

基于时序分析及 CNN-BiLSTM-AM 的阶跃型 滑坡位移预测^{*}

杨进昆 党建武 杨景玉 岳彪
(兰州交通大学电子与信息工程学院 兰州 730070)

摘要:传统基于递归神经网络的模型对阶跃型滑坡位移预测能力不足,为解决这一问题,提出一种基于时序分析及卷积神经网络-双向长短期记忆-注意力机制(CNN-BiLSTM-AM)的滑坡位移动态预测模型。首先使用变分模态分解方法(VMD)将序列分解为趋势项、周期项和随机项。采用二次指数平滑法拟合趋势项位移,然后引入最大互信息系数法(MIC)计算各类影响因子与周期项位移相关性,对于周期项和随机项位移采用 CNN-BiLSTM-AM 混合模型进行多因素和单因素预测,最终累加各分量预测值得到累积位移预测结果。实验结果表明,所提方法在最终累计位移预测结果中拟合系数 R^2 达 0.984 和 0.987,平均绝对误差(MAE)分别为 5.334 和 3.947,均方根误差(RMSE)分别为 6.196 和 4.941,相比卷积神经网络-长短期记忆(CNN-LSTM)、麻雀搜索算法-核极限学习机(SSA-KELM)和 NARX 方法,所提方法能够更好的捕捉监测数据的时间相关性,预测精度显著提高,可为阶跃型滑坡预警及防治工作提供参考。

关键词:阶跃型滑坡;变分模态分解;注意力机制;卷积神经网络;双向长短期记忆

中图分类号: P642.22 文献标识码: A 国家标准学科分类代码: 620.1030

Displacement prediction of step-like landslide based on temporal analysis and CNN-BiLSTM-AM

Yang Jinkun Dang Jianwu Yang Jingyu Yue Biao

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

Abstract: Traditional models based on recurrent neural networks have insufficient predictive capabilities for stepwise landslide displacement. To address this issue, a dynamic landslide displacement prediction model based on time series analysis and CNN-BiLSTM-AM is proposed. Firstly, the sequence is decomposed into trend components, periodic components, and random components using the variational mode decomposition (VMD) method. The trend component displacement is fitted using the second-order exponential smoothing method. Then, the maximum mutual information coefficient (MIC) method is introduced to calculate the correlation between various influencing factors and periodic component displacement. For both periodic and random component displacements, a hybrid CNN-BiLSTM-AM model is used for multi-factor and single-factor prediction. Finally, the predicted values of each component are accumulated to obtain the cumulative displacement prediction results. Experimental results show that the proposed method achieves fitting coefficients R^2 of 0.984 and 0.987 in the final cumulative displacement prediction results, with average absolute errors (MAE) of 5.334 and 3.947, and root mean square errors (RMSE) of 6.196 and 4.941, respectively. Compared to CNN-LSTM, SSA-KELM, and NARX methods, the proposed method better captures the temporal correlations in monitoring data, significantly improving prediction accuracy, and providing valuable references for stepwise landslide early warning and mitigation efforts.

Keywords: step-like landslide; variational mode decomposition; attention mechanism; convolutional neural network; bi-directional long short-term memory

收稿日期: 2023-07-25

^{*} 基金项目: 甘肃省教育科技创新项目(221jyibgs-05)、甘肃省军民融合专项(2020JG01)、甘肃省重点研发计划(21YF5GA158)项目资助

0 引言

滑坡灾害分布广泛、发生频率高且具有突发性,对人民生命财产安全和交通运行构成严重威胁。准确的滑坡位移预测模型有助于有效评估滑坡状态,并对滑坡灾害的预警和防治提供重要依据。三峡库区由于其特殊的复杂地理环境条件,滑坡位移呈现出“阶跃型”特征。因此,针对三峡库区滑坡预测问题,构建准确的滑坡位移预测模型具有重要意义^[1-2]。

