

长江科学院院报 Journal of Yangtze River Scientific Research Institute ISSN 1001-5485,CN 42-1171/TV

《长江科学院院报》网络首发论文

题目:	基于天地协同与深度学习的灌区地下水位模拟研究
作者:	陈文龙,杨云丽,张煜,胡祖康
收稿日期:	2022-01-18
网络首发日期:	2022-06-18
引用格式:	陈文龙,杨云丽,张煜,胡祖康.基于天地协同与深度学习的灌区地下水位
	模拟研究[J/OL]. 长江科学院院报.

https://kns.cnki.net/kcms/detail/42.1171.tv.20220615.0900.010.html



www.cnki.net

网络首发:在编辑部工作流程中,稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶 段。录用定稿指内容已经确定,且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期 刊特定版式(包括网络呈现版式)排版后的稿件,可暂不确定出版年、卷、期和页码。整期汇编定稿指出 版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出 版管理条例》和《期刊出版管理规定》的有关规定;学术研究成果具有创新性、科学性和先进性,符合编 辑部对刊文的录用要求,不存在学术不端行为及其他侵权行为;稿件内容应基本符合国家有关书刊编辑、 出版的技术标准,正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。 为确保录用定稿网络首发的严肃性,录用定稿一经发布,不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认:纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约,在《中国 学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版,以单篇或整期出版形式,在印刷 出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出 版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z),所以签约期刊的网络版上网络首 发论文视为正式出版。 doi:10.11988/ckyyb.20220061

基于天地协同与深度学习的灌区地下水位 模拟研究

陈文龙¹,杨云丽¹,张 煜²,胡祖康³

(1. 江苏省规划设计集团有限公司,南京 210036,2. 长江科学院 农业水利研究所,武汉 430010,3. 河海大学 计算机与信息学院,南京 210024)

摘 要:本文利用灌区地面和遥感的天地协同序列观测数据,以降水、土壤湿度、地下水位历史观测量、哨兵-2 遥感观测值作为地下水位的模拟因子,采用基于多层 GRU 网络的深度学习模型建立地面和遥感观测因子与地下水 位的内在联系,进行灌区地下水位模拟的研究,并在南北方两处灌区研究区进行地下水位模拟实验和结果分析。 实验结果表明,基于天地协同与深度学习的灌区地下水位模拟模型具有自行建立外界环境因素和灌区地下水位内 在关系的能力,具有较好的地下水位模拟效果,以及在不同地理环境下的模型适用性,具有一定的应用潜力,能 够为灌区的农作物种植和水资源管理提供决策信息支持。

关键词:地下水位模拟;深度学习;天地协同;灌区 分类号: P641; TP181

Research on the Simulation of Groundwater Level in Irrigation Area Based on Sky-Earth Cooperation and Deep Learning

CHEN Wen-long¹, YANG Yun-li¹, ZHANG Yu², HU Zu-kang³

(1. Jiangsu Planning and Design Group Co., Ltd., Nanjing 210036, China; 2. Changjiang River Scientific
 Research Institute, Agricultural Water Conservancy Department, Wuhan 430010, China; 3. School of Computer and Information, Hehai University, Nanjing 210024, China)

Abstract: In this paper, using the sequential observation data of ground and remote sensing in the irrigation area, a deep learning model based on multi-layer GRU network is constructed to simulate the groundwater level in the irrigation area, and the groundwater level simulation experiment and result analysis are carried out in two irrigation areas in the South and North China. The experiment results show that the groundwater level simulation model of irrigation area based on sky-earth cooperation and deep learning can establish the internal relationship between external environmental factors and groundwater level of irrigation area, having good groundwater level simulation effect, geographical environment applicability and certain application potential, and can provide decision-making information support for crop planting and water resources management in irrigation area. **Keywords:** groundwater level simulation; deep learning; sky-earth cooperation; irrigation area

收稿日期: 2022-01-18 ;修回日期: 2022-04-02

基金项目: 国家重点研发计划(2018YFC1508302)

