

doi: 10.6046/zrzyyg.2021450

引用格式: 张可,张庚生,王宁,等. 基于遥感和深度学习的输电线路地表水深预测[J]. 自然资源遥感,2023,35(1):213-221.
(Zhang K,Zhang G S,Wang N,et al. A forecasting method for water table depths in areas with power transmission lines based on remote sensing and deep learning models[J]. Remote Sensing for Natural Resources,2023,35(1):213-221.)

基于遥感和深度学习的输电线路地表水深预测

张可^{1,2,3}, 张庚生^{1,2}, 王宁⁴, 温静⁴, 李宇^{1,2}, 杨俊⁵

(1. 国网电力科学研究院有限公司, 合肥 230088; 2. 安徽南瑞继远电网技术有限公司, 合肥 230088; 3. 中国科学技术大学, 合肥 230088; 4. 中国自然资源航空物探遥感中心, 北京 100083; 5. 国网浙江省电力有限公司杭州供电公司, 杭州 310000)

摘要: 近年来很多输电线路区域受到洪水灾害的影响,因此,预测输电线路区域地表水深对于输电线路安全至关重要。本研究通过遥感卫星产品、观测气象资料和水文数据来预测地表水深。该研究首先利用长短期记忆网络(long short-term memory, LSTM)、门控循环单元网络(gated recurrent unit, GRU)、编码器和解码器的长短期记忆网络(long short-term memory-seq2seq, LSTM-S2S)和前馈神经网络(feedforward neural network, FFNN)模型针对气象资料和水文数据进行了日和月尺度数据模拟。结果表明,在4个模型中,LSTM-S2S是预测地表水深的最佳模型;相比之下,FFNN的表现最差;LSTM,GRU和LSTM-S2S模型在日和月尺度数据模拟中均表现良好。在LSTM,GRU和LSTM-S2S模型中,日尺度模拟的决定系数(coefficient of determination, R^2)和纳什效率系数(Nash-Sutcliffe efficiency coefficient, NSE)均优于月尺度。因此,本研究中的方法可以用来模拟未来电力传输线地区的日和月尺度的地表水深。

关键词: 深度学习模型; GRU; LSTM-S2S; LSTM; 地表水深

中图分类号: TP 79 **文献标志码:** A **文章编号:** 2097-035X(2023)01-0213-09

0 引言

了解气候变化导致的输电线路区域的地表水深变化,不仅对区域水资源管理,而且对项目安全而言都是至关重要的^[1]。众多输电线路被安装在山区,容易受到水灾的影响,而地表水位的深度是水灾事件的主要因素。因此,预测输电线路的地表水深可以预防或减缓其对电力系统的影响。

在过去研究中,基于水文过程的物理模型和机器学习模型是主要的模拟地表水深主要方法。基于水文过程的物理模型,如模块化三维有限差分地下水流动模型(modular three-dimensional finite-difference ground-water flow model, MODFLOW)和环境土壤物理模型(HYDRUS)^[2];这些模型需要大量的输入数据和校准数据,所以很难将其应用于更广泛的领域。机器学习方法,如人工神经网络模型(artificial neural network, ANN)。机器学习往往选

择用来生成样本的值和参数,将影响之后的模型训练,在没有任何先验知识的情况下,很难确定最佳时间步骤。因此,使用机器学习算法进行地表水深预测会导致一些不确定因素。

近年来,许多研究运用深度学习模型对水循环和地表水深度进行了建模。大多数模型都是基于递归神经网络(recurrent neural network, RNN)。RNN模型反映了时间序列的顺序信息,因此可以记住以前的信息,并捕捉时间动态,同时当用长期的滞后期加以训练时,会出现梯度爆炸和梯度消失问题^[3]。长短期记忆网络(long short-term memory, LSTM)模型通过克服RNN在学习长期依赖性方面的问题,在水文领域展示了其优势^[4]。与机器学习方法相比,深度学习模型有4个优势:①从原始数据中提取和塑造一连串的抽象特征;②在学习知识后进行迁移学习;③用增加的网络深度来表示复杂的功能;④深度学习方法的进步得益于计算机技术进步^[5]和越来越多可获取的巨大数据集^[6]。