自基于蠕变理论提出滑坡预测经验公式以来,过去60年里国内外学者开发了许多滑坡位移预测模型,这些模型可分为物理模型和数据驱动模型两类。物理模型有多种,如Jiang等^[3]基于流固耦合理论预测滑坡位移。Mufundirwa等^[4]评估了反速度法预测滑坡的有效性,并提出一种基于斜率来预测滑坡失效时间的新方法。这些模型都有明确的力学和物理意义。但由于简化了地质和力学机制,可能导致模型与实际情况存在差异。数据驱动模型通过结合时间序列分析方法对历史监测数据进行建模,挖掘数据之间的时序相关性,成为滑坡位移预测的主流方法。如张俊等^[5]和李麟玮^[6]各自根据时序加法模型分解累积位移序列,然后使用粒子群算法优化的支持向量机对周期项位移进行预测。马飞燕等^[7]用小波分析将序列进行分解,然后使用麻雀搜索算法(SSA)优化的核极限学习机(KELM)对趋势项和周期项序列进行预测。安冬等^[8]提出用集合经验模态分解方法将序列分解,用随机森林回归模型预测周期项位移。尽管这些方法在滑坡预测方面取得了较好的效果,但它们将滑坡位移预测视为静态回归问题,未充分考虑滑坡作为一个动态系统的时序相关性。为提升预测模型的准确度,一些学者基于递归神经网络(recursive neural network, RNN)提出滑坡动态预测模型,通过网络记忆能力学习数据之间的时序特征,取得了较大进展。如Yao等^[9]使用RNN对三峡地区3次滑坡的演化进行了预测。Meng等^[10]使用长短时记忆网络(long short-term memory, LSTM)对三峡库区白水河滑坡进行了多因素预测,取得了较好的预测效果。杨背背等^[11]首先使用移动平均法将序列分解,然后结合降雨量和库水位数据,利用LSTM进行周期项的精确预测。此外,张振坤等^[12]在LSTM模型中引入多头自注意力机制,进一步挖掘时序变化特征,用于白水河滑坡位移预测。

基于RNN的动态预测模型能够对历史信息进行记忆,在滑坡预测中效果显著,LSTM作为RNN的变体,其有效解决了RNN梯度爆炸和消失的问题。BiLSTM是由正反LSTM组合而成,能够同时学习历史信息和未来信息。另一方面,卷积神经网络(convolution neural network, CNN)的卷积和池化操作能够有效的提取时序数据的特征^[13]。本文将CNN和BiLSTM结合,CNN负责对多因素数据进行特征提取,通过卷积操作捕捉输入特征空

间关联性。BiLSTM则用于对CNN提取后的特征进行预测。然而,BiLSTM在处理长序列数据时可能面临信息丢失问题^[14]。注意力机制(attention mechanism, AM)可以聚焦关键时间步的隐藏状态,在长期相关性中选择关键信息,从而改善BiLSTM因序列过长关键信息丢失的情况^[15]。

本文以八字门滑坡为研究对象,采用变分模态分解(variational mode decomposition, VMD)将累积位移序列分解为趋势项、周期项和随机项,随后采用二次指数平滑法对趋势项进行拟合。同时引入最大互信息系数(maximal information coefficient, MIC)分析周期项位移和各影响因素之间的关联程度。最后,利用CNN-BiLSTM-AM组合预测模型对周期项和随机项位移进行多因素和单因素的预测。

1 理论与方法

1.1 滑坡位移时间序列分析

滑坡位移是随时间变化的非平稳时间序列,位移的变化受内部地质条件和外部环境因素相互影响^[16]。滑坡的地质条件(地形、岩土特性等)会导致位移随时间单调增加,此位移分量表明了滑坡位移的长期趋势,定义为趋势项位移。受外部周期性影响因素(降雨量、库水位升降等)影响的位移表现为近似周期函数,定义为周期项位移。受其他随机影响因素(风荷载、人类活动等)影响的位移表现出不规则波动,定义为随机项位移。因此,累积位移可以表示为:

$$D_t = T_t + P_t + N_t \quad (1)$$

式中: D_t 是原始累积位移; T_t 是趋势项位移; P_t 是周期项位移; N_t 是随机项位移。

1.2 变分模态分解

VMD是一种非递归信号分解方法,结合了维纳滤波、希尔伯特变换和交替方向乘法。通过迭代搜索最优解,VMD能够自适应地将信号进行频域划分和分量分离。该技术主要包括两个步骤:变分问题的构造和变分问题求解。变分问题构造如下:

$$\begin{cases} \min_{\{u_k\}, \{w_k\}} \left\{ \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \otimes u_k(t) \right] \cdot e^{-jw_k t} \right\|_2^2 \right\} \\ \text{s. t. } \sum_{k=1}^K u_k(t) = y(t) \end{cases} \quad (2)$$