作者简介:陈文龙(1989-),男,四川绵阳人,工程师,硕士,研究方向为空间信息与机器学习。E-mail: cowerling@163.com

通信作者:张 煜(1971-),男,湖北武汉人,教授级高级工程师,博士,研究方向为摄影测量与遥感。**E-mail:** zhangyu_1999@126.com

1. **研究背景**

农作物的生长情况与地下水位的变化存在着直 接的依存关系^[1],地下水位是农作物需水规律确定 和灌区灌溉管理的重要基础数据^[2],准确掌握灌区 地下水位情况并进行预测,是灌区对灾害做出有效 防范、高效利用灌溉水资源和可持续农业发展的有 效辅助手段。国内外学者针对灌区地下水位预测的 问题,开展了一定的研究: Mao 等人^[3]利用 MODFLOW 建模预测了不同灌溉方式下太行山麓 灌溉地区地下水位的变化情况:管孝艳^[4]根据河套 灌区沙壕渠灌域的地下水埋深、降雨、蒸发及引水 量资料,基于多变量时间序列 CAR 模型建立了地下 水埋深的预测模型和验证;管新建等人^[5]利用 BP 神经网络模型来对河套灌区义长灌域的地下水位埋 深进行了预测;范庆来等人^[6]采用自适应 MGM(1, n)模型—多变量灰色预测模型来描述某井灌水稻地 区地下水动态变化趋势并进行预测; Emamgholizadeh^[7]以降雨量、灌溉回归水、水井抽 水率等作为输入因子,分别利用人工神经网络和自 适应神经模糊系统对伊朗巴斯塔姆平原农业区的地 下水位进行了预测。此外,遥感作为一种大范围地 理信息获取手段,也有学者利用遥感技术进行地下 水的相关研究,罗浩^[8]利用 MODIS 遥感数据,通过 温度植被干旱指数和表观热惯量法,建立了反演地 下水埋深的线性方程,评价了反演效果; Groeneveld 等人^[9]利用遥感反演植被指数(NDVI),对碱灌木 植被蒸散量进行评估,研究长时期的地下水位变化; 史晓亮等人^[10]利用长时间序列的 MODIS 遥感数 据,反演干旱地区的土壤含水量,并结合地下水 位实测数据对干旱区域的地下水位变化进行了分 析。近年来,以深度学习为突出代表的人工智能 技术的快速发展以及在水利、气象、国土等各领 域的广泛应用[11-14],为灌区地下水位预测展示了新 的探索方向。本文以灌区地下水位相关的遥感和地 面观测因素为数据驱动,选取了降水、土壤湿度、 地下水位历史观测量、哨兵-2遥感观测值作为反映 灌区地下水位变化的模拟因子,结合时间序列预测 深度学习模型,对灌区地下水位的准确模拟进行研 究,并在安徽利辛和湖北潜江两个农业灌区研究区 进行地下水位预测的实验以验证本研究的有效性。

2. 灌区地下水位模拟模型

2.1. 地下水位模拟的地面和遥感观测因子

灌区地下水的动态变化是一个相当复杂的水文 过程,其受到区域地质条件、水文气候、人工影响 等多方面因素的影响,而且还与灌区类型和灌溉方 式密切相关^[15,16]。这些环境因素对于地下水位的影 响程度强弱不同,需要选择一定范围内的外界观测 因子作为地下水位的模拟特征,确定模拟特征有利 于降低模型参数维度以及避免过拟合问题,进而提 高地下水位模型预测的准确性^[17]。

