

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

李明伟

(中煤科工集团沈阳设计研究院有限公司, 辽宁 沈阳 110015)

摘要: [目的] 准确模拟和预测不同水保工程措施下土壤侵蚀量, 为辽西北地区精准预测土壤侵蚀量提供技术和理论依据。[方法] 基于野外径流小区 2011—2021 年的监测数据, 包括: 最大 30 min 和 60 min 降雨强度(I_{30} 和 I_{60})、降雨历时(T)、降雨量(P) 和土壤侵蚀量, 建立了长短期记忆神经网络(LSTM) 分别对 3 种工程措施(水平槽、果树台田和梯田) 下的土壤侵蚀量进行预测。并将 LSTM 预测结果与 3 个经典机器学习模型[反向传播神经网络(BP)、随机森林(RF) 和支持向量机(SVM)] 预测的结果进行对比。[结果] ①在 3 种工程措施中, I_{30} 、 I_{60} 、 T 和 P 对土壤侵蚀量的影响程度不同, 但 I_{30} 、 I_{60} 和 T 对土壤侵蚀量的影响大于 P 。②利用 BP 模型预测土壤侵蚀量的相对均方根误差(NRMSE) 均大于 0.2。③相比于 RF 和 SVM 模型, LSTM 模型在 3 种工程措施下(水平槽、果树台和梯田) 预测土壤侵蚀量的 NRMSE 分别降低了约 0.04~0.08, 0.02~0.08, 0.05~0.08。④利用 I_{30} 和 T 作为 LSTM 模型的输入特征预测土壤侵蚀量的精度与使用 I_{30} 、 I_{60} 、 T 和 P 为输入特征时的预测精度相近。[结论] 在辽西北地区 3 种水保工程措施中, 利用 LSTM 模型基于最大 30 min 雨强和降雨历时对土壤侵蚀量进行预测, 取得了较其他传统模型高的预测精度。这说明 LSTM 模型可在同类地区土壤侵蚀量的精准模拟和确定水土保持措施中推广和应用。

关键词: 土壤侵蚀量; 水土保持工程; 机器学习模型; 长短期记忆神经网络; 深度学习模型; 辽西北地区
文献标识码: B **文章编号:** 1000-288X(2023)04-0162-08 **中图分类号:** S157.1

文献参数: 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[J]. 水土保持通报, 2023, 43(4): 162-169. DOI: 10.13961/j.cnki.stbctb.20230508.010; Li Mingwei. Estimating soil erosion under different soil and water conservation engineering measures using LSTM model [J]. Bulletin of Soil and Water Conservation, 2023, 43(4): 162-169.

Estimating Soil Erosion Under Different Soil and Water Conservation Engineering Measures Using LSTM model

—A Case Study in Northwest Liaoning Province

Li Mingwei

[China Coal Technology and Engineering Group (CCTEG)

Shenyang Engineering Company, Shenyang, Liaoning 110015, China]

Abstract: [Objective] The soil erosion under different conservation engineering measures was precisely predicted in order to provide a technical and theoretical basis for formulating appropriate conservation measures in Northwest Liaoning Province. [Methods] We used experimental plot data from 2011 to 2021 that included maximum precipitation intensity in 30 and 60 minutes (I_{30} and I_{60}), precipitation duration (T), and precipitation (P) to construct a long short-term memory neural network model (LSTM) to predict soil erosion under three different water-and-soil conservation measures (horizontal trough, fruit tree terrace, terrace). Results from the LSTM model were compared with the results of three classical machine learning models, i.e., artificial neural networks (BP), random forest (RF), and support vector machine (SVM). [Results] ① The impacts of I_{30} , I_{60} , T , and P on soil erosion were different for the three different conservation conditions, but in general, I_{30} , I_{60} , and T had significant impacted on soil erosion. ② The normal relative

收稿日期: 2022-09-28

修回日期: 2023-01-17

资助项目: 中煤科工集团沈阳设计研究院有限公司科研基金项目“神东煤炭矿区采煤沉陷区耕地复垦技术研究”(NK002-2021)

第一作者: 李明伟(1984—), 男(汉族), 辽宁省朝阳市人, 学士, 高级工程师, 主要从事水土保持监测、水土保持监理方向研究。Email: lm-wmt1984@163.com.

mean square error (NRMSE) of the BP model under the three different water-and-soil conservation measures were all greater than 0.2. ③ Compared with the RF and SVM models, the LSTM model decreased NRMSE by 0.04~0.08, 0.02~0.08, and 0.05~0.08 under the three different water-and-soil conservation measures, respectively. ④ The LSTM model based on only two input features (I_{30} and T) had a similar accuracy with the LSTM model based on four input features in predicting soil erosion. [Conclusion] The LSTM model was used to predict the soil erosion amount based on the maximum 30 min rainfall intensity and rainfall duration, and the prediction accuracy was higher than other traditional models. This shows that the LSTM model can be popularized and applied in the accurate simulation of soil erosion and the determination of soil and water conservation measures in similar areas.