式中: K 是分解模态总数; u_k 代表 K 个本征模态函数; w_k 描述对应的中心频率; ∂_t 是时间导数; δ 是脉冲函数。

为求解上述变分问题,引入拉格朗日惩罚算子 λ 和惩罚因子 α 将约束问题转化为无约束变分问题。在保证信号重建精度的情况下,拉格朗日惩罚算子 λ 保持严格的约束。扩展的拉格朗日表达式如下:

$$L(\{u_k\}, \{w_k\}, \lambda(t)) = \alpha \sum_{k=1}^K \left\| \partial_t \left[\left(\delta(t) + \frac{j}{\pi t} \right) \otimes u_k(t) \right] e^{-jw_k t} \right\|_2^2 + \left\| y(t) - \sum_{k=1}^K u_k(t) \right\|_2^2 + \langle \lambda(t), y(t) - \sum_{k=1}^K u_k(t) \rangle \quad (3)$$

最后采用交替方向乘法解决上述问题,通过不断更新各分量及其频率,得到无约束模型的鞍点,即问题最优解,从而将原始信号分解为IMF分量。

1.3 最大互信息系数

MIC 是 Reshef^[17] 基于互信息 (mutual information, MI) 提出的,与皮尔逊系数等传统统计指标相比,MIC 可以检测出各种相关关系,包括线性、非线性、泛函和非泛函关系,且 MIC 计算复杂度较低,鲁棒性好。MIC 旨在研究在二维空间中离散化的两个变量之间的关系。其计算原理为,针对随机变量 x 和 y ,将当前的二维空间在 x 和 y 方向上划分为一定数量的区间,检查落在每个网格中的散点,以解决互信息中的联合概率问题。相关公式如下:

$$I(x, y) = \sum_x \sum_y p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} \quad (4)$$

$$MIC(x, y) = \max_{a, b < B} \frac{I(x, y)}{\log_2 \min(a, b)} \quad (5)$$

式中: $I(x, y)$ 表示 x 与 y 间的互信息, $p(x)$ 和 $p(y)$ 是边际密度函数, $p(x, y)$ 是联合概率密度函数, $a \cdot b < B$ 是对网格总数的约束, B 一般设置为数据总量的 0.6 次方。MIC 取值范围为 $[0, 1]$, 为 0 表示变量间没有依赖关系,值越大变量相关性越强。为保证特征筛选的合理性,基于文献^[14, 18]的研究,本文将 $MIC > 0.2$ 的变量视为重要影响因素。

1.4 二次指数平滑法

二次指数平滑法旨在处理有一定趋势的时间序列。其工作原理是通过过去观测值和最近的观测值进行加权组合,利用指数平滑更新时间序列的趋势。考虑到滑坡位移的趋势分量主要受地质条件影响而非外界因素触发,位移曲线整体呈单调递增的趋势。因此,本文使用二次指数平滑法预测滑坡趋势项位移。其计算方法如下:

$$\hat{y}_{t+m} = s_t + mb_t \quad (6)$$

$$s_t = \alpha y_t + (1 - \alpha)(s_{t-1} + b_{t-1}) \quad (7)$$

$$b_t = \gamma(s_t - s_{t-1}) + (1 - \gamma)b_{t-1} \quad (8)$$

式中: \hat{y}_{t+m} 为 t 时刻的第 m 个时间步长预测值; s_t 为平滑值; b_t 为变化趋势; α 为数据平滑系数 ($0 < \alpha < 1$); γ 为趋势平滑系数 ($0 < \gamma < 1$)。