农业灌区是一种半人工的生态系统,其必然受 到自然环境和人类活动的复合影响。对于地下水位 变化的影响因素,学者们也进行了一系列相关研究, 主要关注的影响因素集中在地理环境因素、水文气 象因素、人类活动等方面^[18-21],相关研究表明,地 下水位对降水[22-24]、土壤含水量[25-27]、土地使用和 人类活动[28]具有对应的响应规律和一定的相关性。 结合地面观测具体条件,本文选取降水、土壤湿度、 地下水位历史观测量作为地下水位模拟的地面观测 因子。这三种观测因子是农业水利的常见观测因素, 且能有效反映灌区水量补充情况,与地下水水位的 变化有着内在复杂联系。灌区还存在着周期性的农 业种植和水资源调配,也对地下水位有着复杂且深 刻的影响,比如农作物成长对地下水的消耗、灌溉 对地下水的补充等,这些人类活动属于地理空间广 域范围内的外界环境变化,农业灌区的人类种植活 动会对地下水位造成显著影响[29]。卫星遥感作为一 种周期性的农业监测手段,能够准确快速地获取耕 地农作物类型、生长态势、水量蒸散发等内容^[30-33], 从而有效反映灌区的农业生产情况,而灌区的主要 人类活动即为农业生产活动。本文采用哨兵-2 高分 辨率多光谱卫星遥感影像的观测值作为反映影响灌 区地下水位的人类活动观测因子。哨兵-2分为2A、 2B 两颗互补卫星,影像重访周期为5天,携带有多 光谱成像系统(Multispectral Imaging, MSI),覆盖 有13个光谱波段,空间分辨率为10m、20m和60m。 哨兵-2卫星影像是唯一含有红边范围三个波段的遥 感影像,对于农作物植被的类型和状况监测非常有 效^[34,35],还含有可以用于水体监测的波段^[36],且对 同一地点的重访次数多,适用于灌区农业活动的监 测,其影像波段的情况见表1。

表 1 本研究中的哨兵-2 遥感影像参数[37]

Table 1 S	Specification	of Sentinel-2 in	this Study	
-----------	---------------	------------------	------------	--

波段	波长	作用	
1	442 0 mm (P2A) / 442 2mm (P2D)	海岸/气溶胶波段,用来监测近岸水体和大	
1	445.9nm (S2A) / 442.3nm (S2B)	气中的气溶胶	
2 2 4	496.6nm~(S2A)~/~492.1nm~(S2B)~~560nm~(S2A)~/~559nm~(S2B)~~664.5nm	可回火冲风	
2, 3, 4	(S2A) / 665nm (S2B)	可见几夜夜	
5, 6, 7	703.9nm (S2A) / 703.8nm (S2B) 、740.2nm (S2A) / 739.1nm (S2B) 、782.5nm	在计立国中述95 长测技速健康信息	
	(S2A) / 779.7nm (S2B)	红边池田内顶枝,	
8	835.1nm (S2A) / 833nm (S2B)	近红外波段(宽)	
8A	864.8nm (S2A) / 864nm (S2B)	近红外波段(窄)	
9	945nm (S2A) / 943.2nm (S2B)	水蒸气波段	
10、11、12	1613.7nm (S2A) / 1610.4nm (S2B)、2202.4nm (S2A) / 2185.7nm (S2B)	短波红外波段	

2.2. 基于多层 GRU 网络的深度学习模型

本研究主要探究利用地面和遥感多个地理环境 观测因子的时间序列进行灌区地下水位的模拟预测, 采用深度学习中的门控制循环单元神经网络(Gated Recurrent Unit, GRU)作为地下水位预测深度学习 模型的基础结构。GRU属于机器学习中处理和预测 时序数据的循环神经网络,可较好解决序列预测中 的长期记忆和反向传播中的梯度等问题^[38],在诸多 域的序列预测中已经证明具有较好的作用。GRU的 结构示意如图 1。



图 1 GRU 结构

Fig.1 GRU Structure

图 1 中, x_t 为时刻 t 的输入特征数据, h_{t-1} 为前 一时刻(t-1)的隐含状态, z_t 为更新门输出矩阵, r_t 为 重置门输出矩阵, σ 为 Sigmoid 函数, tanh为双曲 正切函数, 在 GRU 网络中有如下定义:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \tag{1}$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \tag{2}$$

$$\tilde{h}_t = tanh(W_{\tilde{h}} \cdot [r_t * h_{t-1}, x_t])$$
(3)

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \tag{4}$$

其中, W_z为更新门权重矩阵, W_r为重置门权重 矩阵。

因为灌区地下水位变化的影响作用机理较为复杂,为了提升深度学习模型根据因子序列预测地下水位能力,拓展模型对于不同数据情况的适应性,本研究采用多层 GRU 相结合的方式来构建的深度学习模型,深度学习模型层次过少对于数据的内在联系挖掘能力有限,而层次过多则会造成参数过多和训练过拟合的问题,综合平衡下,构建的深度学习模型如图 2。



