[J]. Transactions of the CSAE, 2021, 37(8): 87-98. (in Chinese)

[23] ALLEN R G, PEREIRA L S, RAES D, et al. Crop evapotranspiration. guidelines for computing crop water requirements[M]. Rome: FAO Irrigation and Drainage Paper 56, 1998.

[24] 廖海, 栗现文, 陈俊英, 等. 原状盐渍土不同盐分含量对土壤水分特征曲线的影响[J]. 节水灌溉, 2021(1): 7-13.
LIAO Hai, LI Xianwen, CHEN Junying, et al. Effect of different salt contents of undistured saline soil on soil moisture characteristic curves[J]. Water Saving Irrigation, 2021(1): 7-13. (in Chinese)

[25] XU X, HUANG G, SUN C, et al. Assessing the effects of water table depth on water use, soil salinity and wheat yield: searching for a target depth for irrigated areas in the upper Yellow River basin[J]. Agricultural Water Management, 2013, 125(7): 46-60.

[26] 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. Estimational 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)

[27] 韩旭军, 李新. 非线性滤波方法与陆面数据同化[J]. 地球科学进展, 2008(8): 813-820.
HAN Xujun, LI Xin. Review of the nonlinear filters in the land data assimilation[J]. Advances in Earth Science, 2008(8): 813-820. (in Chinese)

[28] 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 improve simulation accuracy of soil moisture by using HYDRUS-1D model[J]. Transactions of the CSAE, 2019, 35(17): 79-86. (in Chinese)

[29] YANG H, XIONG L, LIU D, et al. High spatial resolution simulation of profile soil moisture by assimilating multi-source remote-sensed information into a distributed hydrological model[J]. Journal of Hydrology, 2021, 597: 126311.

[30] HE L, JIANG Z W, CHEN Z X, et al. Assimilation of temporal-spatial leaf area index into the CERES－Wheat model with ensemble Kalman filter and uncertainty assessment for improving winter wheat yield estimation[J]. Journal of Integrative Agriculture, 2017, 16(10): 2283－2299.
[31] 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)
[32] 刘昭，周艳莲，居为民，等. 基于集合卡尔曼滤波同化方法的农田土壤水分模拟[J]. 应用生态学报，2011，22(11)：2943－2953.
LIU Zhao, ZHOU Yanlian, JU Weimin, et al. Simulation of cropland soil moisture based on an ensemble Kalman filter[J]. Chinese Journal of Applied Ecology, 2011, 22(11): 2943－2953. (in Chinese)
[33] 冯文哲，王新涛，韩佳，等. 基于卫星和无人机遥感数据尺度转换的土壤盐渍化监测研究[J]. 节水灌溉，2020(11)：87－93,104.
FENG Wenzhe, WANG Xintao, HAN Jia, et al. Research on soil salinization monitoring based on scale conversion of satellite and UAV remote sensing data[J]. Water Saving Irrigation,2020(11): 87－93,104. (in Chinese)
[34] 刘卓，李志杰，胡柳明，等. 基于集合卡尔曼滤波的湖泊富营养化模型 Delft3D－BLOOM 数据同化[J]. 湖泊科学，2017，29(5)：1070－1083.
LIU Zhuo, LI Zhijie, HU Liuming, et al. Ensemble Kalman filter based data assimilation in the Delft3D－BLOOM lake eutrophication model[J]. Journal of Lake Sciences, 2017, 29(5): 1070－1083. (in Chinese)
[35] 褚楠，黄春林，杜培军. 基于双 EnKF 的土壤水分与土壤属性参数同时估计[J]. 遥感技术与应用，2016，31(2)：214－220.
CHU Nan, HUANG Chunlin, DU Peijun. State and parameter estimation in soil moisture data assimilation based on dual ensemble Kalman filter[J]. Remote Sensing Technology and Application, 2016, 31(2): 214－220. (in Chinese)
[36] 熊春晖，张立凤，关吉平，等. 集合-变分数据同化方法的发展与应用[J]. 地球科学进展，2013，28(6)：648－656.
XIONG Chunhui, ZHANG Lifeng, GUAN Jiping, et al. Development and application of ensemble－variational data assimilation methods[J]. Advances in Earth Science, 2013, 28(6): 648－656. (in Chinese)
[37] YANG E G, KIM H M. A comparison of variational, ensemble-based, and hybrid data assimilation methods over East Asia for two one-month periods[J]. Atmospheric Research, 2021, 249: 105257.

(上接第 140 页)
[23] 闫银发，孟德兴，宋占华，等. 槽轮式补饲机颗粒动力学数值模拟与试验[J]. 农业机械学报，2016，47(增刊)：249－253.
YAN Yinfa, MENG Dexing, SONG Zhanhua, et al. Particle kinetic simulation and experiment for flute-wheel feeding machine [J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(Supp.): 249－253. (in Chinese)
[24] 彭飞，王红英，方芳，等. 基于注入截面法的颗粒饲料离散元模型参数标定[J]. 农业机械学报，2018，49(4)：140－147.
PENG Fei, WANG Hongying, FANG Fang, et al. Calibration of discrete element model parameters for pellet feed based on injected section method[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(4): 140－147. (in Chinese)
[25] 廖宜涛，廖庆喜，周宇，等. 饲料油菜薹期收获茎秆破碎离散元仿真参数标定[J]. 农业机械学报，2020，51(6)：73－82.
LIAO Yitao, LIAO Qingxi, ZHOU Yu, et al. Parameters calibration of discrete element model of fodder rape crop harvest in bolting stage[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(6): 73－82. (in Chinese)
[26] 向伟，吴明亮，吕江南，等. 基于堆积试验的黏壤土仿真物理参数标定[J]. 农业工程学报，2019，35(12)：116－123.
XIANG Wei, WU Mingliang, LÜ Jiangnan, et al. Calibration of simulation physical parameters of clay loam based on soil accumulation test[J]. Transactions of the CSAE, 2019, 35(12): 116－123. (in Chinese)
[27] CHEN Z P, WASSGREN C, VEIKLE E, et al. Determination of material and interaction properties of maize and wheat kernels for DEM simulation[J]. Biosystems Engineering, 2020, 195: 208－226.
[28] CAULKIN R, TIAN W, PASHA M, et al. Impact of shape representation schemes used in discrete element modelling of particle packing[J]. Computers & Chemical Engineering, 2015, 76: 160－169.
[29] 温翔宇，袁洪方，王刚，等. 颗粒肥料离散元仿真摩擦因数标定方法研究[J]. 农业机械学报，2020，51(2)：115－122，142.
WEN Xiangyu, YUAN Hongfang, WANG Gang, et al. Calibration method of friction coefficient of granular fertilizer by discrete element simulation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 115－122, 142. (in Chinese)
[30] 杨贵，许建宝，刘昆林. 粗粒料颗粒破碎数值模拟研究[J]. 岩土力学，2015，36(11)：3301－3306.
YANG Gui, XU Jianbao, LIU Kunlin. Numerical simulation of particle breakage of coarse aggregates[J]. Rock & Soil Mechanics, 2015, 36(11): 3301－3306. (in Chinese)
[31] 蔡改贫，肖洪力，郭进山，等. 基于多尺度内聚颗粒模型的挤压分级破碎研究[J]. 岩石力学与工程学报，2018，37(增刊)：3557－3567.
CAI Gaipin, XIAO Hongli, GUO Jinshan, et al. Research on extrusion rushing based on multi-scale cohesive particle model [J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(Supp.): 3557－3567. (in Chinese)