收稿日期: 2021-12-20; 修订日期: 2022-11-04

基金项目: 国家电网公司总部科技项目“无人区输电线路全景物联网技术及共享型智慧感知平台研究”(编号: 5500-202140127A)。

第一作者: 张可(1983-),男,高级工程师,主要从事电气自动化及人工智能应用研究。zhangke2@sgepri.sgc。

通信作者: 王宁(1988-),男,高级工程师,主要从事航空物探遥感数据处理及应用研究。Email: ning.-wang@163.com。

Zhang 等^[7]利用每月的天气数据和水文数据开发了一个 LSTM 来模拟河套灌区 5 个分区的地表水深度。因为 LSTM 的架构是合理的,它可以保存以前的信息,因此有助于学习时间序列数据。此外,丢弃率方法可以防止训练过程中的过度拟合,LSTM 层之上的全连接层也提高了训练过程中的学习和拟合能力。因此,LSTM 模型在月尺度水位深度预测中比前馈神经网络 (feedforward neural network, FFNN) 模型有更好的表现。然而,这个测试只有月尺度数据,而电力传输线地区的地表水深预测需要更高的时间分辨率数据。

为了提供更准确的地表水深预测,需要一个更深、更广、更强大的长时间序列分析模型。还有一个基于 RNN 的模型,称为门控循环单元网络 (gated recurrent unit, GRU)。Kao 等^[8]使用 LSTM 模型和 GRU 网络来预测中国福建省沙溪河流域的径流。结果表明,GRU 模型与 LSTM 模型性能相当。GRU 可能是短期径流预测的首选方法,因为它需要较少的时间进行模型训练。

此外,Xiang 等^[9]和 Kao 等^[8]分别提出的编码器和解码器的长短期记忆网络 (long short-term memory-seq2seq, LSTM-S2S) 模型在各自的实际应用中表现出色。Xiang 等^[9]提出了一个未来连续 24 小时的 LSTM-S2S 降雨-径流模型,并展现了足够的预测能力和良好的性能。Kao 等^[8]提出了一个可用 6 h 前的洪水预报 LSTM-S2S 模型,结果表明它可以提高洪水预报的可靠性。并增加模型内部的可解释性。然而,到目前为止,GRU 或 LSTM-S2S 模型很少被用于预测水循环中的地表水深。

为解决上述问题,本研究采用了遥感产品数据、气象资料和水文数据,利用 LSTM, FFNN, LSTM-S2S 和 GRU 模型预测输电线路区域不同时间尺度地表水深。本研究的目的是评估模型在模拟输电线路区域的地表水深预测结果,研究数据时间尺度对模型模拟的影响。

1 研究区概况和数据源

研究区域位于中国西南部的波密县 (E95°40′12″~95°48′21″, N29°49′12″~29°54′08″), 面积 16 748 km², 海拔 2 720 m (图 1)。波密县的输电线路工程于 2015 年开始, 整个项目横跨 34 km, 穿越 7 个县, 满足超过 2.9 万人的日常用电需求。同时, 年平均气温约为 8.5℃, 最低气温为 0℃ 以下, 最高气温为 7 月的 16.5℃。平均降水量为 900 mm。

研究采用日尺度数据集和月尺度数据集。日尺




图 1 研究区域

Fig. 1 Study area

度数据集来源国家冰川冻土沙漠科学数据中 (<http://www.ncdc.ac.cn/portal/metadata/a6113c36-67cc-47a7-9bbb-f143343302b3>) 的时间序列数据。包括了 2016—2019 年共计 4 a 的数据。该数据集为“年藏东南嘎隆拉冰川径流观测数据”并且其数据收集地点紧邻波密县的电力传输线区域 (图 1)。该测站每 10 min 收集一次原始数据, 并将其转化为每日统计数据供发表使用。2016 年 7 月 24 日—2019 年 8 月 26 日每日降水量、空气湿度、温度、地表水深和径流均被纳入公开数据集。