图 2 地下水位深度学习模型结构

Fig.2 Deep Learning Model Structure for Groundwater

Level Forecasting

如图 2 所示,所构建的深度学习模型由三层基础深度学习网络构成,依次为输出维度 32 的 GRU 网络层、输出维度 64 的 GRU 网络层和一个 FC(Full Connected)全连接层,前两个 GRU 层用于多因子序列的特征学习,发现地下水位与各类外界环境因

子的内在联系,最后的全连接层用于输出预测的地下水位。在地下水位预测深度学习模型中,GRU层数越多可以使模型内在的计算维度越多,提升模型的信息挖掘能力,但是 GRU 层数增多会导致深度学习模型的梯度消失情况明显,许多情况下,当GRU 层数过多,深度学习模型的计算更新变缓和效率显著降低,易使得模型陷入局部最优^[39],故本研究设计的模型使用两层 GRU,同时 GRU 的输出维度过大也会导致模型计算缓慢、超出硬件能力和陷入训练数据过拟合,为避免这些情况,GRU 层的输出维度控制在 64 以下。灌区地下水位预测模型的计算输入数据为一定时刻内连续的多因子观测序列,计算结果为预测的未来时刻地下水位。模型以 MAE

(Mean Absolute Error, 平均绝对误差)作为损失函数评价指标,用于评价模型预测精度,从而进行深度学习网络的权重梯度反向传播和参数调整,其公式如下:

$$MAE = \frac{1}{n} \sum_{i=1}^{n} |\hat{y}_i - y_i|$$
(5)

其中 \hat{y}_i 为预测地下水位, y_i 为实际地下水位, MAE 的值越小,则模型的预测精度越高。

3. **实验与分析**

3.1. 研究区域

本文选择的研究区为国家重点研发计划"农田 涝渍灾害监测预报和减灾技术研究"项目的两处灌 区研究区,分别位于湖北潜江市和安徽利辛县,均 属于重要的粮食生产区域,地下水位的信息对于两 处研究区的农作物生长状况监测和灌溉节水配置都 有着重要作用。潜江研究区属于亚热带季风性湿润 气候,灌区以水稻田为主,降水较为丰富;利辛研 究区为暖温带半湿润季风气候,灌区以旱稻、玉米 田为主,降水适中。两处研究区内各建立有1处灌 区监测站,持续监测所在位置的地下水位、土壤墒 情、降雨等数据(图 3)。



Fig.3 Study area

3.2. **实验数据**

3.2.1 利辛研究区数据

利辛研究区采集的序列数据有: (a) 2020 年 5 月 29 日到 2021 年 12 月 28 日的每小时地下水位观 测数据,其中有效数据 8466 条,占总时刻比例为 60.58%; (b) 2020 年 6 月 5 日到 2021 年 12 月 28 日的每小时地下深度 10cm、20cm、40cm 土壤湿度 观测数据,其中有效数据 11549 条,占总时刻比例 为 82.64%; (c) 2020 年 5 月 26 日到 2021 年 12 月 28 日的每小时降水观测数据,其中有效数据 9221 条,占总时刻比例为 65.98%; (d) 2020 年 5 月 4 日到 2021 年 12 月 25 日的利辛监测站点所在位置的 121 景哨兵-2 遥感影像。利辛研究区地面和遥感的 观测数据序列情况如图 4 所示。



3.2.2 潜江研究区数据

潜江研究区采集的序列数据有: (a) 2020 年 6 月 23 日到 2021 年 12 月 28 日的每小时地下水位观 测数据,其中有效数据 8272 条,占总时刻比例为 62.30%; (b) 2020 年 6 月 23 日到 2021 年 12 月 28 日的每小时地下深度 10cm、20cm、40cm 土壤湿度 观测数据,其中有效数据 8886 条,占总时刻比例为 66.89%; 2020 年 6 月 23 日到 2021 年 12 月 28 日的 每小时降水观测数据,其中有效数据 9359 条,占总 时刻比例为 70.41%; 2020 年 5 月 4 日到 2021 年 12 月 25 日的潜江监测站点所在位置的 120 景哨兵-2 遥感影像。潜江研究区地面和遥感的观测数据序列 情况如图 5 所示。