Keywords: soil erosion; soil and water conservation engineering; machine learning model; long short-term memory neural network model; deep learning model; Northwest Liaoning Province

水土流失是中国面临的主要环境问题之一^[1]。据统计,2021年中国水土流失面积达到了 $2.67 \times 10^6 \text{ km}^2$ ^[2]。研究表明,降雨是水土流失的主要动力^[3]。一般来说,降雨强度和降雨量对水土流失的影响最大^[3-4]。肖继兵等^[5]研究发现 I_{30} 与土壤侵蚀量之间存在显著的正相关关系。大量研究探索了不同降雨特征对土壤侵蚀量的影响。但定量描述降雨特征和土壤侵蚀量之间的关系对合理确定水保措施,降低水土流失具有更重要的现实意义。

目前,对不同降雨特征下土壤侵蚀量确定,主要采用传统的实地监测方法^[3],但该方法成本较大。为此,一些学者使用模型对不同降雨特征下土壤水土流失量进行了预测模拟,其中最著名的5个传统物理和经验模型是修正的土壤流失方程(RUSLE)、通用土壤流失方程(USLE)、水土预测模型(WEPP)、水土评估模型(SWAT)和水土侵蚀模型(WATEM)等^[6]。Zhang Hua等^[7]使用RUSLE模型基于降雨、土壤、植被覆盖、坡度和水土保持能力等5个参数,对兰州市水土流失量进行了模拟,并取得了良好的模拟效果。但该模型计算过程复杂,需要参数较多。综上所述,使用传统的监测和模型方法确定土壤侵蚀量具有成本高和过程复杂等缺点。近些年,随着机器学习算法的发展,并且机器学习模型能够有效拟合特征和目标变量之间的线性和非线性关系^[8]。因而,一些学者开始使用机器学习模型对土壤侵蚀量进行预测。关于利用机器学习模型对土壤侵蚀量的研究也大致经历了3个阶段。第一阶段,众多学者开始关注单一机器学习模型对土壤侵蚀量的预测。Rahmati等^[9]比较了7个经典机器学习模型对土壤侵蚀量预测的精度,最终发现SVM模型对土壤侵蚀量预测精度最高。在这个阶段SVM模型在众多的研究中均取得了较高的精度^[9]。第二阶段,考虑到单一机器学习模型虽然可以在预测土壤侵蚀量的任务中取得一定的精度,但不同的机器学习模型具有不同的特点。因此,大量

研究开始关注集成学习模型对土壤侵蚀量的预测。通过不同的算法,将不同的机器学习模型进行集合。在此阶段使用较多方法是基于stacking,boosting和bagging算法对相同和不同机器学习模型进行集合^[6]。Zhang Yonghong等^[10]比较了XGBoost和单一经典模型对土壤侵蚀量的预测精度,发现XGBoost模型对土壤侵蚀量的预测精度最高。Nguyen等^[6]将基于bagging算法的随机森林模型和基于boosting算法的GBM模型与传统的机器学习模型(线性回归、BP神经网络、SVM模型等)进行了比较,结果发现GBM模型对土壤侵蚀量的预测精度最高。在该阶段RF模型和基于boosting算法的集成学习模型取得了较高的预测精度。第三阶段,随着近些年深度学习模型的发展,如卷积神经网络、残差神经网络、循环神经网络等,一些学者开始探索深度学习模型对土壤侵蚀量的预测。但研究表明并非所有深度学习模型对土壤侵蚀量的预测结果均高于集成学习算法。如,Sahour等^[8]使用多元线性回归模型、基于boosting的集成学习模型和深度学习模型对土壤侵蚀量进行了预测,结果发现基于boosting的集成学习模型预测土壤侵蚀量的精度最高。虽然使用机器学习模型对土壤侵蚀量的预测取得了一定的成果,但这些模型在预测土壤侵蚀量时,仅仅只考虑了当前的特征。实际上,降雨特征对土壤侵蚀量的影响具有累积效应,即土壤侵蚀量会受到历史降雨等特征的影响。为增加模型的预测精度,一些学者将前期的降雨或土壤特征作物特征输入预测当前的土壤侵蚀量,并且提高了模型的预测精度。但该方法增加了特征的选择难度,而且具有一定的经验性。实际上,土壤侵蚀量的预测是一个时间序列问题,因而使用擅长处理时间序列的机器学习模型,如循环神经网络(RNN)、长短期记忆神经网络(LSTM)等会提升模型对土壤侵蚀量的预测精度^[11]。研究表明长短期记忆神经网络模型(LSTM)可以“记住”历史特征,因而在大量研

