

# 融合时空注意力机制的土壤湿度预测方法

赫晓慧<sup>1</sup>, 关煜歆<sup>1</sup>, 程浙杰<sup>1</sup>, 孟玉清<sup>2</sup>, 杨松林<sup>2</sup>, 冯跃华<sup>2</sup>

(1. 郑州大学 地球科学与技术学院, 河南 郑州 450001; 2. 河南省豫东水利保障中心, 河南 开封 475000)

**摘要:** [目的] 建立一个模型, 解决现有土壤湿度预测模型在复杂时空动态表征与跨场景样本泛化的协同优化上存在的空间特征挖掘不足, 时间动态建模局限以及数据分布差异适应性弱等问题, 为应对旱涝灾害动态预警, 灌溉资源精准配置以及提升农业抗灾能力提供科学决策引擎。[方法] 提出一种注意力引导的时空特征动态融合土壤湿度预测网络模型 (AGSMP-Net), 模型融合了长短期时空预测网络和“特征-时间-空间”的注意力机制模块, 可以专注于时间序列信息处理与空间分布的变化捕捉, 把握土壤湿度的长期变化趋势, 优化时空维度的信息利用。[结果] 验证了利用气象要素 (降水量、土壤温度) 对土壤湿度预测任务中 AGSMP-Net 模型的可行性。在 2015—2024 年河南省的土壤湿度预测任务中, 与 ConvLSTM 相比, AGSMP-Net 模型精确度 ( $R^2$ ) 高 0.048, 均方根误差 (RMSE) 低 0.012。降水量对土壤湿度模型预测精度有显著影响。[结论] 提出的模型通过时空注意力机制动态分配特征权重, 能够有效捕捉土壤湿度变化的突变响应与稳态趋势, 进而提升土壤湿度预测的精度。

**关键词:** 长时序时空预测; 土壤湿度预测; 注意力机制; 深度学习; ConvLSTM

文献标识码: B

文章编号: 1000-288X(2025)06-0169-12

中图分类号: Q948, S812.2

**文献参数:** 赫晓慧, 关煜歆, 程浙杰, 等. 融合时空注意力机制的土壤湿度预测方法[J]. 水土保持通报, 2025, 45(6): 169-180. He Xiaohui, Guan Yuxin, Cheng Xijie, et al. Soil moisture prediction method integrating spatiotemporal attention mechanism [J]. Bulletin of Soil and Water Conservation, 2025, 45(6): 169-180.

DOI: 10.13961/j.cnki.stbctb.2025.06.009

CSTR: 32312.14.stbctb.2025.06.009

## Soil moisture prediction method integrating spatiotemporal attention mechanism

He Xiaohui<sup>1</sup>, Guan Yuxin<sup>1</sup>, Cheng Xijie<sup>1</sup>, Meng Yuqing<sup>2</sup>, Yang Songlin<sup>2</sup>, Feng Yuehua<sup>2</sup>

(1. School of Earth Sciences and Technology, Zhengzhou University, Zhengzhou, Henan 450001, China; 2. Henan Eastern Water Conservancy Security Center, Kaifeng, Henan 475000, China)

**Abstract:** [Objective] A model will be established to address the issues existing in current soil moisture prediction models, such as insufficient spatial feature mining, limitations in temporal dynamic modeling, and weak adaptability to data distribution differences in the collaborative optimization of complex spatiotemporal dynamic representation and cross-scenario sample generalization. This will provide a scientific decision-making tool for dynamic early warning of drought and flood disasters, precision allocation of irrigation resources, and improved agricultural disaster resistance. [Methods] To address these issues, an attention-guided spatiotemporal feature dynamic fusion network (AGSMP-Net) was proposed. The model integrated a long short term spatiotemporal prediction network with a feature-time-space attention mechanism module, enabling focused processing of time-series information and the capture of spatial distribution variations. It identified the long-term variation trends of soil moisture and optimized the utilization of information across spatiotemporal dimensions. [Results] Experiments validated the feasibility of the AGSMP-Net model in predicting soil moisture using meteorological factors (precipitation and soil temperature). In the soil moisture prediction task for Henan Province from 2015 to 2024, compared to ConvLSTM, AGSMP-Net model improved the accuracy ( $R^2$ ) from 0.758 to 0.806 and reduced the root mean square error (RMSE) from 0.069 to 0.057. Precipitation has a significant effect

收稿日期: 2025-05-08

修回日期: 2025-07-25

采用日期: 2025-07-28

资助项目: 河南省水利科技攻关项目“豫东引黄灌区作物耗水及生长过程信息智能感知关键技术”(GG202250); 国家自然科学基金项目“地表时空异质性干扰下的非平衡复杂场景冬小麦叶面积指数反演”(42371358)

第一作者: 赫晓慧(1978—), 女(汉族), 河南省商丘市人, 博士, 教授, 主要从事高性能遥感计算、遥感反演研究。Email: hexh@zzu.edu.cn。

通信作者: 程浙杰(1995—), 女(汉族), 河南省南阳市人, 博士, 讲师, 主要从事遥感智能解译研究。Email: chengxj@zzu.edu.cn。

on the prediction accuracy of soil moisture model. [Conclusion] The proposed model dynamically allocates feature weights through the spatiotemporal attention mechanism, which can effectively capture both the abrupt responses and steady-state trends in soil moisture variations, thereby improving the accuracy of soil moisture prediction.

**Keywords: long-sequence spatiotemporal prediction; soil moisture prediction; attention mechanism; deep learning; ConvLSTM**

土壤湿度(soil moisture, SM)是气候、水文和生态系统中的关键状态变量,其动态变化是气象条件、地表特征及生物活动等协同作用的结果<sup>[1-6]</sup>。土壤湿度对气象要素(如降水、土壤温度等)有着较为复杂的依赖关系<sup>[7-8]</sup>,如降水量主导土壤水分补给过程,温度通过蒸散发作用调控水分耗散速率等<sup>[9]</sup>。气象要素因其具有明确的物理作用机制以及良好的时间序列连续性,因而常作为土壤湿度预测模型的核心变量<sup>[10-12]</sup>。适宜的土壤湿度对农业生产以及农田灌溉管理等具有重要意义,因而构建土壤湿度精准预测模型,能够精准应对旱涝灾害,提升农业抗灾能力,对保障粮食安全与农业可持续发展具有决定性战略价值<sup>[13]</sup>。

传统的土壤湿度预测包括土壤水动力方法、经验公式法以及统计学方法等<sup>[14]</sup>。经验法简单易行,但其需要大量数据和水动力学方面理论的支撑,在泛用性上存在一定的局限性<sup>[15]</sup>。统计学方法可以较为直接的提取有用信息,速度快且泛用性高,但是其准确性和确定性存在一定的缺陷<sup>[16]</sup>。相较于传统机器学习方法,深度学习模型在特征学习和数据表征方面展现出独特的优势<sup>[17-19]</sup>。土壤湿度预测中的各要素之间存在协同性,某个要素发生变化必然会引起其他要素发生相应变化,长时间序列数据可以帮助更好地提取潜在的长期依赖关系,从而使模型在处理复杂的时间序列模式时表现得更加精确和稳健。在模型架构方面,Li等<sup>[20]</sup>提出的EDT-LSTM模型利用残差学习和中间时序特征融合,增强了长序列预测能力,而Park等<sup>[21]</sup>则通过多深度协同预测框架揭示了土层深度与气象因子的耦合关系。此外,特征工程优化也推动了模型性能提升,例如Jiang等<sup>[22]</sup>提出的PCA-LSTM混合模型通过主成分分析消除特征共线性,使中短期预测稳定性提高22%。

深度学习模型在较长时序预测任务中,存在丢失隐藏状态关键信息的状况。注意力机制的引入可以使模型在处理时间序列时自动计算不同时间步之间的关联度,灵活地的选择和强调当前任务所需的关键信息<sup>[23]</sup>。针对长时序预测中的信息丢失

问题,注意力机制被广泛采用,如车银超团队<sup>[24]</sup>研发的DA-LSTM-soil模型通过自适应加权关键气象要素使预测误差降低约18%,Kara等<sup>[25]</sup>则进一步证明注意力机制与全连接层的结合可显著提升判别性特征提取能力。上述方法在处理长时间跨度的数据时效果不佳,如应用于河南省土壤湿度预测任务时,无法满足特定区域作物轮作制度对土壤湿度记忆效应的影响,进而不能很好地平衡长短期时间步间的依赖关系,忽略了非线性的气象要素信息。