月尺度数据集包括 2000—2013 年降水与地表温度数据, 从美国航天航空局 (National Aeronautics and Space Administration, NASA) (<http://www.nasa.gov/>) 获取。其中, 降水数据来源于 TRMM-3B43 V7 数据产品, 空间分辨率为 25 km, 地表温度数据来源于 MOD11B3 数据产品, 空间分辨率为 6 km。土壤湿度数据来源于英国布里斯托大学地理科学学院的 GLEAM 数据产品 (<http://geoservices.falw.vu.nl/>), 空间分辨率为 25 km。该数据已经过站点实测数据进行验证, 在国内干旱-半干旱区具有较高的准确性^[10]。地表水深来自 2000—2013 年监测的月尺度地表水深。

2 研究方法

2.1 LSTM 模型

LSTM 是一种特殊的 RNN。RNNs 最早是在 20 世纪 80 年代开发的, 这些网络的神经元之间有连接, 并形成一定向循环。这种类型的结构创造了一个内部的自循环单元, 使得它能够显示动态的时间行为。RNNs 具有重复模块的链状结构 (图 2)。图中, $S(t)$ 是指通过公式 $Y_{(t)}$ 得到 t 时间的状态, $S_{(t+1)}$ 是指通过公式 $Y_{(t+1)}$ 得到 $t+1$ 时间的状态, 而




图 2 RNN 网络

Fig.2 RNN network




图 3 LSTM 网络

Fig.3 LSTM network

由于梯度消失的问题,时间反向传播算法对于从长期依赖性中学习一个模式是不够有效的^[12]。这个问题可以通过 LSTMs 的结构来解决^[13]。LSTM 也有类似链条的模块,但重复模块的结构更复杂。LSTM 的每个重复模块都包含一个记忆模块。这个记忆模块是专门为存储长时间的信息而设计的。记忆块包含 4 个部分: 1 个常量错误木马 (constant error carousel, CEC) 单元,此外还有 3 个被称为门的特殊乘法单元。CEC 单元在整个链条上直接运行,没有任何激活函数,因此当应用时间反向传播算法来训练 LSTM 时,梯度不会消失。因此,LSTM 已被证明是比 RNN 更容易学习长期依赖关系,因为信息可以很容易地沿着细胞流动而不改变。此外,每个记忆块中的输入、遗忘^[14]和输出门可以控制记忆块内的信息流。输入、遗忘和输出门分别控制新的输入流入 CEC 单元的程度,信息存储在单元中,以及输出从单元流向网络的其他部分。图 3 展示了存储块的示意图。它包括块的输入,包括 3 个门: 输入门、遗忘门和输出门,计算公式分别见式(1)–(3); 一个新的存储单元计算公式见式(4); 最终存储和最终隐藏状态计算公式分别见式(5)和式(6):

$$i_t = (W_i x_t + U_i h_{t-1} + b_i) \sigma, \quad (1)$$

RNN 基于 $S_{(t)}$ 和 $S_{(t+1)}$ 得到新的状态。这些结构可以帮助 RNNs 重新显示以前的信息,这使得 RNNs 可以处理任意的 (长时间) 序列。因此,RNNs 在学习序列方面有其先天优势。

LSTM 是由 RNN 衍生出来的,并在其基础上有所改进。RNN 在对先前信息的记忆方面有局限性。因为 RNN 的隐藏层只有一个激活函数 ($\tanh$ 或 relu),梯度可以迅速消失或爆炸 (图 3)。由于 w 通常小于 1,当 w 减少到 1 时,梯度会爆炸;当 w 减少到 0 时,梯度会消失。LSTM 的开发就是为了优化这个过程。