究中取得了较高的精度,被认为是处理时序变量回归任务时的首选模型^[12]。目前,LSTM 模型在预测土壤侵蚀量的研究中仍不多见。另外,监测土壤侵蚀量的影响特征,如降雨量、降雨历时,最大 30 min 和 60 min 降雨强度也会增加工作量。因而探索基于少量重要特征对土壤侵蚀量进行精准预测,对降低成本和提高预测土壤侵蚀量效率具有重要意义。为探究 LSTM 模型利用重要降雨特征对土壤侵蚀量预测的可行性,本文以 2011—2021 年水土流失动态监测站数据为基础,首先综合评价了 4 个降雨特征(I_{30} , I_{60} , T 和 P)对于预测土壤侵蚀量的重要性。然后使用 LSTM 模型分别利用 2 个最重要的特征和全部 4 个特征对 3 种水保工程措施条件下土壤侵蚀量进行预测,并将预测结果与传统机器学习模型(BP, RF 和 SVM)预测的结果进行对比。以期为辽西北地区土壤侵蚀量的精准预测和合理制定水土保持措施提供理论和技术依据。

1 材料与方法

1.1 研究区概况与数据收集

本研究基础数据(2011—2021 年)来源于辽宁省朝阳市朝阳县东大道小流域全国水土流失动态监测站(120°01′00″E, 41°26′00″N)。监测站平均降雨量、风速、气温分别为 450 mm, 2.9 m/s 和 8.2 °C。监测站中有 3 个典型水保工程措施(监测小区),分别为水平槽、果树台田和梯田。径流小区内土壤为褐土,土壤容重为 1.13 g/cm³。监测小区投影长度、宽度和坡度分别为 20 m, 5 m 和 12°。小区末端设有长度为 5 m, 宽度为 0.6 m 的集流槽,且流槽上缘与地面同高,确保小区地表径流汇入槽内。槽壁采用水泥抹面,确保水流面光滑;底部向下及向中间倾斜,保证水流顺利汇入分流桶。小区径流经集流槽流入分流桶,分流桶为砖混结构,根据当地降雨及产流情况,确定分流桶长宽高均为 1 m,设 1 个分流孔。分流孔距分流桶底面 60 cm。分流桶下方设置集流桶,规格为 1 m×1 m×1 m,收集径流量较大时由分流桶流入的清水,下部设放水孔 1 处。每次降雨之后,测定分流桶深度,计算总的径流量。随后通过混匀样本,采用烘干法测定泥沙浓度,计算土壤流失量。气象数据由监测站附近的人工气象观测站及 TRM-ZS2 型自动气象站观测^[13]。本研究中将间隔时间超过 6 h 的两次降雨,定义为两次降雨事件。通过对 2011—2021 年监测数据和侵蚀数据的整理,本文共计得到 177 条数据每条数据记录包含 4 个降雨特征(I_{30} , I_{60} , T 和 P)和土壤侵蚀量。本文中水平槽中土壤侵

蚀量的最小值、最大值和标准差分别为 0.34, 17.15 和 5.89 kg;果树台田中为 0.06, 13.38, 4.0 kg;梯田中为 0.14, 40.38, 9.9 kg。该结果表明本研究土壤侵蚀量波动较大。

1.2 模型介绍

随机森林模型(RF):随机森林是基于 bagging 集成算法的一种拓展^[14]。它是在以决策树为基本学习器,使用 bagging 集成学习算法的基础上,进一步采用自助采样法对特征进行随机选择,使得由决策树构成的“森林”中每一棵“树”均不一样^[15]。建立随机森林模型主要是对于决策树数量的选择及每一个决策树的内部结点数和叶结点数量的确定。因此本文在建模过程中主要是对这 3 个参数进行率定。支持向量机模型(SVM):支持向量机基本思路是将给定的数据集正确分开,同时使得不同类别之间的间隔最大化^[16]。建立支持向量机模型时需要选择核函数 gamma 和损失参数 C ,因此本文对参数 gamma 和 C 进行率定。本文采用的 BP 神经网络是指含有 2 个隐含层的 BP 神经网络模型。前一层和后一层之间通过全连接方式连接。根据 BP 神经网络的原理,本文在建立 BP 神经网络模型时,选择 Relu 函数为激活函数^[17]。这是因为 Relu 激活函数相比于传统的 sigmoid 函数,有效解决了梯度消失问题,同时还能使模型的收敛速度维持在一个稳定的范围之内^[18-19]。