1.5 长短时记忆网络

LSTM 是特殊类型的 RNN,通过输入门、遗忘门和输出门来控制存储单元。输入门负责更新存储单元状态,遗忘门根据记忆单元的信息来保留或遗忘信息,而输出门则

根据当前输入和上一时间步隐藏状态,决定 LSTM 单元将多少信息传递给下一时间步。LSTM 的结构如图 1 所示。




图1 LSTM模型结构

遗忘门、输入门和输出门的计算过程如下:

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (9)$$

式中: f_t 、 i_t 和 o_t 分别为遗忘门、输入门和输出门的计算结果; σ 为 sigmoid 函数; W 和 b 为相关权重和偏执; h_{t-1} 为上一时刻隐藏状态; x_t 为当前时刻序列输入。

候选状态、更新状态及隐藏层输出的计算过程如下:

$$\begin{cases} \tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \\ h_t = o_t \cdot \tanh(c_t) \end{cases} \quad (10)$$

式中: c_t 和 \tilde{c}_t 分别代表当前时刻候选状态和更新状态的计算结果; h_t 代表该时刻隐藏层输出; \tanh 为正切函数。

BiLSTM 是 LSTM 的改进版本,如图 2 所示,由两层方向相反的 LSTM 组成,它允许通过两次处理输入数据来进行更多的训练。在 BiLSTM 网络学习过程中,输入序列以正顺序输入到前向 LSTM 网络,后向 LSTM 网络以相反的顺序输入。两个相反顺序的 LSTM 网络分别执行输入序列上下文特征提取和信息记忆。




图2 BiLSTM模型结构

本文利用 BiLSTM 神经网络从 CNN 层提取的特征信息中学习双向序列特征,充分利用样本数据的长期依赖特征进行学习。

1.6 注意力机制

注意力机制是模拟人脑注意力资源分配机制,核心思想是将更多关注度集中在重要信息上,从而获得更详细、需要关注的信息,并抑制无用的信息。在深度学习模型中加入注意力机制可以根据不同的特征分配不同权重,从而有助于网络学习到有用的历史信息。在这种机制下,注意力权重的计算通常通过式(11)~(13)来实现。

$$e_i = \tanh(W_s h_i + b) \quad (11)$$

$$\alpha_i = \frac{\exp(e_i^T u_s)}{\sum_{i=1}^t \exp(e_i^T u_s)} \quad (12)$$

$$v = \sum_{i=1}^t \alpha_i h_i \quad (13)$$

使用注意力机制对 BiLSTM 输出的隐藏层向量表达式进行加权求和计算,其中权重的大小则表示特征在某个时间点的重要性。注意力机制的引入可以改善 BiLSTM 因序列过长导致的信息丢失问题,进一步提高滑坡位移预测的准确性。