针对以上问题,本研究提出AGSMP-Net模型,该模型包括ConvLSTM网络与时空特征注意力机制模块。其中ConvLSTM网络能够解决土壤湿度受气象条件影响而存在的时空依赖性问题,注意力模块包含特征注意、时间注意以及空间注意,能有效解决土壤湿度预测中的时空依赖性和空间异质性问题,同时能够关注时间序列中的突变时刻,提升模型在复杂环境下的预测精度。

## 1 研究区域与数据

### 1.1 研究区概况

河南省(31°23'—36°22'N, 110°21'—116°39'E),横跨中国第二、三级地貌阶梯过渡带,呈现显著的“西高东低”地形格局,总面积 $1.65 \times 10^6 \text{ km}^2$ 。河南省属暖温带-亚热带、湿润-半湿润季风气候<sup>[26]</sup>,具有四季分明,雨热同期,复杂多样等基本特点。全省0—7 cm层土壤年平均温度为15~17℃,北部略低,南部稍高<sup>[7]</sup>。年降水量主要集中在汛期(6—9月),具有季节分配不均匀、年际变化大的特点<sup>[27]</sup>。2024年土壤湿度全省呈现显著的纬度地带性特征(图1),豫北、豫西及豫中地区土壤湿度相对较低,而豫南、豫东地区则较为湿润<sup>[28]</sup>。这种水分格局与河南省作为国家粮食生产核心区的地位密切相关——黄淮海平原占全省耕地面积的75%以上,支撑着全国重要的冬小麦-夏玉米轮作体系。由于作物关键生育期与降水集中期存在时空错位,精准监测土壤湿度动态对于保障粮食安全具有特殊意义。

### 1.2 数据来源

数据来源于ERA5-Land全球再分析数据集<sup>[29]</sup>。

该数据集采用规则经纬度网格投影,水平覆盖全球,覆盖的时间范围从 1950 年至今,提供逐小时的时间分辨率数据,空间分辨率为  $0.1^\circ$ ,垂直覆盖从地表到 289 cm 的土层深度,垂直分辨率对应 ECMWF 表面模型的 4 个级别(第 1 层:0—7 cm,第 2 层:7—28 cm,第 3 层:28—100 cm,第 4 层:100—289 cm)。ERA5-Land 包含 50 个气候变量,涵盖地表水和能量循环的诸多方面,如温度、降水量、土壤湿度、蒸散发、积雪深度等。本研究数据选用土壤温度、降水量以及土壤湿度 3 个气候变量作为研究影响因子。其中,土壤温度(K)指 0—7 cm 土层温度;降水量(m)指累积降水的平均深度;土壤湿度( $m^3/m^3$ )指 0—7 cm 土层单位体积含水量,数据水平分辨率为  $0.1^\circ \times 0.1^\circ$ ,时间覆盖范围为 2015 年 1 月 1 日至 2024 年 12 月 31 日,时间分辨率为日,数据范围涵盖河南省全域(图 2)。数据获

取自 CDS 官网(<https://cds-beta.climate.copernicus.eu/datasets/reanalysis-era5-land> tab=overview)。

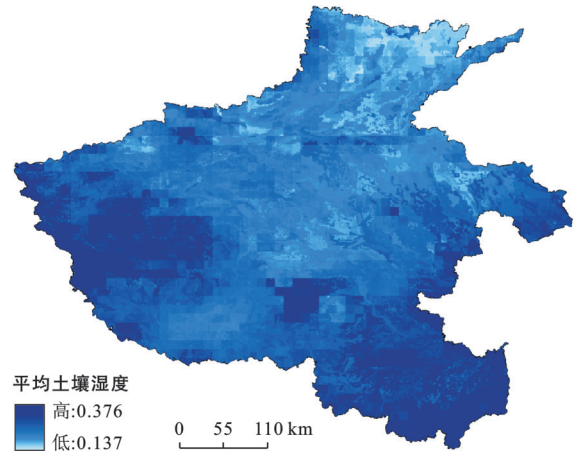


图 1 河南省 2024 年平均土壤湿度空间分布  
Fig.1 Spatial distribution of average soil moisture in Henan Province in 2024

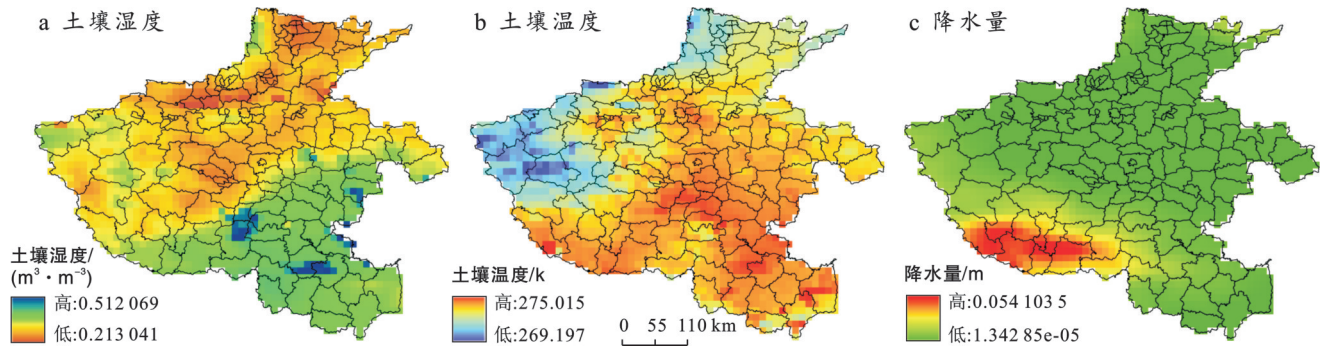


图 2 河南省预测因子数据示例  
Fig.2 Examples of predictor data in Henan Province

本研究使用 2015—2024 年河南省日数据进行建模,并对数据进行预处理,包括异常值检测与过滤、时间重采样、数据划分、归一化、特征和标签分离等。首先,进行异常值检测与过滤,基于地表温度合理范围和统计方法进行筛选,同时对时空突变值如相邻时间步长温度骤变等实施过滤。其次,通过时间重采样对土壤温度、土壤湿度以及降水量数据进行处理,将原始小时数据聚合为日尺度,针对不同变量采用适当的聚合方法,对温度取日均值,对降水取日累计,并采用线性插值处理重采样过程中的短暂缺失。最后,将数据划分为训练集和测试集按照 7:3 的比例进行划分,其中 70% 的数据作为训练集,用于训练预测模型,剩余的 30% 的数据作为测试集,用于验证模型的预测效果。

由于不同特征量之间存在尺度差异,使用线性归一化方法对原始数据进行归一化处理,并获取归一化参数,将不同类别的影响因素映射到相同的范围内,避免因量纲不同导致的结果偏差。线性归一

化的计算公式为

$$x_{norm} = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (1)$$

式中: $x_{max}, x_{min}$  分别为原始数据集中同一因素特征的最大、最小值; $x_i$  为原始数据; $x_{norm}$  为的归一化结果,其值在  $[-1, 1]$  之间。

## 2 研究方法

### 2.1 整体框架

针对土壤湿度预测任务中时空特征挖掘不足的问题,本研究提出了一种注意力引导的时空特征动态融合土壤湿度预测网络模型(attention-guided spatiotemporal feature dynamic fusion moisture prediction network, AGSMP-Net)。该模型包括以下两个部分:

#### 2.1.1 卷积长短期记忆网络基础框架

ConvLSTM 网络作为模型的基础架构,利用网络中卷积与循环结构的融合特性,精准捕捉不同时

间和空间维度下土壤湿度与气象要素的交互关系。

### 2.1.2 时空注意力机制模块

注意力模块细分为特征注意、时间注意以及空间注意3个部分,用于替代传统卷积中的固定权重模

式,动态筛选关键时间特征和空间特征,专注于时间序列信息处理与空间分布的变化捕捉,把握土壤湿度的长期变化趋势,优化时空维度的信息利用。模型的总体架构如图3所示。

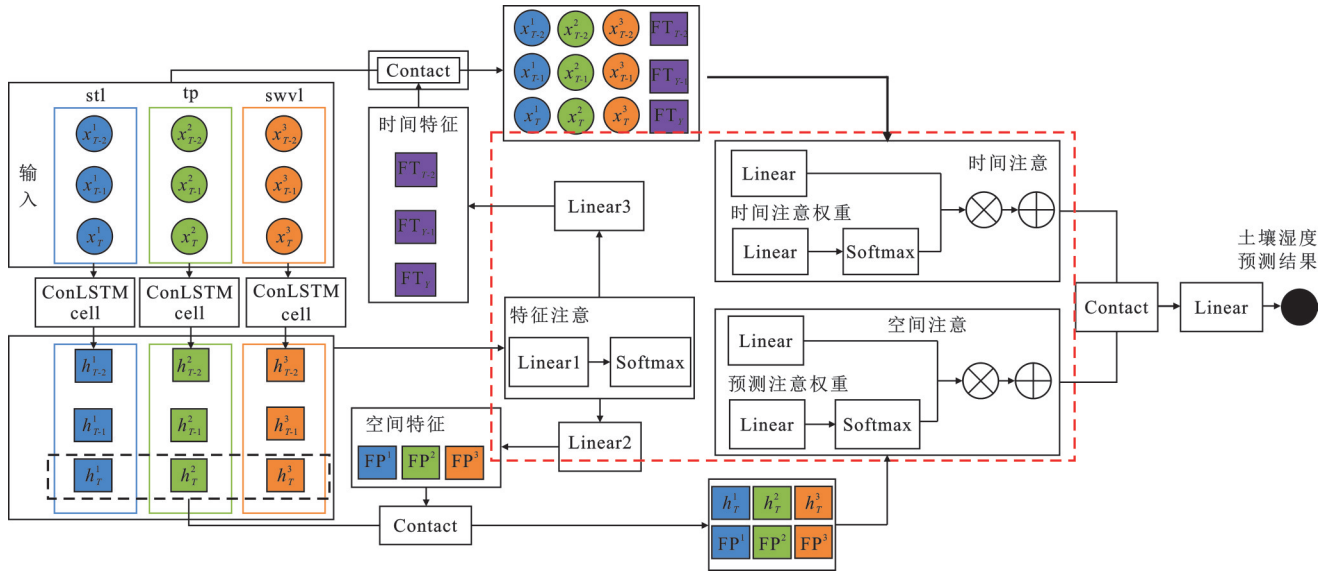


图3 注意力引导的时空特征动态融合土壤湿度预测网络模型总体架构

Fig.3 Overall architecture of attention-guided spatiotemporal feature dynamic fusion moisture prediction network model

## 2.2 土壤湿度时空预测模型

ConvLSTM模型是CNN与LSTM底层结合的卷积长短时记忆神经网络,是针对时空序列设计的深度学习模块。在土壤湿度预测中,土壤湿度受气象影响有复杂时空依赖。ConvLSTM将LSTM全连接层改卷积层,可处理多维数据并捕获空间特征:卷积捕捉土壤湿度空间局部特征;LSTM处理时间维度,记住湿度变化趋势,解决时空依赖,为精准预测奠基。ConvLSTM内部结构如图4所示。其中 $X_t$ 为输入, $C_t$ 为输出, $H_t$ 为隐藏状态。ConvLSTM的关键方程为

$$i_t = \sigma(W^*_{xi} X_t + W^*_{hi} H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W^*_{xi} X_t + W^*_{hi} H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tan h(W^*_{xc} X_t + W_{hc} \odot H_{t-1} + b_c) \quad (4)$$

$$o_t = \sigma(W^*_{xo} X_t + W^*_{ho} H_{t-1} + W_{co} \odot C_{t-1} + b_o) \quad (5)$$

$$H_t = o_t \odot \tan h(C_t) \quad (6)$$

式中: $*$ 表示卷积算子; $\odot$ 表示Hadamard积。

本研究基于ConvLSTM网络开展试验,具体设置如图5所示。输入数据由 $t, t-1, t-2$  d的影响因子构成,包括土壤温度、降水量以及土壤湿度。特征图大小为 $61 \times 71$ ,模型的输入尺寸为 $3 \times 3 \times 61 \times 71$ ,

其中第一个“3”代表3个时间步的数据,第2个“3”代表3种影响因子。




图4 ConvLSTM内部结构示意图  
Fig.4 Schematic diagram of internal structure of ConvLSTM

输入的数据首先会进入包含16个滤波器的ConvLSTM层,该层卷积核大小设定为3,选用双曲正切函数“tanh”作为激活函数。在这一层,通过对输入数据进行卷积操作与时间递归处理,有效捕捉时序数据中的空间和um时间特征。随后,数据进入第2个ConvLSTM层,此层包含8个滤波器,卷积核大小与激活函数保持不变。这一层进一步对数据进行处理,以提取更深入的时空特征。为确保卷积操作前后数组大小一致,在处理过程中对数据进行零填充。

### 2.3 时空特征注意力机制模块

本研究设计的时空特征注意力机制模块包含特

征注意、时间注意以及空间注意 3 种类型。①特征注意模块通过计算特征关联权重,提取关键时空特征,强化其作用以解决空间异质性问题;②时间注意模块动态分配时间步权重,把握长期趋势并捕捉突

变,使模型能准确把握时间维度动态变化;③空间注意模块关注地理差异,突出重点,抑制干扰,提升对空间变化规律的学习能力,为土壤湿度精准预测提供全面支持。

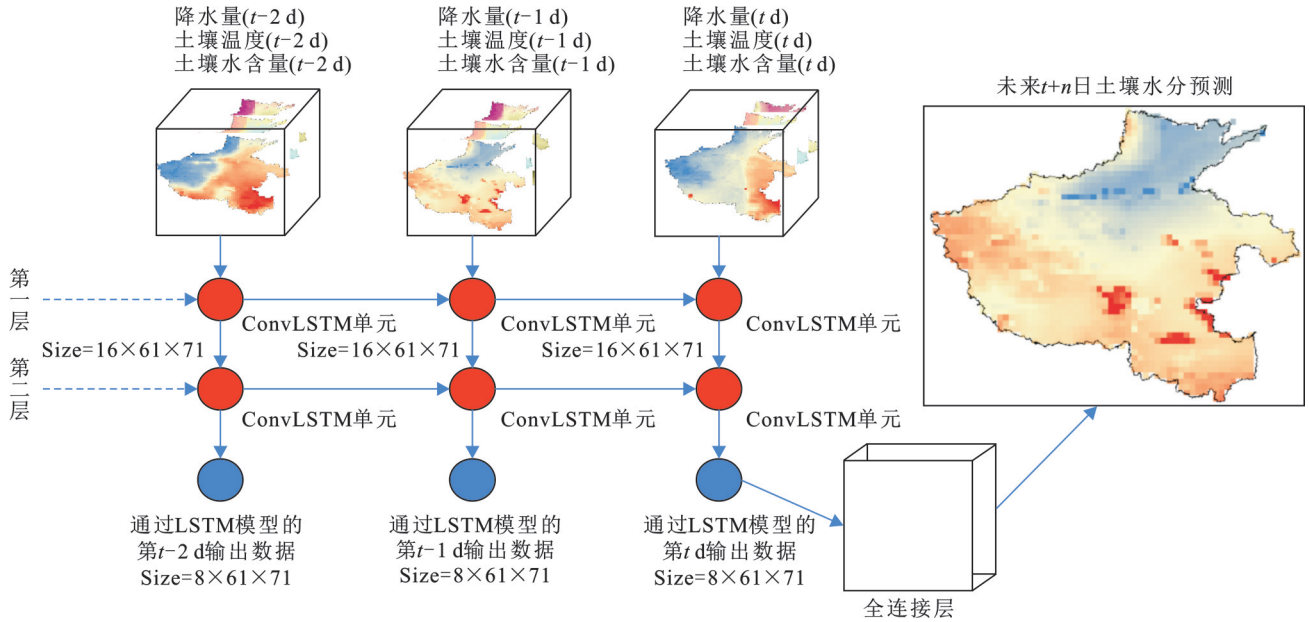


图 5 ConvLSTM 网络试验设置

Fig.5 Experimental setup of ConvLSTM network

特征注意的目的是对 ConvLSTM 网络处理后数据的时间步隐状态进行加权,从而获取时间特征和预测特征。全连接层  $Net_{L_{linea}^{\#}}(i=1,2)$  表示第  $i$  个全连接层,其能够为每个时间步的输出生成注意力权重,之后通过指数函数激活:

$$\exp(x) = e^x \quad (7)$$

指数函数 ( $\exp$ ) 可以确保重要时间步特征被放大,从而获得更高的权重。 $Net_{L_{linea}^{\#}}$  传输张量从  $[batch\ size, T, N, d]$  大小到  $[batch\ size, T, N, 1]$  大小, softmax 层定义如下:

$$\text{soft max}(x_t) = \frac{\exp(-x_t)}{\sum_{t=1}^T \exp(-x_t)} \quad (8)$$

式中:  $x_t$  是原始的注意力分数。softmax 层主要用来进行归一化操作,为了确保权值的有限可加性,特征注意机制可以识别各影响因子的时间重要性,特征注意由神经网络  $Net_{L_{linea}^{\#}}$  和一个 softmax 层组成,其定义如下:

$$mf_{a_t} = \text{soft max}\{Net_{L_{linea}^{\#1}}(x_t)\} \quad (9)$$

$$mf_{x_t} = mf_{a_t} * x_t \quad (10)$$

$[FP1, FP2, FP3]$  ( $FPn \in Rd$ ) 是基于线性神经网络  $Net_{L_{linea}^{\#}}$  生成的预测特征,将张量  $mf_{x_t}$  从  $[batch\ size, 3, N, d]$  大小转换到  $[batch\ size, 1, N, d]$  大小。