3.2.3 地面观测数据预处理

对两个研究区的地下水位、降水、土壤墒情地 面观测数据进行数据统计分析,计算每种类型观测 数据序列的中位数和方差,对序列中有显著方差, 且明显偏移中位数或者超过正常数值范围的观测量 认为是异常值,予以剔除。

利用数据拟合插值方法将两个研究区的地面观 测数据中的个别缺失数据进行插值补充。插值方法 采用滑动时间窗口^[40]样条插值方法,以 24 h 为时间 窗口,在时间序列观测数据上,按时间顺序,从开 始到结束时刻,以每小时为步长移动时间窗口。若 时间窗口内存在缺失值,则利用窗口内的有效观测 值进行样条拟合,并求出缺失时间的拟合值作为原 观测数据序列的补充(图 6)。



3.2.4 遥感观测数据预处理

对哨兵-2 影像数据进行大气校正和几何校正, 去除云覆盖区域,以研究区地面监测站的空间位置 为空间掩膜进行栅格提取,获取监测站所在位置的 遥感观测数据。对获取的遥感数据的每一波段进行 如下计算,以得到研究区监测站的哨兵-2遥感观测 代表值。

$$B_i = \frac{B_{i-sum}}{N} \tag{6}$$

其中, B_i为研究区遥感观测数据第 i 波段代表 值, B_{i-sum}为研究区遥感观测数据内有效栅格第 i 波 段值之和, N 为有效栅格个数。

将处理得到的研究区监测站的遥感观测代表值 按照时间进行排序,因哨兵-2的重访周期、云遮挡

7000

6000

5000

4000

3000

2000

1000

0



代表值, **B**_{pre}为 **T** 时刻相邻的上时刻研究区遥感观测代表值, **T** 为缺失数据的时刻。

的影像,并不是每小时都能获得有效的遥感观测代

表值,对缺失的数据采取如下补充方式:

两个研究区通过上述处理方式,获得各自的哨 兵-2 遥感观测代表值的每小时数据,其情况如图 7 所示。



图 7 研究区哨兵-2 遥感观测代表值



3.3. 多特征时间序列深度学习样本集

将每个研究区预处理后的地面观测数据与遥感 观测数据组合,取每种类型数据的时间交集,即将 每种类型数据均存在的一个时刻组合为一个 17 维 的向量样本(地下水位、土壤墒情、降水、哨兵-2 各波段值),并赋予对应的时刻戳,并将所有有效向 量样本形成的时间序列作为该研究区地下水位预测 深度学习模型的多特征时间序列样本数据集。两个 研究区的样本数据集,均存在缺失时间区间,形成 不连续的时间序列样本,其情况如表 2、图 8 所示。

表 2 研究区深度学习样本情况统计

Table 2 Statistics of Deep Learning Samples in

Experimental Area					
研究区	样本数	占总时刻比	开始时间	结束时间	
		例			
利辛	9782	70.00%	2020/5/25	2021/12/28	
潜江	10031	75.55%	2020/6/23	2021/12/28	



Fig.8 Time Distribution of Deep Learning Samples in Experimental Area

3.4. 深度学习模型训练

根据多特征时间序列深度学习样本集的数据情况和深度学习模型训练的要求,样本集选择 70%的序列样本作为深度学习训练集,20%的序列样本为深度学习测试集。三种集合均只含有连续的样本区间,且所有数据根据其自身特征序列进行归一化处理,以便于深度学习模型快速训练,归一化公式如下:



其中, Xⁱ_{origin}为原始样本集某一个维度序列数 据, mean为Xⁱ_{origin}的平均值, std为Xⁱ_m的均方差。 利用本研究所构建地下水预测深度学习模型, 使用上述构建的训练集和验证集,进行深度学习模 型训练。以5个连续时刻的多特征向量样本作为一 个模型训练输入,并将5个时刻的下一个时刻地下 水位作为模型预测结果,即深度学习模型的训练目 标值,模型训练轮数为50轮,两个研究区的地下水 位预测深度学习模型的训练结果如图9所示。