RNNs 的梯度可以通过时间反向传播算法 (Back-PropagationThrough Time) 计算^[11]。然而,

$$f_t = (W_f x_t + U_f h_{t-1} + b_f) \sigma, \quad (2)$$

$$o_t = (W_o x_t + U_o h_{t-1} + b_o) \sigma, \quad (3)$$

$$c_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (4)$$

$$o_t = f_t \odot c_{t-1} + i_t \odot c_t, \quad (5)$$

$$h_t = o_t \odot \tanh(c_t), \quad (6)$$

式中: W_i , W_f 和 W_o 分别为从输入门、遗忘门和输出门到输入门的权重矩阵; U_i , U_f 和 U_o 分别为从输入门、遗忘门和输出门到隐藏门的权重矩阵; b_i , b_f , b_o 分别为输入门、遗忘门和输出门的偏差向量; σ 为一个逐元的非线性激活函数; i_t , f_t , o_t 和 h_t 分别为时间 t 的输入门、遗忘门、输出门和细胞状态向量; c_t 和 o_t 为新存储单元和最终存储单元; x_t 等为不同时刻。

2.2 GRU 模型

GRU 是 Cho 等^[15]提出的一种简单的 LSTM 类型。与 LSTM 的不同之处在于,GRU 合并了输入门和遗忘门,并将其转换为一个更新门。因此,GRU 的参数比 LSTM 少,这使得训练更容易。对于 GRU, h_t 的输出值计算如下:

$$z_t = (W_z x_t + U_z h_{t-1} + b_z) \sigma, \quad (7)$$

$$r_t = (\mathbf{W}_r x_t + \mathbf{U}_r h_{t-1} + b_r) \sigma, \quad (8)$$

$$h_t = \tanh(\mathbf{W}_h x_t + (r_t h_{t-1}) \mathbf{U}_h), \quad (9)$$

$$h_t = h_t z_t + (1 - z_t) h_{t-1}, \quad (10)$$

式中： r 为一个复位门； z 为一个更新门。复位门表示新的输入如何与先前的记忆相结合，更新门表明以前的记忆被保留多少。如果更新门为 1，以前的记忆被完全保留；如果为 0，以前的记忆被完全遗忘。在 LSTM 中，有一个遗忘门，它自动决定以前的记忆被保留多少。而在 GRU 中，所有以前的记忆都被保留或完全遗忘。对于某些问题，GRU 可以提供与 LSTM 相当的性能，但对内存的要求较低^[15]。

2.3 LSTM - S2S 模型

Cho 等^[15]提出了一种结合编码器 (encoder) 和解码器 (decoder) 的神经网络结构，即 LSTM - S2S，它允许在不同的输入和输出时间步骤上建立模型，每部分相当于一个独立的 LSTM 模型 (图 4)。图 4 展示了 LSTM - S2S 模型的原理过程，encoder 将 m 步长时间序列数据作为输入，生成指定长度的向量 C 作为输出，存储在矢量层 (state vector)。decoder 将 n 个时间步长的向量 C 解码为隐藏层状态和单元状态作为输入，从而实现对每个 LSTM 单元预测。LSTM - S2S 模型进行地表水深预测， x_i 代表气象、径流等观测值， C_m 代表包含编码向量， h_m 代表隐藏层， y_i 代表地表水深。




图 4 LSTM - S2S 网络
Fig. 4 LSTM - S2S network

2.4 数据预处理

数据集的标准化是许多神经网络框架的一个共同要求。因此，对所有的气候和水文数据进行了均值归一化，确保数据保持在相同的尺度上，均值归一化的公式为：

$$x_{ij} = \frac{x_{ij} - \bar{x}_i}{\sigma_i}, \quad (11)$$

式中， x_{ij} 为时间 j 中的第 i 个原始数据； x_{ijn} 为第 i 个

变量在时间 j 中的归一化数据； $\bar{x}_i$ 和 σ_i 分别为时间 j 中第 i 个变量的平均数和标准差。

2.5 模型评价标准

本研究使用了 3 个评价标准，包括均方根误差 (root mean square error, RMSE) 和 R^2 。

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{n}}, \quad (12)$$

$$R^2 = \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2 - \sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (13)$$