空间注意由 2 个线性神经网络和 1 个 softmax 层组成。该模块将前一部分的输出与  $h_t$  隐藏状态拼接得到特征向量,之后经过线性神经网络  $Net_{L_{linea}^{\#2}}$ ,全连接层用来计算注意力权重。运用指数函数激活权重后,将权重与特征值进行计算得到最后的结果,其定义如下:

$$\text{pred}_a = \exp\{Net_{L_{linea}^{\#2}}(x_t)\} \quad (11)$$

$$\text{pred}_{\text{pred}} = \sum_i (\text{pred}_{a[i]} \times \text{pred}_{FC[i]}) \quad (12)$$

式中:  $\text{pred}_a$  为注意力权重;  $\text{pred}_{\text{pred}}$  为模型输出的预测值;  $\text{pred}_{FC[i]}$  为特征向量。空间注意机制可以增强各预测者与被预测变量之间的相关性,最后通过级联向量  $[(h_t^1 \oplus FP^1), (h_t^2 \oplus FP^2), (h_t^3 \oplus FP^3)]$ , 汇总各个时间步长上的特征向量并增强其相关性,从而可以得到丰富的预测特征。其线性神经网络将大小为  $[batch\ size, N, 2*d]$  的张量传递到大小为  $[batch\ size, N, 1]$  的张量。针对不同的影响因子,依据其重要性(对土壤湿度的影响大小)确定其权重。

时间注意机制同样由 2 个线性神经网络和 1 个 softmax 层组成。该模块通过为各个时间步分配权重来区分其重要程度,将其特征注意得到的时间特征与输入数据拼接得到新的时间特征向量,经指数函数激活后将权重与特征值进行计算,得到最后的结

果,其定义如下:

$$\text{temp}_a = \exp[\text{Net}_{\text{Linear}}(x_t)] \quad (13)$$

$$\text{temp}_{\text{pred}} = \sum_i [\text{temp}_{a[i]} \times \text{temp}_{\text{FC}[i]}] \quad (14)$$

其中  $\text{temp}_a$  为注意力权重  $\text{temp}_{\text{FC}}$  为特征向量。时间注意机制基于时间特征与输入数据的级联向量  $[(X_{T-2} \oplus \text{FP}_{T-2}), (X_{T-1} \oplus \text{FP}_{T-1}) \text{ 和 } (X_T \oplus \text{FP}_T)]$ , 对所有影响因子的时间特征向量进行汇总,以增强预测变量的时间相关性。其线性神经网络将大小为  $[\text{batch size}, T, 3]$  的张量传递到大小为  $[\text{batch size}, T, 1]$  的张量。经过时间注意机制的运行,可以得到丰富的时间特征,时间注意权重也可以解释预测变量的时间相关性。

## 2.4 评价指标

试验采用决定系数 ( $R^2$ ) 和均方根误差 (RMSE) 2 个指标作为评估标准评价模型的预测精度。其中决定系数 ( $R^2$ ) 表示模型预测结果与真实值之间的拟合程度,其值范围为  $0 \sim 1$ , 数值越接近 1, 表示模型预测性能越好,当  $R^2$  值为 1 时,表示模型完美拟合数据;当  $R^2$  值为 0 时,表示模型拟合效果比简单的平均值预测更好,如果  $R^2$  为负值,表示模型的拟合效果比一个简单的常数模型还要差。均方根误差 (RMSE) 是衡量回归模型预测误差的一种常用指标,用于衡量模型预测的准确性,其单位与数据的原始单位相同,便于直观理解,数值越小,说明模型预测结果与实际值的偏差越小,预测结果越准确。计算公式如下:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - p_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (15)$$

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - p_i)^2} \quad (16)$$

式中:  $n$  为测试样本数量;  $y_i$  表示实际值;  $p_i$  表示预测值;  $\bar{y}$  表示实际数据的平均值。

## 3 结果与分析

### 3.1 不同模型对土壤湿度时空预测效果的影响

不同模型未来 3 d 预测性能如表 1 所示。在对未来 3 d 的预测结果中, AGSMP-Net 模型  $R^2$  和 RMSE 分别是 0.806 和 0.057 0, SVR, CNN, LSTM, Transformer 以及 ConvLSTM 模型分别为 0.566, 0.615, 0.658, 0.717, 0.758 和 0.133, 0.119, 0.110, 0.081, 0.069, 表明 AGSMP-Net 模型拥有更高的预测精度。6 种模型的预测值与真实值之间大致呈线性关系,对大部分预测点(图 6 中的红色集中部分)能够较好地进行预测。

SVR 模型基于支持向量机回归方法具有较好的非线性拟合能力,但其对大数据集的处理能力有限且不擅长处理时序数据。图 6 表明,其模拟结果较为分散,反映出该模型在土壤湿度预测任务中的不稳定性。CNN 和 LSTM 模型的预测结果存在系统性偏差,因各自仅能捕捉空间或时间单一特征。CNN 模型通过卷积操作提取空间特征, LSTM 模型通过门控机制处理时序信息,但二者均忽略时空关联性,导致预测误差较大。Transformer 模型虽擅长远程依赖捕获,但对土壤湿度长期气候影响的建模能力有限。ConvLSTM 模型结合卷积与 LSTM 模型获取时空信息,但共享权重限制了其时空异质性表达能力。AGSMP-Net 模型在 ConvLSTM 模型的基础上加入注意力机制,考虑时间特征的时间重要性以及每个影响因子的时间重要性,前者可以捕捉各影响因子之间的全局关系,后者则能够区分影响因子的时间相关性,进一步增强了模型的时间信息处理能力和扩展空间信息的感知范围,从而提高了模型的模拟性能。

表 1 不同模型未来 3 d 预测性能对比

Table 1 Comparison of prediction performance of different models in next three days

模型	RMSE	$R^2$
SVR	0.133	0.566
CNN	0.119	0.615
LSTM	0.110	0.658
Transformer	0.081	0.717
ConvLSTM	0.069	0.758
AGSMP-Net	0.057	0.806

AGSMP-Net 模型预测精度受极端天气条件的影响(表 2, 图 7)。结合 2016 年豫北特大暴雨 ( $36.1^\circ\text{N}$ ,  $114.3^\circ\text{E}$ )、2021 年郑州暴雨 ( $34.7^\circ\text{N}$ ,  $113.6^\circ\text{E}$ )、2023 年豫南暴雨 ( $32.2^\circ\text{N}$ ,  $115.6^\circ\text{E}$ )、2017 年豫中伏旱 ( $33.9^\circ\text{N}$ ,  $113.5^\circ\text{E}$ )、2019 年豫南夏秋连旱 ( $32.7^\circ\text{N}$ ,  $112.9^\circ\text{E}$ ) 以及 2022 年河南春旱 ( $33.0^\circ\text{N}$ ,  $112.6^\circ\text{E}$ ) 几个典型案例,系统分析暴雨和干旱两种典型极端气候情景下模型的预测准确性变化特征。结果表明,在暴雨条件下,模型预测精度呈现下降趋势;而在干旱情景中,模型预测精度表现出稳定性。同时,模型在不同区域的预测误差存在空间差异。南部(豫南)水系密集区在暴雨事件下土壤湿度响应剧烈,模型在该区域出现一定程度的滞后低估,可能与复杂地形导致的地表径流快速转移有关。而北部干旱区预测结果表现更为稳定,但在持续干旱期间略有高估,可能源于浅层