长短期记忆神经网络(LSTM):LSTM 模型是经典的循环神经网络,且 LSTM 中的记忆单元能够“记住”历史信息,从而提高当前的预测精度。本文使用的长短期记忆神经网络结构图如图 1 所示^[20]。LSTM 具体计算过程如公式(1)—(6)^[11]:

$$f_t = \text{sigmoid}(W_f h_{t-1} + U_f X_t + b_f) \quad (1)$$

$$i_t = \text{sigmoid}(W_i h_{t-1} + U_i X_t + b_i) \quad (2)$$

$$C'_t = \tanh(W_c h_{t-1} + U_c X_t + b_c) \quad (3)$$

$$C_t = f_t C_{t-1} + i_t C'_t \quad (4)$$

$$O_t = \text{sigmoid}(W_o h_{t-1} + U_o X_t + b_o) \quad (5)$$


$$h_t = O_t \tanh(C_t) \quad (6)$$

式中:sigmoid, tanh 为激活函数; f_t , i_t 分别为考虑了 t 时间点的输入 X_t 和 $t-1$ 时间点输出 h_{t-1} 的结果; C'_t , C_{t-1} 分别为忘记矩阵和记忆矩阵; C_t 为新的记忆矩阵; O_t 为没有进行选择的输出; h_t 为经过选择的最终输出。从公式(4)—(5)中可以看出,最终的预测输出由 O_t 和 C_t 计算得到,而 O_t 和 C_t 不仅与当前输入 X_t 有关,也和上一个输出 h_{t-1} 有关。因而,LSTM 可以“历史”信息对当前的影响。另外,由公式(4)和图 1 中可以发现,记忆矩阵 C_t 也在进行更新,因而 LSTM 模型在不断训练会加强对重要信息的记忆。

1.3 模型的建立与评估

本研究采用 Python 3.0 中 Scikit-learn 库对 BP, RF 和 SVM 模型进行建立和训练。本研究中,使用 Python 3.0 中 TensorFlow 2 库对 LSTM 模型进行建立和训练。本文将收集到的 177 条记录分成训练集和测试集两个部分。首先根据 80%训练集和 20%训练集对总样本进行分割,同时考虑到本研究中样本

数量较少,增加了测试样本量。最终确定训练集 152 条和测试集 25 条。另外,数据按时间序列排序分割。其中模型参数的选择使用 3-折交叉验证的方法,即将训练集样本随机分成 3 份,依次取其中 2 份样本训练模型,剩下 1 份样本验证模型,最终选出合适的参数。采用相关系数(R^2)和相对均方根误差(NRMSE)两个判断指标作为模型预测精度好坏的评价指标^[12]。



注: sigmoid, tanh 为激活函数, f_t, i_t 分别为 t 时间点的输入 X_t 和 $t-1$ 时间点输出 h_{t-1} 的结果; C'_t, C_{t-1} 分别为忘记矩阵和记忆矩阵; C_t 为新的控制矩阵; O_t 为没有进行选择的最初输出; h_t 为进行选择后的最终输出。


图 1 LSTM 模型基本结构
Fig.1 Structure of LSTM model

2 结果与讨论

2.1 基于随机森林的特征选择

从图 2 可知,研究区不同的水土保持措施下, I_{30}, I_{60}, T 和 P 对土壤侵蚀量的影响程度不同。在水平槽中降雨因素对土壤侵蚀量的影响程度为: $I_{30} > I_{60} > T > P$; 在果树台中降雨因素对土壤侵蚀量的影响程度为: $T > I_{30} > I_{60} > P$; 在梯田中降雨因素对土壤侵蚀量的影响程度为: $I_{30} > T > I_{60} > P$ 。该结果与之前使用模糊贴近度法的计算结果类似^[21]。

由图 2 还可以看出, I_{30}, I_{60} 和 T 在 3 种水土保持措施中对土壤侵蚀量的影响均达到了显著水平。该结果与林锦阔等^[4]研究结果类似,认为 I_{30} 和降雨历时是影响土壤侵蚀量的主要原因。然而,陈钊柱等^[3]研究发现降雨量与土壤侵蚀量之间存在显著的正相关关系。这种不一致的结果可能是由于降雨特征所在地区不同和土壤理化性质不同造成的^[22]。综上所述,基于随机森林模型, I_{30}, I_{60} 和 T 是该地区影响土壤侵蚀量的主要降雨特征。为了提高模型的预测精度,同时也为了降低监测降雨特征的工作量,本研究选择 I_{30} 和 T 作为输入特征对土壤侵蚀量进行预测,并将该结果与使用全部 4 个降雨特征作为输入特征预测的土壤侵蚀量进行对比。



注: I_{30}, I_{60}, T 和 P 分别为最大 30 min 和 60 min 降雨强度、降雨历时和降雨量。

图 2 研究区各特征因子对土壤侵蚀量的重要性程度
Fig.2 Importance of characteristic factors to soil erosion in study area