式中： y_i 为时间 i 的测量值； $\bar{y}_i$ 为 y_i 的平均值； $\hat{y}_i$ 为时间 i 的预测值。RMSE 衡量预测精度，它通过对误差的平方来创建一个正值。RMSE 分数在 $[0, \text{精度}]$ 之间，如果 RMSE 为 0，模型的预测值为最准确。 R^2 衡量模型对结果的复制程度，范围在 $[-\infty, 1]$ 之间，对于最佳的模型预测， R^2 分数接近 1。

NSE 是一种流行的水文预测方法的评价指标，定义为：

$$NSE = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (14)$$

式中： y_i 为时间 i 的观测值； $\bar{y}_i$ 为时间 i 的预测结果； y 为所有观测值的平均值； n 为观测值的数量。 NSE 的范围在 $[-\infty, 1]$ 之间， NSE 越大意味着模型越好。

输入数据首先被放入 LSTM 层。LSTM 层的输入门将对输入数据进行重新组合，并决定哪些输入数据是重要的，这个过程类似于主成分分析 (principal component analysis, PCA)。LSTM 层可以保留以前的信息，这有助于提高模型学习时间序列数据的能力。为了提高模型的学习能力，在 LSTM 层的顶部设置了一个全连接层。此外，在 LSTM 层上还设置了丢弃率，以防止过度拟合。损失函数 (LOSS) 定义如下：

$$LOSS = \sum_{i=1}^N (y_i - \hat{y}_i)^2, \quad (15)$$

式中： y_i 为时间 i 的测量值； $\hat{y}_i$ 为时间 i 的预测值。

2.6 模型设定

为了确定这项工作的对象，设置了 3 个测试。首先，通过 LSTM, FFNN, GRU 和 LSTM - S2S 模型进行日地表水深训练和预测。评价标准包括 RMSE, R^2 和 LOSS。对于每个运行的模型，训练期为 2016 年 7 月 24—2019 年 4 月 19 日，测试期为 2019 年 4

月 19—2019 年 8 月 26 日。每个模型都是用随机梯度下降法(stochastic gradient descent,SGD)训练的。为了回答数据时间尺度对地表水深预测的影响,LSTM,LSTM-S2S 和 GRU 模型都用月数据预测了地表水深。这些数据来自月尺度数据集。这些结果与日模拟结果进行了比较和分析。

3 结果和讨论

3.1 不同模型的日尺度预测结果

地表水深模拟中使用了 2016—2019 年的每日数据。输入是降水、温度、水分和径流,输出是地表水深。选择 LSTM,FFNN,GRU 和 LSTM-S2S 模型来预测地表水深,训练期为 1 000 天(2016 年 7 月 24—2019 年 4 月 17 日),预测数据约为 130 天(2019 年 4 月 18—8 月 26 日)。在模型训练完成后,通过使

用验证集对每个模型进行验证,并对模型的超参数进行调整。利用 NSE,RMSE, R^2 和 LOSS 这 4 个性能指标来评估模型结果。

较高的学习率可能会导致优化任务错过最佳点,较低的学习率可能有助于避免超标,但可能导致模型需要更长的时间来收敛^[7]。本研究中,LSTM,FFNN 和 LSTM-S2S 的学习率为 0.001,而 GRU 的学习率为 0.01。具有大量参数的深度神经网络很容易出现过拟合,尤其是在数据有限的情况下。丢弃率可以帮助防止网络过于依赖层中的某些神经元,减少神经元的共同适应性。本研究通过不同的模型和训练,将丢弃率设置为 0.3~0.8。此外,由于学习率的影响,测试中的迭代次数从 1 000 到 18 000 不等。

在不同的实验中,通过迭代、丢弃率和学习率进行了敏感性分析。图 5 显示了在 0.3,0.5 和 0.8 的




图 5 使用本实验模型对每日测量和模拟的地表水深进行敏感性分析
Fig.5 Sensitive analysis on daily measured and simulated water table depth using the proposed models: FFNN ,LSTM ,GRU, LSTM-S2S