土壤含水率低值状态下模型感知精度下降。研究为评估模型在极端气候事件中的适用性提供了量化依

据,揭示了不同灾害性天气背景下土壤水分动态演变规律的差异性特征。

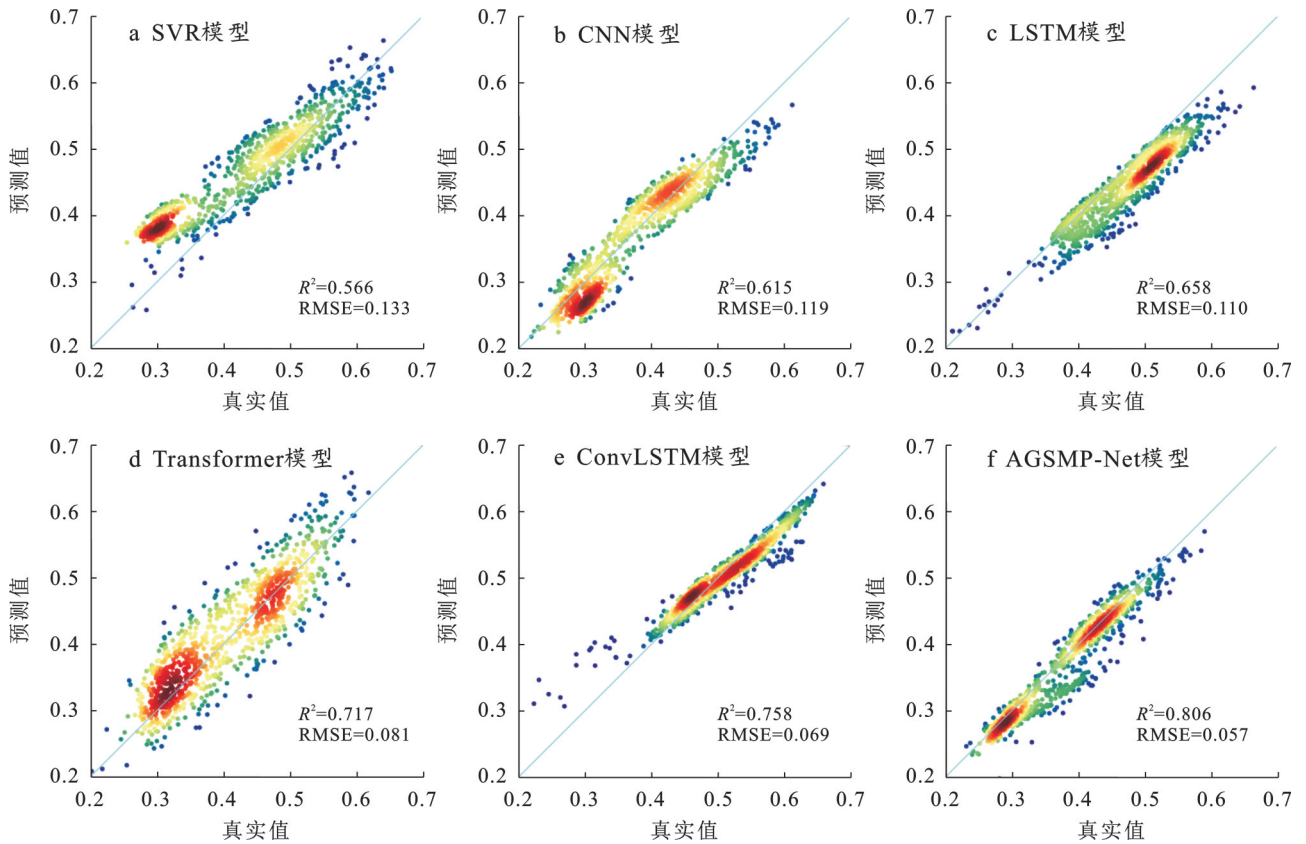


图 6 不同模型 3 d 土壤湿度预测结果散点密度图

Fig.6 Scatter density plots of 3-day soil moisture prediction results of different models

表 2 极端条件下 AGSMP-Net 模型性能  
Table 2 AGSMP-Net model performance under extreme conditions

位置	时间	事件	RMSE	R <sup>2</sup>
36.1°N, 114.3°E	20160709	暴雨	0.066	0.766
34.7°N, 113.6°E	20210720	暴雨	0.067	0.764
32.2°N, 115.6°E	20230703	暴雨	0.069	0.761
33.9°N, 113.5°E	20170701	干旱	0.057	0.820
32.7°N, 112.9°E	20191001	干旱	0.060	0.817
33.0°N, 112.6°E	20220630	干旱	0.059	0.818

图 8 表明, AGSMP-Net 模型能有效模拟河南省土壤湿度的空间分异规律, 但存在显著区域差异。在土壤湿度较低的北部及西部地区, 模型预测值与观测值高度吻合, 表明模型对干旱-半干旱区简单水文过程具有良好适应性; 而在东南部高湿度区, 模型呈现系统性低估现象, 该偏差在夏季季风期显著扩大至  $-0.18 \text{ m}^3/\text{m}^3$ , 且偏差高值区与淮河、洪汝河等密集河网空间分布高度重合。沿河道 10 km 缓冲带内观测到偏差梯度, 揭示模型对河流漫滩区土壤水饱和过程尤其是地表-地下水文耦合效应模拟不足, 这可能是汛期河道侧向补给增强与冲积平原毛细作

用协同导致的结果。从时间尺度上, 春夏两个季节模型的预测结果精度较高, 与真实值吻合度较好; 秋季模型预测结果在河南省东部地区有明显偏低趋势, 而在西部地区, 预测结果能较好地反映真实土壤湿度情况; 冬季模型预测结果在河南省北部呈现偏高趋势, 在南部地区则表现良好, 预测值与真实值较为相符。




图 7 极端天气条件 AGSMP-Net 模型预测结果  
Fig.7 Prediction results of AGSMP-Net model under extreme conditions

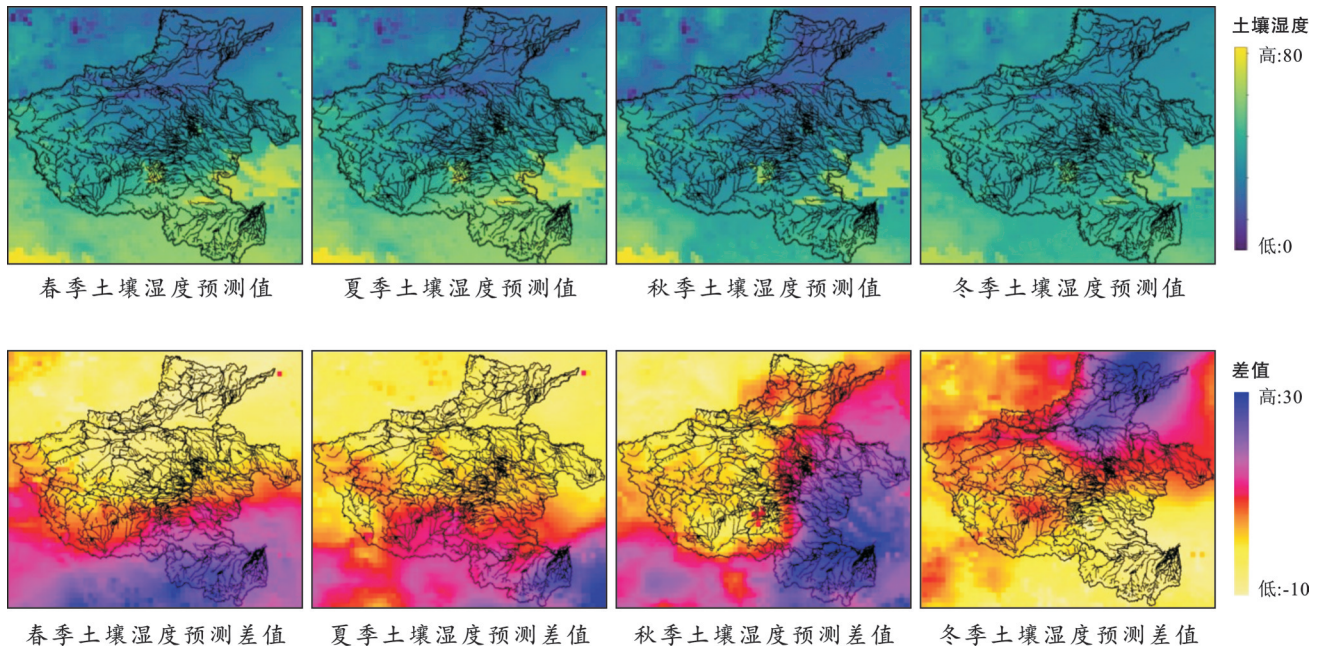


图 8 土壤湿度预测值与差值的空间分布

Fig. 8 Spatial distribution of predicted values and prediction errors of soil moisture