1.7 CNN-BiLSTM-AM 混合预测模型

用于阶跃型滑坡位移预测的基于注意力机制的 1DCNN-BiLSTM 模型的架构,如图 3 所示。由输入层、CNN 层、BiLSTM 层、注意力层和全连接层构成。

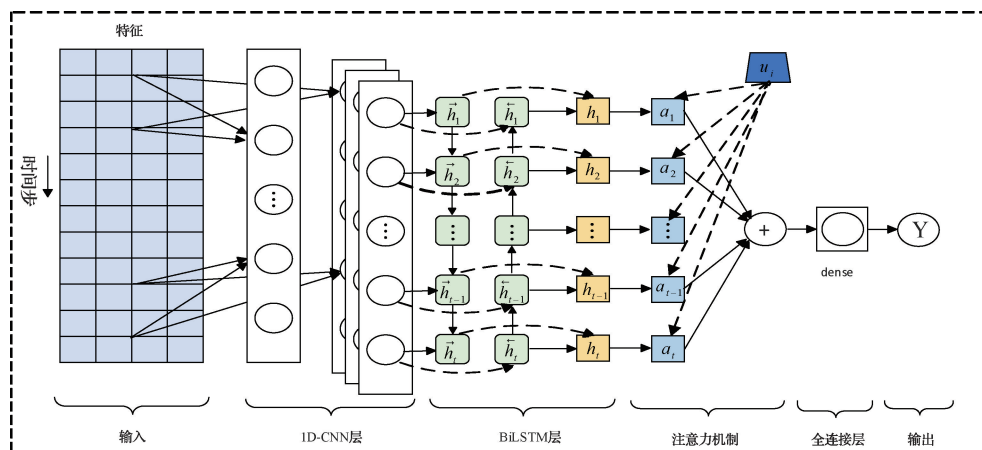


图 3 CNN-BiLSTM-AM 模型结构

1) 输入层

输入预测所需数据,并对输入数据做标准化,本文采用最大最小归一化,计算方法如下:

$$x' = \frac{x - \min}{\max - \min} \quad (14)$$

2) 1D-CNN 层

使用卷积运算提取数据的空间分布特征,卷积核数为 64,卷积核大小为 1,步长为 1。

3) BiLSTM 层

以 CNN 层的输出作为输入,挖掘输入数据序列的时间相关性,正反向 LSTM 的隐藏层节点数为 64。

4) 注意力层

以 BiLSTM 的隐藏层输出作为输入,通过注意力机制计算每个时间步的重要性,最后对各时间步隐藏状态赋以对应注意力权重。

5) 全连接层

将注意力层输出的结果映射到一维进行输出。

本文总体技术路线如图 4 所示。

1.8 评价指标

为客观估计模型的预测能力,使用 3 个性能评价指标来评估模型的准确性和性能表现,包括均方根误差

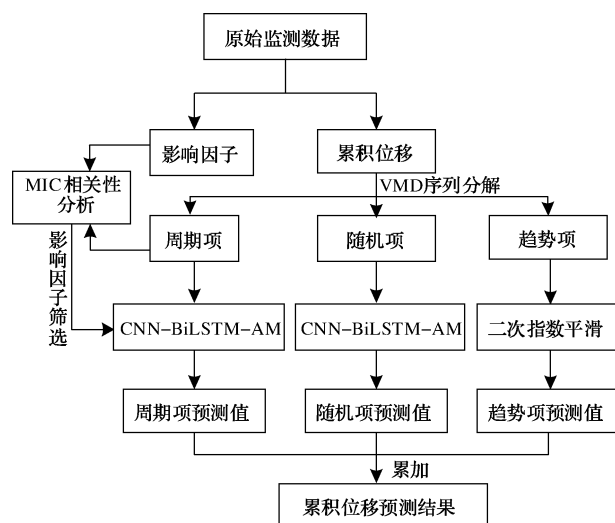


图 4 本文技术路线

(RMSE)、平均绝对误差(MAP)和拟合系数 R^2 ,这些指标主要描述了对模型预测结果与实际观测值之间的误差和拟合程度的量化度量。3 个评价指标的计算方法如下:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (16)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (17)$$

2 工程实例

2.1 八字门滑坡概况

八字门滑坡位于湖北省秭归县归州镇香溪河右岸,其距河口约0.8 km,距三峡坝址约38 km。香溪河在此呈南北走向,几乎横跨长江,三峡水库淹没滑坡前缘55~135 m高程段。

滑坡体前缘直抵香溪河,岸坡呈南北走向。滑坡属于堆积层滑坡,在岸坡脚呈簸箕状排列。滑坡体分布高程为139~280 m,坡面坡度为10°~30°,呈阶梯状起伏。该滑坡在三峡水库蓄水后,多处变形,致使当地村民房屋受损而全部搬迁。滑坡专业监测结果显示,GPS监测点位移持续增大,累积位移量超过2 000 mm,方向总体指向香溪河,变形具有同步性,滑坡一直处于蠕滑状态。滑坡全貌如图5所示。




图5 八字门滑坡全貌

2.2 滑坡位移监测

初期在滑坡监测区域内布置了4个GPS变形监测点(ZG109、ZG110、ZG111及ZG112),构成2条纵向监测剖面线,采用美国天宝GPS接收机(平面精度为 $(5+1) \times 10^{-6}$)进行滑坡位移监测;由于ZG109被淹没、ZG112因毁坏失去监测功能。随着变形趋势逐渐增大,于2013年10月新增GPS监测点8个。滑坡体外围稳定山体布设了2个基准点(ZGJ6、ZG06)。各监测点详细布置如图6所示。