丢弃率下,不同迭代次数(1 000 到 18 000,GRU 从 1 000 到 1 800,LSTM,FFNN,LSTM-S2S 从 10 000 到 18 000)的 4 个模型的 R^2 和 NSE。笔者在每轮模拟中选择了 4 个模型的最佳评价标准(R^2 和 NSE),并以红色的虚线表示(图 5)。4 个模型的总体最佳表现进一步显示在图 6 和表 1 中。图 6 中用绿色虚线将数据分为训练组和验证组。表 1 列出了基于 LSTM,FFNN,GRU 和 LSTM-S2S 模型的敏感性分析的最佳模拟结果。

图 6 中展示了训练和测试的过程。从表 1 来

看,4 个模型的 R^2 从 0.85 ~ 0.94 不等, RMSE 从 0.03 ~ 0.11 m 不等,4 个模型的 NSE 处于 0.14 ~ 0.92 区间,LOSS 处于 16.07 ~ 128.33 区间。这些发现表明,所提出的基于 RNN 的模型(LSTM,GRU,LSTM-S2S)可以比 FFNN 模型更准确地预测地表水深。在 FFNN 模型中虽然 R^2 和 RMSE 都很好,但 NSE 为 0.14,LOSS 为 128.33。它也与图 6 中的其他 3 个模型进行了比较。FFNN 模型在验证数据集中的预测效果不好。之前的研究^[7]表明,FFNN 模型未能准确预测地表水深。因为它不能捕捉以前的




图 6 使用实验模型对日测量和模拟的地表水深进行比较

Fig. 6 Comparison of daily measured and simulated water table depth using the proposed models

表 1 不同模型中的最佳性能参数表							
Tab. 1 Best performance statistics in different models							
模型	迭代次数	丢弃率	学习率	均方根误差	决定系数	效率系数	损失
LSTM-S2S	14 000	0.3	0.001	0.03	0.92	0.92	16.07
LSTM	18 000	0.3	0.001	0.05	0.89	0.85	16.80
GRU	1 800	0.5	0.01	0.05	0.85	0.84	19.34
FFNN	10 000	0.5	0.001	0.11	0.94	0.14	128.33

信息,不能“记住”以前的地表水深,与其他 3 个基于 RNN 模型(LSTM,GRU 和 LSTM-S2S)相比,FFNN 模型的结构只包括拟合函数,不包括隐藏层。这就造成了与 LSTM,GRU 和 LSTM-S2S 模型相比,容易过拟合,学习能力不足。

从图 5、图 6 和表 1 的 R^2 ,NSE, RMSE 和 LOSS 来看,GRU 模型的表现与 LSTM 的表现同样出色。Gao 等^[16]在 2020 年,用 GRU 和 LSTM 网络预测径

流,他们的结果表明,当时间步长被优化时,LSTM 和 GRU 模型比 ANN 模型表现更好。与 LSTM 模型相比,GRU 模型的参数较少,结构也不复杂,但其性能与 LSTM 相当。GRU 可能是短期径流预测的首选方法,因为它需要较少的时间进行模型训练。我们的测试结果也显示 GRU 模型与 LSTM 一样好,这与 Gao 等^[16]的结论相同。

此外,在 3 个基于 RNN 的模型中,LSTM-S2S 模型的 R^2 和 NSE 最高,而 RMSE 和 LOSS 最低。LSTM-S2S 模型在每日水位深度方面显示出比 LSTM 和 GRU 更好的性能(图 6 和表 1)。根据先前的研究^[9],LSTM-S2S 模型在降雨径流模拟中的表现比 LSTM 模型更好。LSTM-S2S 模型显示出足够的预测能力,可用于提高短期洪水预报应用中的预测精度。编码器和解码器结合的方法被证明是水文领域时间序列预测的有效方法。本文研究表明,LSTM-S2S 模型在电力传输线地区的日水位模拟中具有最佳性能。对于现有的 LSTM-S2S 模型,编码器的最后一个 LSTM 单元的隐藏状态向量被视为状态向量,然后它被多次复制作为输入到解码器序列的那些 LSTM 单元。笔者在 LSTM-S2S 模型在测试中增加了一个由编码器和解码器过程组成的输入(降水、温度、湿度、径流)的训练过程(图 4)。综上所述,LSTM-S2S 模型的优势体现在日尺度地表