### 3.2 预测时间尺度对精度的影响

在时间尺度方面,本研究所用 SVR, CNN, LSTM, Transformer, ConvLSTM 以及 AGSMP-Net 模型对未来 3, 5, 7 d 的预测精度均呈现递减的趋势。可能是由于土壤湿度具有较强的时间依赖性,即当前土壤湿度与近期历史数据密切相关,随着预测时间的延长,历史数据对当前预测的影响逐渐减弱,导致模型难以准确捕捉长期变化趋势。另一方面,随着预测时间的延长,外部环境因素(如气温、降水、蒸发等)对土壤湿度的影响逐渐累积,增加了预测的不确定性。

传统模型(如 SVR, CNN)由于缺乏对复杂时空关系的建模能力,难以有效处理这种不确定性,因此预测精度下降更为明显。AGSMP-Net 模型由于结合了注意力机制,能够动态加权关键时间步长的信息,在长期预测中表现相对较好。然而,其他模型(如 LSTM, Transformer)在长期预测中可能出现过拟合或欠拟合问题,导致预测精度显著下降。

研究结果表明,AGSMP-Net 模型在不同时间尺度上的预测精度均优于其他模型(表 3、表 4 和图 9)。具体而言,AGSMP-Net 模型在未来 3 d, 5 d 和 7 d 的预测中, $R^2$  值分别为 0.806, 0.795, 0.782, RMSE 值分别为 0.057, 0.061, 0.068 相比之下,其他模型在相同时间尺度上的  $R^2$  和 RMSE 值均表现较差,尤其是在未来 7 d 的预测中(图 10), AGSMP-Net 模型的优势更加明显。从密度散点图(图 10, 图 11)可以看出,

AGSMP-Net 模型的预测值与真实值之间的分布更加集中,尤其是在高密度区域,预测点几乎沿着对角线分布,表明其预测结果与真实值高度一致。而其他模型的预测点分布较分散,尤其是在低密度区域,预测误差较大。

表 3 不同模型未来 5 d 预测性能对比

Table 3 Comparison of prediction performance of different models in next five days

模型	RMSE	$R^2$
SVR	0.139	0.551
CNN	0.120	0.602
LSTM	0.111	0.645
Transformer	0.085	0.689
ConvLSTM	0.071	0.743
AGSMP-Net	0.061	0.795

表 4 不同模型未来 7 d 预测性能对比

Table 4 Comparison of prediction performance of different models in next seven days

模型	RMSE	$R^2$
SVR	0.146	0.531
CNN	0.131	0.581
LSTM	0.117	0.625
Transformer	0.091	0.667
ConvLSTM	0.081	0.729
AGSMP-Net	0.068	0.782

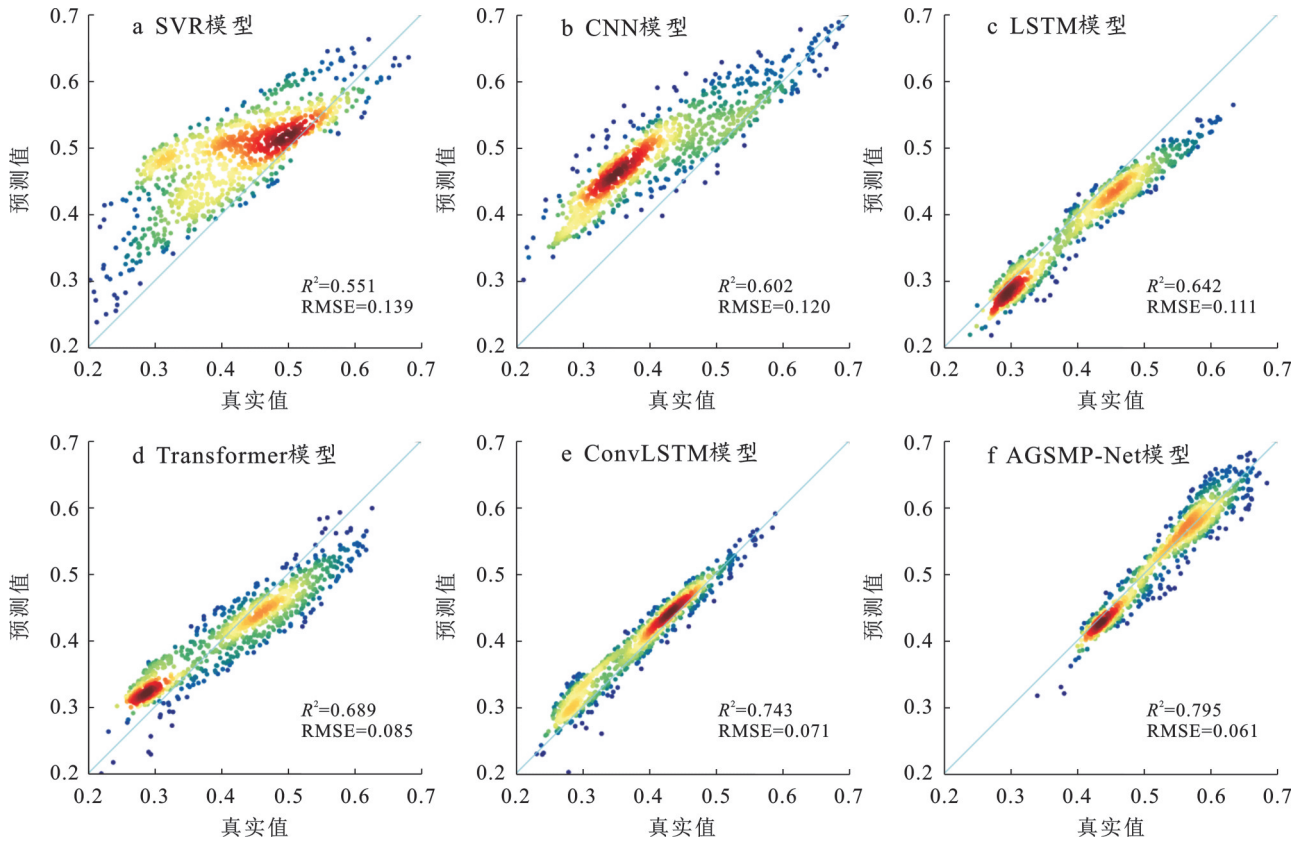


图 9 不同模型预测 5 d 土壤湿度结果散点密度

Fig.9 Scatter density plots of 5-day soil moisture prediction results of different models