2.2 水平槽中土壤侵蚀量预测

表 1 列出了分别使用 2 个特征 (I_{30} 和 T) 和 4 个特征 (I_{30}, I_{60}, T 和 P) 对研究区水平槽中土壤侵蚀量的预测精度。从表 1 可以看出, BP 模型在训练集和验证集上的 NRMSE 均大于 0.2, 表明 BP 模型对水平槽中土壤侵蚀量预测精度较低。RF 和 SVM 模型在训练集和验证集上的 NRMSE 虽然小于 0.2, 但均大于 0.15, 表明 RF 和 SVM 模型在预测水平槽工程中土壤侵蚀量时精度一般。与 RF 和 SVM 模型相

比, LSTM 模型提高了 R^2 约 0.03~0.08, 同时降低了 NRMSE 约 0.04~0.08(表 1)。该结果说明, 对于水平槽工程中土壤侵蚀量的预测, LSTM 模型的精度最高。另外, LSTM 模型在训练集和验证集上的 NRMSE 最大为 0.12, 最小为 0.06, 表明 LSTM 模型预测水平槽工程中土壤侵蚀量达到了较高的精度。在 4 个模型中, LSTM 模型的精度最高, SVM 和 RF 次之, BP 模型最低。这是因为 LSTM 模型考虑了时间序列对水平槽工程中土壤侵蚀量的影响。在本研究中, LSTM 模型考虑了前两次降雨对当前土壤侵蚀量的影响。该结果与 Chen Zhijun 等^[12] 研究结果类似, 认为与传统机器学习模型(BP, RF, SVM 和线性回归模型等)相比, 深度学习模型(尤其是考虑时间变化的 LSTM 模型)对目标变量的预测精度更高。从表 1 还可以看出, 在仅使用 I_{30} 和 T 两个特征时, 在验证集上, LSTM 模型对水平槽中预测土壤侵蚀量的 NRMSE 为 0.11。在使用全部 4 个特征(I_{30} , I_{60} , T 和 P)时, LSTM 模型水平槽工程中预测土壤侵蚀量的 NRMSE 为 0.09。该结果表明, 在增加两个特征后, LSTM 模型的精度并未得到显著提高。从图 3 中可以看出, 在 2 特征和 4 特征情景中, 虽然在一些观测点上 LSTM 预测的土壤侵蚀量与实测土壤侵蚀量之间的相对误差较大, 但多数观测点上 LSTM 模型的预测值与实测值之间误差较低, 且总体上误差也在

可接受范围内(表 1)。LSTM 模型在一些观测点上产生较大的相对误差, 这可能是因为样本数据中土壤侵蚀量波动较大。从图 3 还可以看出, 虽然基于 4 特征的 LSTM 模型的相对误差较小, 但基于 2 特征的 LSTM 模型总体误差也较低(表 1)。因此, 在水平槽工程中 LSTM 模型使用 I_{30} 和 T 这 2 个特征可以较准确预测土壤侵蚀量。这是因为在水平槽工程中, I_{30} 和 T 对土壤侵蚀量具有显著影响。综上所述, 在水工槽中, 相比于 BP, RF 和 SVM 模型, LSTM 模型对土壤侵蚀量的预测精度最高。同时, LSTM 使用 I_{30} 和 T 作为特征和使用全部 4 个特征(I_{30} , I_{60} , T 和 P)对土壤侵蚀量的预测精度没有显著差异。

表 1 各模型在研究区水平槽中预测土壤侵蚀量的精度
Table 1 Precision of models in predicting soil erosion of horizontal channel in study area

数据集	模型	2 特征		4 特征	
		R^2	NRMSE	R^2	NRMSE
训练集	BP	0.82	0.25	0.88	0.22
	RF	0.89	0.18	0.91	0.15
	SVM	0.92	0.16	0.93	0.13
	LSTM	0.95	0.12	0.97	0.06
验证集	BP	0.84	0.23	0.80	0.24
	RF	0.88	0.19	0.89	0.18
	SVM	0.91	0.19	0.92	0.16
	LSTM	0.99	0.11	0.99	0.09





图 3 研究区水平槽中 LSTM 模型预测值与实测值对比

Fig.3 Comparison between LSTM-predicted value and measured value of horizontal channel in study area

2.3 果树台中土壤侵蚀量预测

表 2 列出了在果树台田措施中, 各模型预测土壤侵蚀量的 R^2 和 NRMSE。从表 2 可以看出, 在果树台田措施中, BP 模型在训练集和验证集上的 R^2 为 0.83~0.84, 处于较高水平, 表明 BP 模型预测的土壤侵蚀量的趋势与实测土壤侵蚀量的趋势较为一致。但 BP 模型在训练集和验证集上的 NRMSE 较大, 均大于 0.2。该结果说明使用 BP 模型预测果树台田措