Fig.9 Training of Deep Learning Model for Groundwater Level Prediction in Experimental Area

由训练结果可见,利辛研究区和潜江两个研究 区分别利用来自地面和卫星遥感的历史地下水位、 土壤墒情、降水和哨兵-2 影像的多源观测数据,采 用基于多层 GRU 网络的深度学习模型进行地下水 位的预测应用,大约在训练到 20 多轮时达到模型数 据拟合,模型训练损失 MAE 最小分别可达到 0.01 左右,按照深度学习样本集的归一化参数进行数据 反归一化,可知训练过程中地下水位的预测误差最 低可达到大约在 0.005m 左右,证明了利用地面和遥 感观测数据的深度学习模型对地下水位的预测是具 有可行性的。

2.1 2.45 实际地下水位 实际地下水位 2.075 预测地下水位 预测地下水位 2.05 2.4 地下水位(m) 下水位(m) 王 2.35 2 1.975 2.3 1.95 2021-12-15 2021-12-19 2021-12-23 2021-12-27 2021-12-23 2021-12-27 2021-12-15 2021-12-19 时间 时间 (a) 利辛研究区测试结果 (b) 潜江研究区测试结果 图 10 研究区地下水位预测实验结果

3.5. 灌区地下水位模拟测试

Fig.10 Results of Groundwater Level Prediction in Experimental Area

表 3 研究区地下水位预测误差分析

 Table 3
 Error Analysis of Groundwater Level Prediction

in Experimental Area

研究区	平均绝对误差	均方根误差	R 方值(R2)
	(MAE)	(RMSE)	
利辛	0.003570	0.004586	0.9861
潜江	0.007601	0.009173	0.9631

由两个研究区的地下水位预测实验结果可见, 虽然两个研究区的地理环境各有不同,种植活动也 各有所异,但是地下水位的预测均取得较好的效果, MAE(平均绝对误差)显示总体上实际地下水位与 预测地下水位的误差在 0.005m 左右,而两个研究区 的预测结果的 R2(R 方值)均在 0.95 以上,进一 步说明预测结果与实际情况有着较好的匹配效果。

为了进一步验证基于天地协同与深度学习的灌

为了验证本研究所构建的地下水位预测深度学 习模型的实际效果,分别采用利辛和潜江两个研究 区的最近一段时间观测数据作为测试数据进行模型 效果的验证,其中:(1)利辛研究区的实验数据为 2021年12月13日到2021年12月28日的376个 小时的地面和遥感观测连续序列数据;(2)潜江研 究区的实验数据为2021年12月13日到2021年12 月28日的375个小时的的地面和遥感观测连续序列 数据。将两个研究区的测试数据序列输入对应研究 区训练好的深度学习模型,模型预测出对应时间间 隔下的每小时的地下水位情况,其具体实验效果如 图 10、表3所示。

区地下水位预测模型的预测效果,本研究同时构建 了仅使用地下水历史观测值的单层 GRU 深度学习 模型作为对比模型,在使用相同的训练样本和训练 轮数的条件下,对利辛、潜江两地的测试数据进行 模拟测试,其测试结果如见表4。

表 4 对比模型地下水位预测误差

Table 4	Error A	Analysis of	Groundwater	Level	Prediction
---------	---------	-------------	-------------	-------	------------

of Model				
研究区	平均绝对误差 均方根误差		R 方值(R2)	
	(MAE)	(RMSE)		
利辛	0.011644	0.012245	0.9012	
潜江	0.009732	0.010010	0.9101	

可见在两个灌区试验区,基于天地协同与深度 学习的地下水位预测模型的预测结果均优于仅有地 下水位观测值作为模拟因子的模型。通过上述分析, 利用地面和遥感的同时刻观测序列数据(天地协同), 通过基于多层 GRU 网络的深度学习模型,可以有 效地发掘自然环境和人类活动对灌区的地下水影响 的深层次关联关系,可以自行建立这些外界环境因 素和灌区地下水的内在关系,从而对灌区的地下水 位进行有效准确的序列模拟。