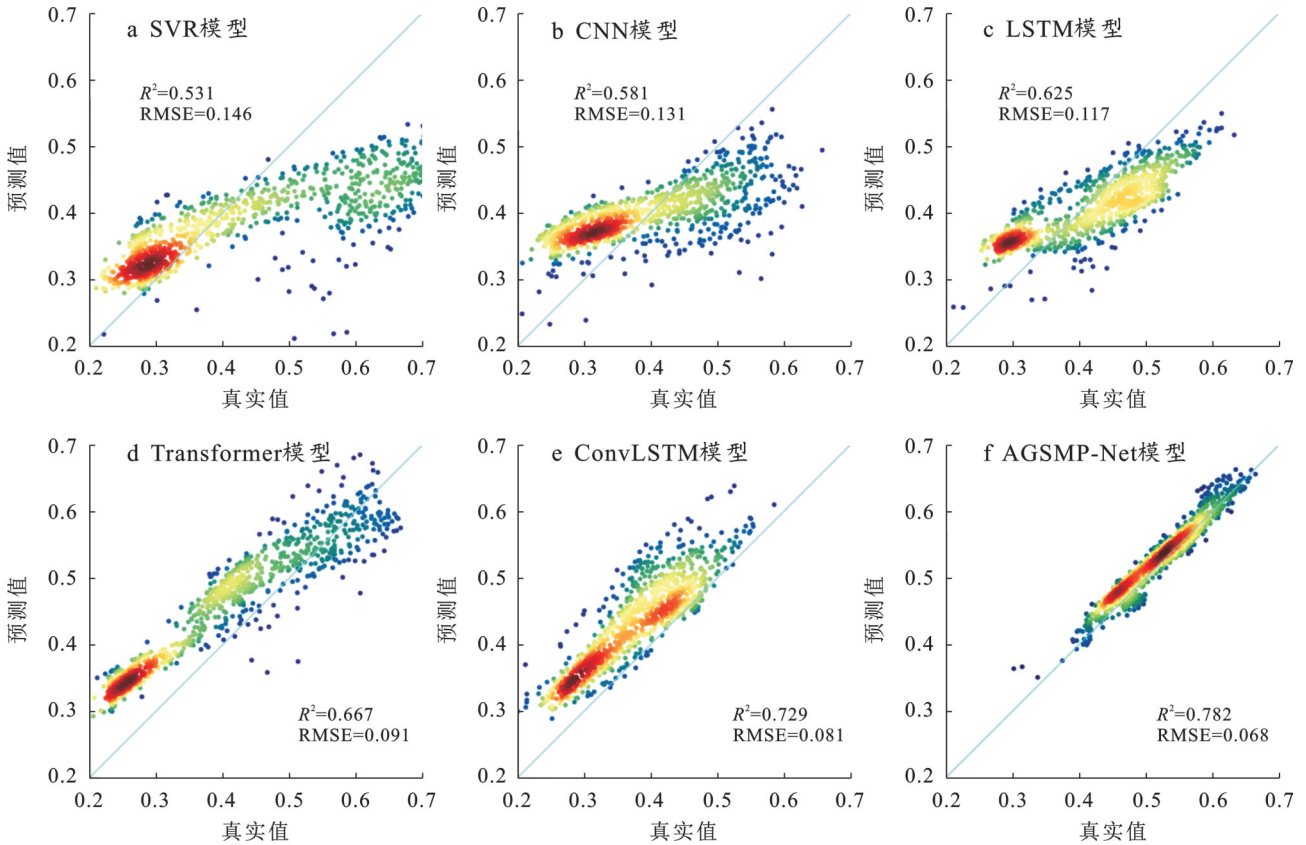


图 10 不同模型预测 7 d 土壤湿度结果散点

Fig.10 Scatter density plots of 7-day soil moisture prediction results of different models

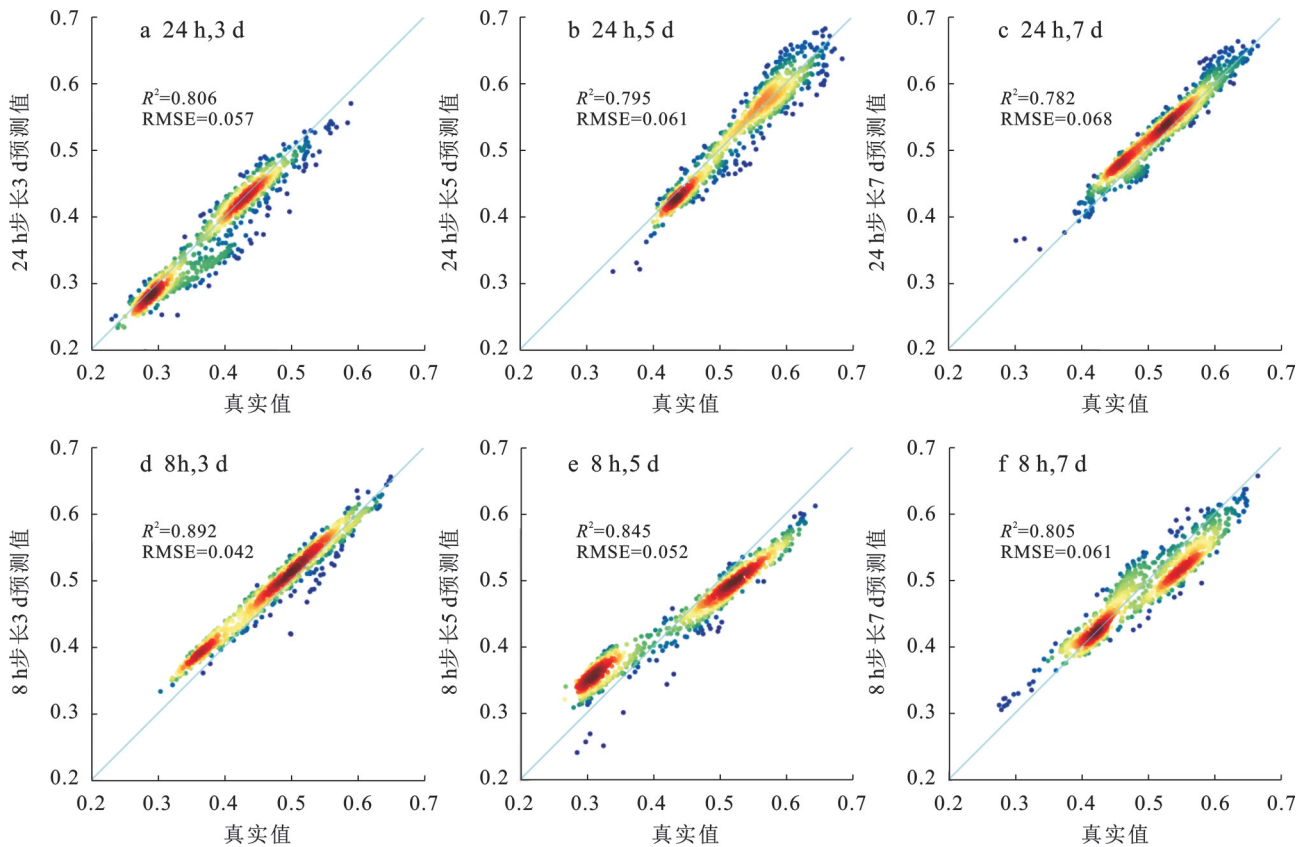


图 11 时间步长影响结果散点图

Fig.11 Scatter density plots showing time step size effect

同时,为了深入探究时间步长对土壤湿度预测精度的影响,本试验增设 8 h 时间步长开展对比研究。由表 5 可知,8 h 步长的  $R^2$  值分别为 0.892, 0.845, 0.805, RMSE 值分别为 0.042, 0.052, 0.061, 预测精度优于 24 h 步长。究其原因,时间步长较小(如 8 h)时,如同以更细密的“筛网”采集信息,能获取更多有效数据。ERA5-Land 数据时间分辨率为小时,8 h 步长可将每日划分为 3 个时段,细致捕捉土壤湿度在短时间间隔内的变化特征及相关气象要素信息。相比之下,24 h 步长每日仅划分 1 个时段,时间间隔较大,因而 8 h 步长因信息获取量更丰,使得土壤湿度预测精度相对更高。

表 5 时间步长对模型预测精度的影响  
Table 5 Effect of time step size on model prediction accuracy

时间步长	预测时间/d	RMSE	$R^2$
24 h	3	0.057	0.806
	5	0.061	0.795
	7	0.068	0.782
8 h	3	0.042	0.892
	5	0.052	0.845
	7	0.061	0.805

### 3.3 气象要素对模型预测精度的影响

为深入探究降水量与土壤温度在土壤湿度预测过程中的重要程度,试验对这两个要素设置了不同的输入比例,并记录了 AGSMP-Net 模型在相应输入下预测精度的变化情况。

图 12 表明,与 1:1 输入降水量和土壤温度的情况进行对比,单独输入降水量或者土壤温度,都会致使模型的预测精度下降。同时,单独输入降水量时,模型精度的下降幅度小于单独输入土壤温度时的情况。此外,当降低降水量的输入比例时,模型的精度随之降低;而降低土壤温度的输入比例,却会使模型的精度有所提高。

综合以上结果可知,在利用 AGSMP-Net 模型进行土壤湿度预测时,降水量对模型的预测结果具有更显著和重要的影响。

## 4 结论

(1) 对河南省 2015—2024 年土壤湿度数据的试验验证结果表明,AGSMP-Net 模型在预测性能上优于其他土壤湿度时空预测模型。ConvLSTM 相比,AGSMP-Net 模型精确度 ( $R^2$ ) 高 0.048, 均方根误差 (RMSE) 低 0.012。该模型能够有效建模数据

中的时空变化趋势和相关性,从而进一步提高预测精度。




图12 不同比例气象要素输入的AGSMP-Net模型预测精度变化

Fig.12 Variation of prediction accuracy of AGSMP-Net model with different proportions of meteorological element inputs

(2) 模型预测精度随预测时间的延长而降低,预测结果为精准灌溉和农业水资源管理提供了重要的数据支持。未来,研究可以进一步探索该模型在其他气候与环境变量预测中的应用潜力,并优化其计算效率,以适应大规模实时预测的需求。