施中土壤侵蚀量的误差较大。RF 和 SVM 模型的预测精度相近, 在预测果树台田措施中土壤侵蚀量的 R^2 和 NRMSE 分别为 0.87~0.91, 0.12~0.19。该结果表明 RF 和 SVM 模型的预测精度较好。与 RF 和 SVM 模型相比, LSTM 模型提高了 R^2 约 0.08~0.11 和降低了 NRMSE 约 0.02~0.08。该结果说明 LSTM 模型对果树台田措施中土壤侵蚀量的预测精度最高。传统的机器学习模型, 如 BP, RF 和 SVM,

在预测土壤侵蚀量时仅考虑了本次降雨特征对土壤侵蚀量影响。而 LSTM 模型通过内部的记忆单元可以记住之前降雨特征对土壤侵蚀量的影响。在实际中,前一次降雨对土壤的侵蚀会影响下一场降雨对土壤侵蚀量的影响,尤其是两次降雨事件接近时。因此,LSTM 在众多时序数据的预测研究中取得了较高的精度^[22]。在使用 2 特征和 4 特征情景中,LSTM 模型在验证集上的 R^2 均为 0.99,说明 LSTM 模型能够很好地预测土壤侵蚀量的变化趋势。这是因为在实际中,降雨特征与土壤侵蚀量之间的线性关系较强,而 LSTM 模型能够通过时间序列的记忆,很好地处理线性和非线性关系^[23]。但 LSTM 在 2 特征和 4 特征情景中预测果树台中土壤侵蚀量的 NRMSE 均大于 0.1。该结果说明,LSTM 在预测精度方面不如预测趋势精确。但是,LSTM 在 2 特征和 4 特征情景中预测果树台中土壤侵蚀量的 NRMSE 分别为 0.13,0.11,说明 LSTM 对果树台中土壤侵蚀量的预测精度较高。同时,使用 2 特征和 4 特征对土壤侵蚀量预测的精度类似。从图 4 也可以看出,LSTM 模型在 2 特征和 4 特征情景中对土壤侵蚀量预测的相对误差相近。虽然在有些观测点上相对误差较大,但多数点的相对误差较低。该结果说明,LSTM 模型使用 2 个特征预测土壤侵蚀量时精度较好。LSTM

模型使用 4 个特征预测土壤侵蚀量的精度并没有显著优于使用 2 个特征预测土壤侵蚀量的精度。这可能是因为:①本研究中使用的两个特征(I_{30} 和 T)是影响果树台田措施中土壤侵蚀量的主要降雨特征(图 2);②4 个降雨特征 I_{30}, I_{60}, T 和 P 之间存在相关性,因此有些特征对于预测土壤侵蚀量来说是冗余信息^[24]。综上所述,在果树台田措施中,LSTM 模型的预测精度最高。同时,LSTM 仅使用最重要的两个降雨特征(I_{30} 和 T)即可较准确地预测土壤侵蚀量。

表 2 各模型在果树台田中预测土壤侵蚀量的精度

Table 2 Precision of models in predicting soil erosion of fruiter terrace lands

数据集	模型	2 特征		4 特征	
		R^2	NRMSE	R^2	NRMSE
训练集	BP	0.84	0.22	0.85	0.25
	RF	0.87	0.19	0.91	0.17
	SVM	0.88	0.17	0.89	0.12
	LSTM	0.98	0.09	0.97	0.07
验证集	BP	0.84	0.23	0.83	0.23
	RF	0.88	0.18	0.89	0.17
	SVM	0.88	0.15	0.91	0.17
	LSTM	0.99	0.13	0.99	0.11




图 4 果树台田中 LSTM 模型预测值与实测值对比


Fig.4 Comparison between LSTM-predicted value and measured value of fruiter terrace lands

2.4 梯田中土壤侵蚀量预测

表 3 列出了 BP,RF,SVM 和 LSTM 模型对梯田中土壤侵蚀量的预测精度。从表 3 可以看出,4 个模型预测梯田中土壤侵蚀量的 R^2 均大于 0.79。该结果说明,4 个模型均能很好预测梯田中土壤侵蚀量的变化趋势。但 BP 模型在训练集和验证集上预测梯田中土壤侵蚀量的 NRMSE 均大于 0.2,说明 BP 模型对梯田中土壤侵蚀量的预测精度较低。与在水平槽和果树台田措施中类似,在梯田中 RF 和 SVM 模型

的预测精度相近。从表 3 可以看出,RF 和 SVM 模型预测梯田中土壤侵蚀量的 NRMSE 均相差 0.01~0.03。与大多数结果一致,在传统机器学习模型中,RF 和 SVM 模型在回归和分类任务中均取得了较高的精度^[25]。但与深度学习模型相比,RF 和 SVM 模型的精度较低。相比于 RF 和 SVM 模型,LSTM 模型降低了 NRMSE 约 0.05~0.08(表 3)。主要原因与在水平槽和果树台中类似:LSTM 模型通过长短期记忆单元,在预测土壤侵蚀量的同时不仅考虑了本