4. 结论

随着现代科学技术的发展,遥感技术、深度学 习技术等现代信息技术在地理环境监测和精确信息 预测等方面具有的显著优点,将其引入到灌区农业 水利的应用,有助于提升灌区管理的现代化、信息 化和决策能力水平。本文研究采用地面监测站与卫 星遥感观测数据相结合的方式,构建灌区天地协同 的观测数据序列,并利用能进行时序分析的多层 GRU深度学习模型对地面和遥感观测因子进行深 层次信息和时序规律挖掘,建立地面和遥感观测因 子与地下水位序列的内在联系,从而实现对灌区地 下水位序列的有效模拟,实验结果表明,基于天地 协同与深度学习的地下水位的模拟具有良好效果, 而且在灌区地理环境、水文气象条件不同的情况下, 本文所构建的深度学习模型仍然有较好的适应性, 可见本研究在灌区地下水位的模拟方面具有一定的 应用潜力。

参考文献(References):

- [1] 刘秀强张阳阳陈喜高满.基于元数据分析的西北干旱 区生态地下水位埋深及其影响因素[J].南水北调与水 利科技(中英文),2020,18(5):9.
- [2] 崔恩贵,张富有,崔京京.人民胜利渠灌区地下水位数 值处理与灰色预测[J].中国水运:下半月,2015(2):4.
- [3] Xuesen, Mao, Jinsheng, et al. A simulation and prediction of agricultural irrigation on groundwater in well irrigation area of the piedmont of Mt. Taihang, North China[J]. Hydrological Processes, 2005,19(10):2071-2084.
- [4] 管孝艳,王少丽,高占义,等.基于多变量时间序列 CAR模型的地下水埋深预测[J].农业工程学报, 2011,27(7):6.
- [5] 管新建, 逯洪波, 徐清山. 基于BP神经网络的区域地下 水位动态预测[J]. 人民黄河, 2006,28(8):3.
- [6] 范庆来, 刘国华, 王军, 等. 地下水位动态变化预测中的MGM(1,n)模型[J]. 农机化研究, 2004(3):165-167.
- [7] Emampholizadeh S, Moslemi K, Karami G. Prediction the Groundwater Level of Bastam Plain (Iran) by Artificial Neural Network (ANN) and Adaptive Neuro-Fuzzy Inference System (ANFIS)[J]. Water Resources

Management, 2014,28(15):5433-5446.

- [8] 罗浩, 王红, 施长惠. 黄河三角洲地区地下水埋深遥感 反演[J]. 国土资源遥感, 2013,25(3):145-152.
- [9] Groeneveld D P. Remotely-sensed groundwater evapotranspiration from alkali scrub affected by declining water table[J]. Journal of Hydrology, 2008,358(3– 4):294-303.
- [10] 史晓亮,周政辉,王馨爽.基于遥感技术的干旱区地下 水监测研究[J].人民黄河,2019,41(7):87-91.
- [11] Zhang Z, Yang X, Li H, et al. Application of a novel hybrid method for spatiotemporal data imputation: A case study of the Minqin County groundwater level[J]. Journal of Hydrology, 2017,553:384-397.
- [12] Wang N, Zhang D, Chang H, et al. Deep learning of subsurface flow via theory-guided neural network[J]. Journal of Hydrology, 2020,584:124700.
- [13] Zhanga J, Yan Z, Zhanga X, et al. Developing a Long Short-Term Memory (LSTM) based model for predicting water table depth in agricultural areas[J]. Journal of Hydrology, 2018,561.
- [14] Wunsch A, Liesch T, Broda S. Forecasting groundwater levels using nonlinear autoregressive networks with exogenous input (NARX)[J]. Journal of Hydrology, 2018,567:743-758.
- [15] 周维博, 曾发琛. 井渠结合灌区地下水动态预报及适宜 渠井用水比分析[J]. 灌溉排水学报, 2006,25(1):4.
- [16] Nurolla Magzum,张彦,张嘉星,等.引黄灌区地下水 动态变化影响因素及种植结构优化分析——人民胜利 渠灌区为例[J].中国农村水利水电,2018(3):6.
- [17] Guyon I, Elisseeff A. An introduction to variable and feature selection[J]. Journal of machine learning research, 2003,3(3):1157-1182.
- [18] Aya B, Fna B, Asba B, et al. Groundwater recharge and water table response to changing conditions for aquifers at different physiography: The case of a semi-humid river catchment, northwestern highlands of Ethiopia[J]. Science of The Total Environment, 2020,748.
- [19] Guo C, Liu T, Niu Y, et al. Quantitative analysis of the driving factors for groundwater resource changes in arid irrigated areas[J]. Hydrological Processes, 2020.
- [20] Korrakoch T, Uma S, Phayom S. The Influence of Climate Variability Effects on Groundwater Time Series in the Lower Central Plains of Thailand[J]. Water, 2018,10(3):290.
- [21] 王晓勇, 朱立峰, 董佳秋, 等. 干旱-半干旱区下垫面变 化对地下水位的影响[J]. 西北地质, 2019,52(2):227-235.
- [22] Yu H, Lin Y. Analysis of space-time non-stationary