本文选用数据较完整的监测点ZG110和ZG111两个监测点自2007年1月~2016年12月的监测数据做实验验证。数据包含两个监测点的累计位移量、月平均降雨量和月平均库水位(图7)。数据来源于国家冰川冻土沙漠科学数据中心(<http://www.ncdc.ac.cn>)。

2.3 滑坡累积位移时间序列分解

滑坡累积位移是内外因素耦合效应的综合响应,通过

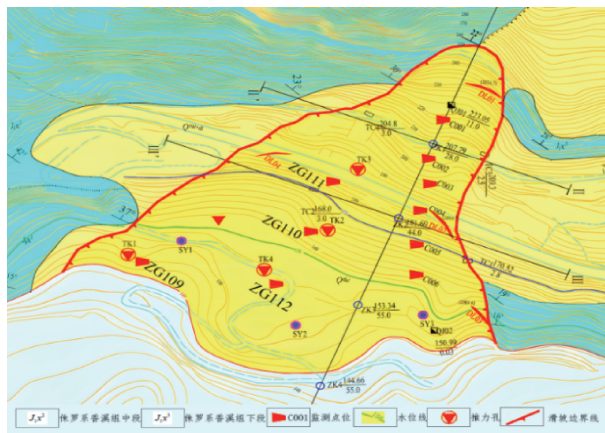


图6 八字门滑坡工程地质平面图




图7 八字门滑坡累计位移与降雨量、库水位关系曲线

对这种综合响应进行分解,可以更准确的预测滑坡位移。在划分数据集前,需要对ZG110和ZG111两个测点的累积位移曲线进行分解。为此本文采用VMD将监测数据分解为趋势项、周期项和随机项位移。VMD各参数的选择对分解效果和数据保真度影响较大^[19],经过多次实验,本文在VMD算法中将模态分解个数 K 设置为3,惩罚因子 α 分别设置为25和75,上升时间步长 τ 设置为0.1。分解结果如图8所示。

2.4 趋势项位移预测

滑坡趋势项位移很大程度上反映了滑坡当前状态,其主要受内部因素影响,受外部因素影响较小。本文使用二次指数平滑法对趋势项位移进行拟合,拟合结果如图9所示。

2.5 周期项位移预测

1) 周期项位移影响因子选择

为了选择与预测目标更相关的影响因子作为模型的输入特征,以提高预测效果。本文考虑了八字门滑坡变形的的外部影响因素,主要包括降雨量和库水位。降雨渗入岩石裂缝和土壤孔隙,导致滑坡体地下水位上升,软化岩土,降低抗剪强度。库水位周期性升降会导致坡体前缘的黏土吸水膨胀和失水收缩,进而降低抗剪强度及稳定性^[20]。这些影响都是持续且缓慢的过程^[21]。并且结合图7可以




图8 监测点 ZG110 及 ZG111 累积位移分解结果

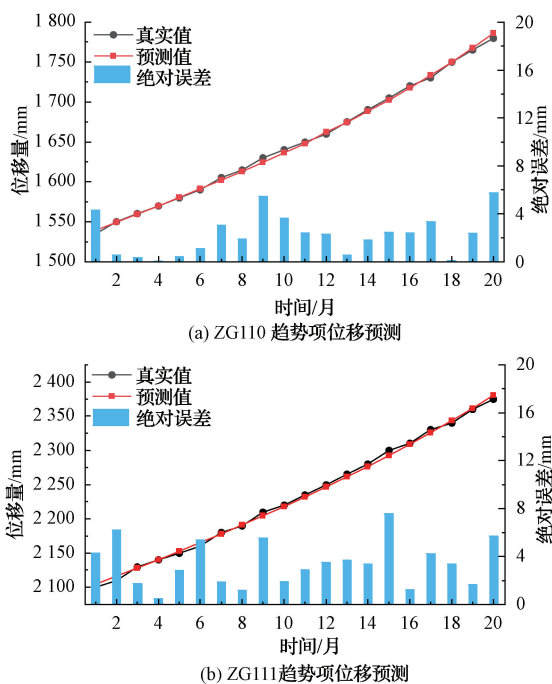


图9 趋势项拟合预测结果

看出,降雨量和库水位的变化对八字门滑坡位移变化有一定的滞后效应^[22]。此外,不同的滑坡演化状态对外部影响因子的响应也存在差异^[23]。因此本文考虑 10 个候选影响因子,划分为库水位、降雨量和滑坡演化状态 3 类。