次降雨特征的影响,还考虑了之前降雨特征的影响^[25]。此外,在 2 特征和 4 特征情景中,LSTM 模型预测梯田中土壤侵蚀量的 NRMSE 分别为 0.12, 0.09。该结果表明,相比于 2 特征情景,在 4 特征情景中 LSTM 模型预测梯田中的土壤侵蚀量提高了 0.03。从图 5 也可以看出,LSTM 模型使用 2 特征和 4 特征预测的梯田土壤侵蚀量与实测值之间差异分别为 0.65%~489.7%和 0.18%~184.8%。LSTM 模型在一些观测点上产生较大的相对误差,这可能是由于样本数据中土壤侵蚀量波动较大。但总体上 LSTM 使用 2 个重要降雨特征(I_{30} 和 T)预测梯田中土壤侵蚀量时,仍然取得了较高的精度(表 3)。一方面, I_{30} 和 T 是影响梯田中土壤侵蚀量最重要的两个特征。另一方面,降雨特征之间存在线性相关。例如, I_{30} 和 I_{60} 之间通常存在显著的正相关关系^[5]。综上



所述,在梯田中,相比于传统的机器学习模型,LSTM 模型预测土壤侵蚀量的精度最高。同时,基于 LSTM 模型,使用 I_{30} 和 T 可以较为准确地预测土壤侵蚀量。

表 3 各模型在梯田中预测土壤侵蚀量的精度

Table 3 Precision of models in predicting soil erosion of terrace

数据集	模型	2 特征		4 特征	
		R^2	NRMSE	R^2	NRMSE
训练集	BP	0.79	0.27	0.80	0.20
	RF	0.83	0.18	0.86	0.17
	SVM	0.85	0.17	0.87	0.14
	LSTM	0.92	0.12	0.97	0.09
验证集	BP	0.73	0.27	0.80	0.23
	RF	0.85	0.17	0.85	0.15
	SVM	0.83	0.19	0.84	0.17
	LSTM	0.99	0.12	0.99	0.09




图 5 梯田中 LSTM 模型预测值与实测值对比

Fig.5 Comparison between LSTM-predicted value and measured value of terrace

3 结论

以 2011—2021 年水土流失动态监测站数据为基础,首先综合评价了 4 个降雨特征(I_{30} , I_{60} , T 和 P)对于预测土壤侵蚀量的重要性。然后使用 LSTM 模型分别利用 2 个最重要的特征(I_{30} 和 T)和全部 4 个特征分别对 3 种水保工程措施条件下土壤侵蚀量进行预测。主要结论为:

(1) 在水平槽、果树台田和梯田 3 种水保工程措施中, I_{30} , I_{60} 和 T 对土壤侵蚀量有显著影响;

(2) 在水平槽、果树台田和梯田 3 种水保工程措施中,使用 I_{30} , I_{60} , T 和 P 变量时,LSTM 模型对土壤侵蚀量的预测精度最高,RF 和 SVM 次之,BP 模型最低;

(3) 在水平槽、果树台田和梯田 3 种水保工程措施中,仅使用 I_{30} 和 T 两个变量,LSTM 模型对土壤侵蚀量的预测取得了较高的精度。综上所述,LSTM 模型在辽西北地区水平槽、果树台和梯田 3 种水保工

程措施中,对土壤侵蚀量的预测精度高于传统的神经网络、支持向量机和随机森林模型,为辽西北地区合理制定水土保持措施提供理论和技术依据。

[参 考 文 献]

- [1] Zhao Jianlin, Wang Zhengang, Dong Yifan, et al. How soil erosion and runoff are related to land use, topography and annual precipitation: insights from a meta-analysis of erosion plots in China [J]. Science of the Total Environment, 2022,802:149665.
- [2] 于珊.我国水土流失面积和强度继续保持“双降”[OL]. 北京:新华社,2022-06-28. http://www.gov.cn/xinwen/2022-06/28/content_5698072.htm.
- [3] 陈钊柱,蔡卓杰,谢福倩,等.自然降雨对广西赤红壤坡地土壤侵蚀特征的影响[J].水土保持通报,2022,42(3):36-42.
- [4] 林锦阔,李子君,许海超,等.降雨因子对沂蒙山区不同土地利用方式径流小区产流产沙的影响[J].水土保持通报,2016,36(5):7-12.