patterns of rainfall–groundwater interactions by integrating empirical orthogonal function and cross wavelet transform methods[J]. Journal of Hydrology, 2015,525:585-597.

- [23] 张展羽,梁振华,冯宝平,等. 基于主成分-时间序列模型的地下水位预测[J]. 水科学进展,2017,28(3):6.
- [24] 丁启振,周金龙,杜明亮,等.新疆石河子-昌吉地区 2016—2020年地下水位动态特征分析[J]. 灌溉排水学 报, 2022,41(2):109-117.
- [25] Chen X, Hu Q. Groundwater influences on soil moisture and surface evaporation[J]. Journal of Hydrology, 2004,297(1-4):285-300.
- [26] Jackson T J. Remote sensing of soil moisture: implications for groundwater recharge[J]. Hydrogeology journal, 2002,10(1):40-51.
- [27] 刘景利, 史奎桥, 梁涛, 等. 锦州玉米地地下水位、降水与土壤含水量的关系分析[J]. 安徽农学通报, 2008(20):126-130.
- [28] 秦俊桃.武威盆地不同土地利用类型下的地下水位时空动态分析[J].中国水利水电科学研究院学报, 2014,12(3):287-290.
- [29] Sahoo S, Russo T A, Elliott J, et al. Machine learning algorithms for modeling groundwater level changes in agricultural regions of the U.S.[J]. Water Resources Research, 2017,53(5):3878-3895.
- [30] 王娜,李强子,杜鑫,等.单变量特征选择的苏北地区 主要农作物遥感识别[J].遥感学报,2017,21(4):519-530.

- [32] 唐荣林, 王晟力, 姜亚珍, 等. 基于地表温度——植被指数三角/梯形特征空间的地表蒸散发遥感反演综述[J].
 遥感学报, 2021,25(1):65-82.
- [33] 贾坤,李强子.农作物遥感分类特征变量选择研究现 状与展望[J].资源科学,2013,35(12):2507-2516.
- [34] Nguyen M D, Baezvillanueva O M, Bui D D, et al. Harmonization of Landsat and Sentinel 2 for Crop Monitoring in Drought Prone Areas: Case Studies of Ninh Thuan (Vietnam) and Bekaa (Lebanon)[J]. Remote Sensing, 2020,12(2):281.
- [35] 张东彦, 戴震, 徐新刚, 等. 基于时序Sentinel-2影像的 现代农业园区作物分类研究[J]. 红外与激光工程, 2021,50(5):262-272.
- [36] 刘宇晨, 高永年. Sentinel时序影像的长江流域地表水体提取[J]. 遥感学报, 2022,26(2):358-372.
- [37] 闫丹丹,李静泰,薛媛媛,等.基于Sentinel-2的江苏省 植被生物物理特征反演[J].环境科学学报, 2022,42(1):70-79.
- [39] Ketkar N, Santana E. Deep learning with Python[M]. Springer, 2017.
- [40] Angiulli F, Fassetti F. Detecting distance-based outliers in streams of data[C]//. Sixteenth Acm Conference on Conference on Information & Knowledge Management, 2007.

说明: 该文为经编委会审查通过的录用文章, 由于尚未确定具体刊出日期, 其内容可能与最后的发表版本 稍有差异, 请以最后发表为准。