针对库水位,选择前一月平均库水位 W_1 、前两月平均库水位 W_2 、单月内库水位波动幅度 W_3 和平均库水位变化量 W_4 作为候选影响因子。针对降雨量则选择前一月累积降雨量 F_1 、前两月累积降雨量 F_2 、单月内最大降雨量 F_3 和双月累积降雨量 F_4 作为候选影响因子。最后选择前一个月位移变化量 D_1 和前两个月位移变化量 D_2 作为描述滑坡演化状态的候选影响因子。

本文引入 MIC 评估滑坡周期项位移和各候选因子之间的相关性,MIC 可以检测出线性和非线性关系,以及更复杂的关系模式。MIC 取值范围在 0~1 之间,越接近 1 说明变量之间有强依赖性。如表 1 所示,所有候选因子的 MIC 值均大于 0.2,说明候选因子和滑坡周期项位移有较

表1 周期项位移与候选影响因子之间的 MIC 值

类别	编号	ZG110	ZG111
库水位	W_1	0.541 3	0.377 5
	W_2	0.672 4	0.478 0
	W_3	0.291 2	0.226 4
	W_4	0.401 7	0.493 6
降雨量	F_1	0.296 6	0.313 2
	F_2	0.391 1	0.412 7
	F_3	0.290 0	0.271 4
	F_4	0.354 1	0.331 2
滑坡演化状态	D_1	0.321 3	0.417 4
	D_2	0.591 1	0.758 6

强相关关系。然而,考虑到同类别影响因子可能包含重复和冗余信息^[24]。综上,为充分考虑变量间的强相关性,同时避免冗余特征影响预测的准确性,选择各候选影响因子类别中 MIC 值前 50% 的因子作为模型输入。

2) 周期项位移预测结果

本文选取八字门滑坡 ZG110 和 ZG111 前 100 个月的数据作为模型的训练集,后 20 个月作为模型的测试集。将 MIC 筛选出的影响因子作为模型输入,并与 CNN-LSTM^[13]、SSA-KELM^[7] 以及 NARX^[18] 模型的预测结果进行对比。预测结果如图 10、表 2 所示。




图 10 ZG110 及 ZG111 周期项位移预测结果

表 2 不同模型周期项位移预测结果评估					
测点	评价	本文方法	CNN-LSTM	SSA-KELM	NARX
ZG110	RMSE	3.976	5.140	5.301	6.237
	MAE	2.826	4.346	4.652	4.556
	R^2	0.964	0.940	0.936	0.912
ZG111	RMSE	4.680	7.674	7.836	8.463
	MAE	3.961	6.747	7.178	7.389
	R^2	0.974	0.932	0.929	0.917

2.6 随机项位移预测

随机项位移通常受到随机因素影响,例如人类活动、地震、风荷载等,这使得随机项位移通常是一个无

明显规律的高频波动序列。当坡体处在稳定和不稳定状态的临界点时,随机波动可能会导致剧烈变形^[20]。因此对于随机项预测具有一定必要性。由于各种随机因素种类多且不可量化,使得预测难度较大。因此本文从随机项位移序列自身特征出发,使用 CNN-BiLSTM-AM 对随机项位移进行单因素预测,同样与 CNN-LSTM、SSA-KELM 以及 NARX 模型进行对比。预测结果如图 11、表 3 所示。