- [5] 肖继兵,孙占祥,蒋春光,等.辽西地区农耕地土壤侵蚀影响因素及相关关系[J].水土保持学报,2015,29(5):13-19.
- [6] Nguyen K A, Chen W, Lin B S, et al. Comparison of ensemble machine learning methods for soil erosion pin measurements [J]. *Isprs International Journal of Geo-Information*, 2021,10(1):42.
- [7] Zhang Hua, Lei Jinping, Wang Hao, et al. Study on dynamic changes of soil erosion in the North and South Mountains of Lanzhou [J]. *Water*, 2022,14(15):2388.
- [8] Sahour H, Gholami V, Vazifedan M, et al. Machine learning applications for water-induced soil erosion modeling and mapping [J]. *Soil and Tillage Research*, 2021, 211:105032.
- [9] Rahmati O, Tahmasebipour N, Haghizadeh A, et al. Evaluation of different machine learning models for predicting and mapping the susceptibility of gully erosion [J]. *Geomorphology*, 2021,298:118-137.
- [10] Zhang Yonghong, Ge Taotao, Tian Wei, et al. Debris flow susceptibility mapping using machine-learning techniques in Shigatse area, China [J]. *Remote Sensing*, 2019,11(23):2801.
- [11] Senanayake S, Pradhan B, Alamri A, et al. A new application of deep neural network (LSTM) and RUSLE models in soil erosion prediction [J]. *Science of The Total Environment*, 2022,845:157220.
- [12] Chen Zhijun, Zhu Zhenchuang, Jiang Hao, et al. Estimating daily reference evapotranspiration based on limited meteorological data using deep learning and classical machine learning methods [J]. *Journal of Hydrology*, 2020,591:125286.
- [13] 李明伟.辽西地区不同水土保持措施条件下土壤侵蚀量与降雨因子关系研究[J].*中国水土保持*,2018(8):29-33.
- [14] 周志华.机器学习[M].北京:清华大学出版社,2016.
- [15] 王升,付智勇,陈洪松,等.基于随机森林算法的参考作物蒸发蒸腾量模拟计算[J].*农业机械学报*,2017,48(3):302-309.
- [16] Dinh T V, Nguyen H, Tran X L, et al. Predicting rainfall-induced soil erosion based on a hybridization of adaptive differential evolution and support vector machine classification [J]. *Mathematical Problems in Engineering*, 2021, 2021:1-20.
- [17] 冯禹,崔宁博,龚道枝,等.利用温度资料和广义回归神经网络模拟参考作物蒸散量[J].*农业工程学报*,2016,32(10):81-89.
- [18] Alhassan A M, Zainon W M N W. Brain tumor classification in magnetic resonance image using Hardswish-based RELU activation function-convolutional neural network [J]. *Neural Computing and Applications*, 2021,33(15):9075-9087.
- [19] 张焕,张庆,于纪言.激活函数的发展综述及其性质分析[J].*西华大学学报(自然科学版)*,2021,40(4):1-10.
- [20] 刘定一,沈阳阳,詹天明,等.融合微博热点分析和 LSTM 模型的网络舆情预测方法[J].*江苏大学学报(自然科学版)*,2021,42(5):546-553.
- [21] 刘洁,陈晓宏,许振成,等.降雨变化对东江流域径流的影响模拟分析[J].*地理科学*,2015,35(4):483-490.
- [22] Zha Wenshu, Liu Yuping, Wan Yujin, et al. Forecasting monthly gas field production based on the CNN-LSTM model [J]. *Energy*, 2022,260:124889.
- [23] 任雨之,郑江坤,付滢,等.不同耕种模式下降雨等级对紫色土坡耕地产流产沙的影响[J].*中国水土保持科学*,2020,18(3):90-98.
- [24] Feng Ziyi, Huang Guanhua, Chi Daocai. Classification of the complex agricultural planting structure with a semi-supervised extreme learning machine framework [J]. *Remote Sensing*, 2020,12(22):3708.
- [25] 陈英义,程倩倩,方晓敏,等.主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J].*农业工程学报*,2018,34(17):183-191.

(上接第 153 页)

- [24] 黄德良,费良军,曾健,等.基于灰色关联法土壤水分垂直入渗影响因素研究[J].*中国农学通报*,2018,34(32):95-101.
- [25] 马蒙蒙,林青,徐绍辉.不同因素影响下层状土壤水分入渗特征及水力学参数估计[J].*土壤学报*,2020,57(2):347-358.
- [26] Atchison D, Severson L. RECARGA User's Manual Version 2.3 [M]. University of Wisconsin, Madison, Civil & Environmental Engineering Department Water Resources Group, 2004.
- [27] 中国城镇供排水协会.T/CUWA40052-2022 雨水生物滞留设施技术规程[S],北京:中国城镇供排水协会,2022.
- [28] Facility for Advancing Water Biofiltration (FAWB). Stormwater Biofiltration Systems Adoption Guidelines: Planning, Design and Practical Implementation [C]. Version 1, Image and Sigal Processing-international Conference, 2009.
- [29] Tirpak R A, Hathaway J M, Franklin J A, et al. Suspended pavement systems as opportunities for subsurface bioretention [J]. *Ecological Engineering*, 2019, 134:39-46.