水深深度模拟中。

3.2 月尺度预测

本研究还测试了月度数据,以评估数据时间尺度对模型模拟的影响。从数据集中,选择了降水量、地表温度、土壤湿度作为输入,地表水深作为输出。训练数据集为 2000 年 1 月—2011 年 12 月,验证数据集范围为 2012 年 1 月—2013 年 12 月。

在验证数据集中月度数据的模拟性能为: R^2 处于 0.65 ~ 0.71, NSE 处于 0.60 ~ 0.71, RMSE 处于 0.83 ~ 1.04, LOSS 处于 4.70 ~ 23.58 区间(图 7,表 2)。图 7 中绿色虚线将数据分为 2 组:训练组和验证组。总体表现表明,LSTM-S2S 比 LSTM 和 GRU 好一点,因为它的 LOSS 最低,而 R^2 , NSE 和 RMSE 是封闭的。这一结果首先证明了 LSTM 模型模拟的日地表水深与月度数据一样好,将这一结果与 Zhang 等^[7]在中国内蒙古巴彦淖尔市内的河套灌区进行实验比较,证明了这一结果。其次,本研究证明 LSTM-S2S 和 GRU 也可以预测月度数据的地表水深。最后,在图 6 和图 7 的比较中,日数据的模拟性能优于月数据。LSTM,GRU 和 LSTM-S2S 模型的 R^2 和 NSE 的日平均结果都比月平均结果高。因为训练数据的数量在日数据中比在月数据中要高,所以模型获得了更多的训练信息,这使得日数据的预测结果比月数据的预测结果好。




图 7 使用实验模型对月测量和仿真的地表水深进行比较

Fig. 7 Comparison of monthly measured and simulated water table depth using the proposed models

表 2 LSTM、GRU 和 LSTM-S2S 模型中月度数据的性能

Tab. 2 Performance statistics of monthly data in LSTM, GRU, and LSTM-S2S models

模型	均方根误差	决定系数	效率系数	损失
LSTM	1.04	0.65	0.60	15.21
GRU	0.83	0.75	0.74	23.58
LSTM-S2S	0.89	0.71	0.71	4.70

4 结 论

本研究利用提出的 4 个模型 (LSTM、GRU、LSTM-S2S 和 FFNN) 来预测输电线路附近的地表水深。为了进一步研究数据时间尺度对模型模拟结果的影响, 首先将结果与在日数据模拟中使用各种模型得到的结果进行比较。然后使用 LSTM、GRU 和 LSTM-S2S 模型对月尺度数据进行预测实验, 并将其结果进行分析。本研究结论如下:

- 1) 对于日尺度预测模拟, LSTM-S2S 是 4 个模型中效果最佳的模型; 相比之下, FFNN 的表现最差。
- 2) LSTM、GRU 和 LSTM-S2S 模型在日和月尺度数据的地表水深模拟中均表现良好。
- 3) 在 LSTM、GRU 和 LSTM-S2S 模型中, R^2 和 NSE 的日平均结果都高于月平均结果。因此基于此结果可推断出, 模型可以广泛用于输电线路地区的地表水深的模拟和预测。

参考文献 (References):

[1] Wang J, Shi P, Jiang P, et al. Application of BP neural network algorithm in traditional hydrological model for flood forecasting[J]. Water, 2017, 9: 48.

[2] Batelaan O, De Smedt F, Triest L, et al. Regional groundwater discharge: Phreatophyte mapping, groundwater modelling and impact analysis of land-use change[J]. Journal of Hydrology, 2003, 275: 86-108.

[3] Bhattacharjee N V, Tollner E W, et al. Improving management of windrow composting systems by modeling runoff water quality dy-

namics using recurrent neural network[J]. Ecological Modelling, 2016, 339: 68-76.

[4] Kratzert F, Klotz D, Brenner C, et al. Rainfall-runoff modelling using Long Short-Term Memory (LSTM) networks[J]. Hydrology and Earth System Sciences, 2018, 22: 6005-6022.