(3) 降水量和土壤温度对土壤湿度预测的重要程度存在差异。相较而言,降水量对模型预测精度影响更明显,降水量和土壤温度对土壤湿度具有重要的影响。

### 参考文献 (References)

- Corona R, Katul G, Montaldo N. The root-zone soil moisture spectrum in a Mediterranean ecosystem [J]. *Journal of Hydrology*, 2022, 609: 127757.
- 李小雁. 干旱地区土壤-植被-水文耦合、响应与适应机制[J]. *中国科学:地球科学*, 2011, 41(12): 1721-1730.  
Li Xiaoyan. Coupling, response and adaptation mechanism of soil-vegetation-hydrology in arid areas [J]. *Scientia Sinica (Terra)*, 2011, 41(12): 1721-1730.
- Li Qingliang, Wang Ziyu, Shanguan Wei, et al. Improved daily SMAP satellite soil moisture prediction over China using deep learning model with transfer learning [J]. *Journal of Hydrology*, 2021, 600: 126698.
- Celik M F, Isik M S, Yuzugullu O, et al. Soil moisture prediction from remote sensing images coupled with climate, soil texture and topography via deep learning [J]. *Remote Sensing*, 2022, 14(21): 5584.
- 董红霞, 张钦弟, 卫强. 基于HYDRUS-1D模型的半干旱黄土区典型整地措施土壤水分动态模拟[J]. *水土保持通报*, 2023, 43(5): 156-168.  
Dong Hongxia, Zhang Qindi, Wei Qiang. Dynamic simulation of soil moisture under typical land preparation in semi-arid loess area using HYDRUS-1D model [J]. *Bulletin of Soil and Water Conservation*, 2023, 43(5): 156-168.
- 吴泽棉, 邱建秀, 刘苏峡, 等. 基于土壤水分的农业干旱监测研究进展[J]. *地理科学进展*, 2020, 39(10): 1758-1769.  
Wu Zhemian, Qiu Jianxiu, Liu Suxia, et al. Advances in agricultural drought monitoring based on soil moisture [J]. *Progress in Geography*, 2020, 39(10): 1758-1769.
- 《中国统计年鉴2024》编委会. 中国统计年鉴[M]. 北京: 中国统计出版社, 2024: 4-5.  
National Bureau of Statistics of China. *China Statistical yearbook 2024* [M]. Beijing: China Statistics Press, 2024: 4-5.
- Egea G, Diaz-Espejo A, Fernández J E. Soil moisture dynamics in a hedgerow olive orchard under well-watered and deficit irrigation regimes: Assessment, prediction and scenario analysis [J]. *Agricultural Water Management*, 2016, 164: 197-211.
- 樊婷, 张存厚, 张德广, 等. 内蒙古自治区达茂旗荒漠草原土壤水分对降水的响应[J]. *水土保持通报*, 2020, 40(1): 72-77.  
Fan Ting, Zhang Cunhou, Zhang Deguang, et al. Response of soil moisture of desert steppes to precipitation patterns in Damao Banner, Inner Mongolia [J]. *Bulletin of Soil and Water Conservation*, 2020, 40(1): 72-77.
- Mahmood R, Hubbard K G. An analysis of simulated long-term soil moisture data for three land uses under contrasting hydroclimatic conditions in the northern great Plains [J]. *Journal of Hydrometeorology*, 2004, 5(1): 160-179.
- Carrasco-Benavides M, Gonzalez Viejo C, Tongson E, et al. Water status estimation of cherry trees using infrared thermal imagery coupled with supervised machine learning modeling [J]. *Computers and Electronics in Agriculture*, 2022, 200: 107256.
- 王铁英, 王仰仁, 战国隆, 等. 基于实时含水率数据的土壤墒情动态建模及预测[J]. *中国农业气象*, 2021, 42(1): 13-23.  
Wang Tieying, Wang Yangren, Zhan Guolong, et al. Dynamic modeling and prediction of soil moisture based on real-time water content data [J]. *Chinese Journal of Agrometeorology*, 2021, 42(1): 13-23.
- Jackson S H. Comparison of calculated and measured volumetric water content at four field sites [J]. *Agricultural Water Management*, 2003, 58(3): 209-222.
- 舒素芳, 钱华峰, 邱小伟. 基于气象因子的金华市土壤墒情预测模型[J]. *中国农业气象*, 2009, 30(2): 180-184.

- Shu Sufang, Qian Huafeng, Qiu Xiaowei. Soil moisture forecast model based on meteorological factors in Jinhua City [J]. Chinese Journal of Agrometeorology, 2009, 30(2):180-184.
- [15] 刘娣,孙佳倩,余钟波.基于机器学习模型的多层土壤湿度反演[J].河海大学学报(自然科学版),2024,52(3):7-14.
- Liu Di, Sun Jiaqian, Yu Zhongbo. Multi-layer soil moisture inversion based on machine learning models [J]. Journal of Hohai University (Natural Sciences), 2024, 52(3):7-14.
- [16] 汪静平,吴小丹,马杜娟,等.基于机器学习的遥感反演:不确定性因素分析[J].遥感学报,2023,27(3):790-801.
- Wang Jingping, Wu Xiaodan, Ma Dujuan, et al. Remote sensing retrieval based on machine learning algorithm: Uncertainty analysis [J]. National Remote Sensing Bulletin, 2023, 27(3):790-801.
- [17] 李明伟.基于LSTM模型预测不同水保工程措施条件下土壤侵蚀量:以辽西北地区为例[J].水土保持通报,2023,43(4):162-169.
- Li Mingwei. Estimating soil erosion under different soil and water conservation engineering measures using LSTM model: A case study in northwest Liaoning Province [J]. Bulletin of Soil and Water Conservation, 2023, 43(4):162-169.
- [18] Xu Lei, Lv Yu, Moradkhani H. Daily multistep soil moisture forecasting by combining linear and nonlinear causality and attention-based encoder-decoder model [J]. Stochastic Environmental Research and Risk Assessment, 2024, 38(12):4979-5000.
- [19] Liu Kexin, Lu Qi, Guo Shilong, et al. CNN based approach for root zone soil moisture prediction by ground penetrating radar [J]. Journal of Physics: Conference Series, 2024, 2887(1):012007.
- [20] Li Xiaoning, Zhang Ziyin, Li Qingliang, et al. Enhancing soil moisture forecasting accuracy with REDF-LSTM: Integrating residual en-decoding and feature attention mechanisms [J]. Water, 2024, 16(10):1376.
- [21] Park S H, Lee B Y, Kim M J, et al. Development of a soil moisture prediction model based on recurrent neural network long short-term memory (RNN-LSTM) in soybean cultivation [J]. Sensors, 2023, 23(4):1976.
- [22] Jiang Shuwen, Chen Guifen, Chen Dong, et al. Application and evaluation of an improved LSTM model in the soil moisture prediction of southeast Chinese tobacco-producing areas [J]. Journal of the Indian Society of Remote Sensing, 2023, 51(9):1843-1853.
- [23] 徐金鸿,李清泉,韦春桃,等.基于样本优化与深度特征提取的滑坡易发性评价[J].水土保持通报,2025,45(2):190-200.
- Xu Jinhong, Li Qingquan, Wei Chuntao, et al. Landslide susceptibility evaluation based on sample optimization and deep feature extraction [J]. Bulletin of Soil and Water Conservation, 2025, 45(2):190-200.
- [24] 车银超,郑光,熊淑萍,等.多因素土壤墒情预测模型DA-LSTM-soil构建[J].河南农业大学学报,2025,59(4):698-710.
- Che Yinchao, Zheng Guang, Xiong Shuping, et al. Construction of a multi-factor soil moisture prediction model DA-LSTM-soil [J]. Journal of Henan Agricultural University, 2025, 59(4):698-710.
- [25] Kara A, Pekel E, Ozcetin E, et al. Genetic algorithm optimized a deep learning method with attention mechanism for soil moisture prediction [J]. Neural Computing and Applications, 2024, 36(4):1761-1772.
- [26] 杨肖杰,秦明周,张鹏岩,等.河南省耕地压力与经济发展耦合特征的时空分析[J].地域研究与开发,2020,39(3):144-149.
- Yang Xiaojie, Qin Mingzhou, Zhang Pengyan, et al. Spatio-temporal analysis of coupling characteristics of cultivated land pressure and economic development in Henan Province [J]. Areal Research and Development, 2020, 39(3):144-149.
- [27] 刘英,岳辉,李遥,等.基于MODIS的河南省春旱遥感监测[J].干旱地区农业研究,2018,36(3):218-223.
- Liu Ying, Yue Hui, Li Yao, et al. Remote sensing monitoring of spring drought based on MODIS in Henan Province [J]. Agricultural Research in the Arid Areas, 2018, 36(3):218-223.
- [28] 魏克循,马国明.河南省土壤普查办公室编著.河南土壤[M].北京:中国农业出版社,2004.
- Wei Kexun, Ma Guoming. Compiled by the Soil Census Office of Henan Province. Soil in Henan [M]. Beijing: China Agriculture Press, 2004.
- [29] Copernicus Climate Data Store. ERA5-Land Hourly Data (1950-present) [EB/OL]. (2025-4-13) [2025-05-08]. <https://cds-beta.climate.copernicus.eu/datasets/reanalysis-era5-land?tab=overview>.