[5] Schmidhuber J. Deep learning in neural networks: An overview[J]. Neural Networks, 2015, 61: 85-117.

[6] Halevy A, Norvig P, Pereira F. The unreasonable effectiveness of data[J]. IEEE Intelligent Systems, 2009, 24(2): 8-12.

[7] Zhang J, Zhu Y, Zhang 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: 918-929.

[8] Kao I, Zhou Y, Chang L, et al. Exploring a long short-term memory based encoder-decoder framework for multi-step-ahead flood forecasting[J]. Journal of Hydrology, 2020, 583: 124631.

[9] Xiang Z, Yan J, Demir I, et al. A rainfall runoff model With LSTM based sequence to sequence learning[J]. Water Resources Research, 2020, 56: 1-17.

[10] Shen Y, Xiong A Y, Wang Y, et al. Performance of high-resolution satellite precipitation products over China[J]. Journal of Geophysical Research, 2010, 115: 1-17.

[11] Rumelhart D E, Hinton G E, Williams R J, et al. Learning representations by back-propagating errors[J]. Nature, 1986, 323: 533-536.

[12] Hochreiter S. The vanishing gradient problem during learning recurrent neural nets and problem solutions[J]. International Journal of Uncertainty Fuzziness and Knowledge-based Systems, 1998, 6: 107-116.

[13] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.

[14] Gers F A, Schmidhuber J, Cummins F, et al. Learning to forget: Continual prediction with LSTM[J]. Neural Computation, 2000, 12: 2451-2471.

[15] Cho K, van Merriënboer B, Bahdanau D, et al. On the properties of neural machine translation: Encoder-decoder approaches[J]. In Proceedings of SSST-8, Eighth Workshop on Syntax, Semantics and Structure in Statistical Translation, 2014, 103-111.

[16] Gao S, Huang Y, Zhang S, et al. Short-term runoff prediction with GRU and LSTM networks without requiring time step optimization during sample generation[J]. Journal of Hydrology, 2020: 125188, doi: <https://doi.org/10.1016/j.jhydrol.2020.125188>.

A forecasting method for water table depths in areas with power transmission lines based on remote sensing and deep learning models

ZHANG Ke^{1,2,3}, ZHANG Gengsheng^{1,2}, WANG Ning⁴, WEN Jing⁴, LI Yu^{1,2}, YANG Jun⁵
(1. State Grid Electric Power Research Institute, Hefei 230088, China; 2. Anhui NARI Jiyuan Electric Power System Tech Co., Ltd, Hefei 230088, China; 3. University of Science and Technology of China, Hefei 230088, China; 4. China Aero Geophysical Survey and Remote Sensing Center for Natural Resources, Beijing 100083, China; 5. State Grid Hangzhou Power Supply Company, Zhejiang Electric Power Co., Ltd., Hangzhou 310000, China)

Abstract: Areas with power transmission lines have been frequently struck by flood disasters in recent years. Therefore, forecasting the water table depths in these areas is critical to the safety of these areas. This study

forecasted the water table depth using remote sensing satellite products and observed meteorological and hydrological data. Based on the meteorological and hydrological data, this study forecast the daily and monthly water table depths using the long short – term memory (LSTM), gated recurrent unit (GRU), long short – term memory – seq2seq (LSTM – S2S), and feedforward neural network (FFNN) models. The results indicate that the LSTM – S2S and FFNN models delivered the best and the worst performances, respectively. Meanwhile, the LSTM, GRU, and LSTM – S2S models performed well in forecasting both daily and monthly water table depths, with their forecasts of daily water table depths having a higher coefficient of determination (R^2) and a Nash – Sutcliffe efficiency coefficient (NSE) than those of monthly water table depths. Therefore, the method presented in this study can be used to forecast the future daily and monthly water table depths in areas with power transmission lines.

Keywords: deep learning model; GRU; LSTM – S2S; LSTM; water table depth

(责任编辑: 李 瑜)