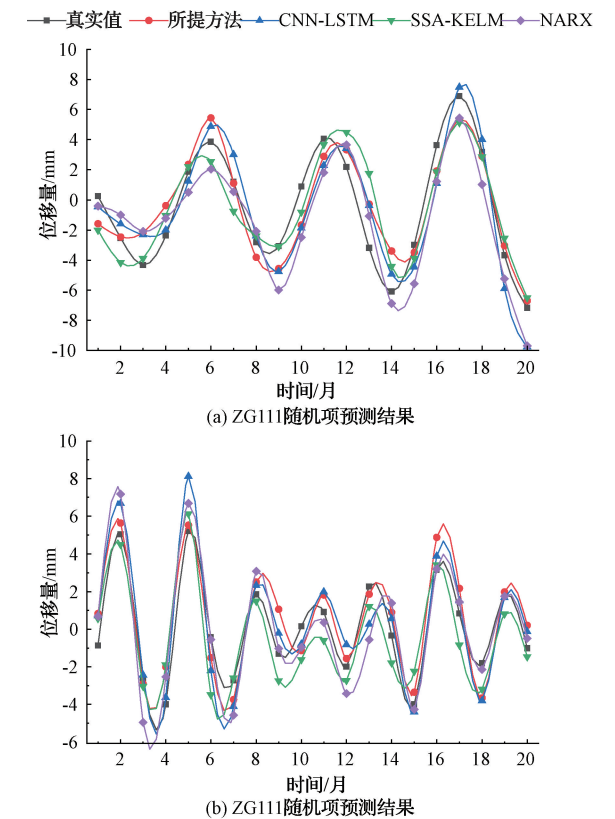


图 11 ZG110 及 ZG111 随机项位移预测结果

表 3 不同模型随机项位移预测结果评估					
测点	评价	本文方法	CNN-LSTM	SSA-KELM	NARX
ZG110	RMSE	1.556	1.709	1.699	1.988
	MAE	1.294	1.517	1.313	1.847
	R^2	0.833	0.798	0.801	0.727
ZG111	RMSE	1.197	1.297	1.361	1.351
	MAE	1.028	1.091	1.153	1.071
	R^2	0.794	0.758	0.733	0.737

2.7 累积位移预测

依照时间序列加法模型,将双指数平滑法拟合的趋势项位移与使用 CNN-BiLSTM-AM 预测的周期项及随机项位移进行累加,得到 ZG110 和 ZG111 最终的累积位移预测结果。其 RMSE 分别为 6.196 和 4.941,MAE 分别

为 5.344 和 3.947, R^2 分别为 0.984 和 0.987, 预测结果如图 12 所示。

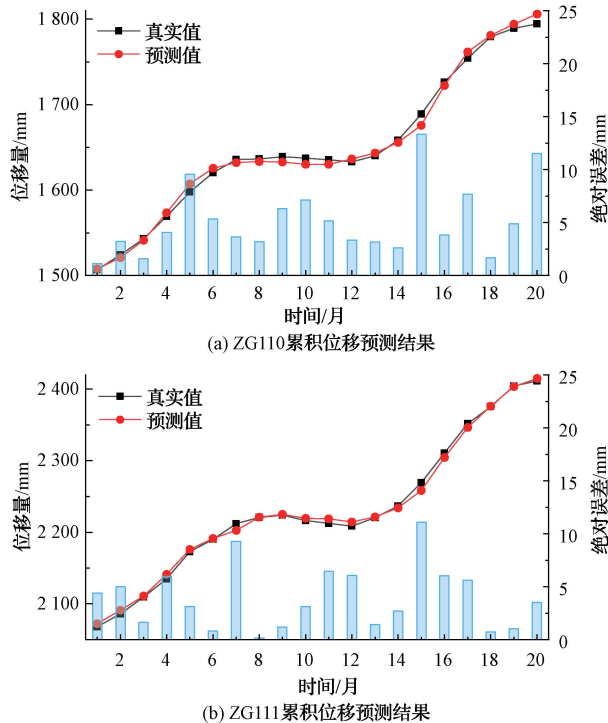


图 12 ZG110 及 ZG111 累积位移预测结果

2.8 消融实验

为验证所提混合预测模型中各模块的合理性和有效性。将 BiLSTM、CNN-BiLSTM 和 BiLSTM-AM 作为消融实验的对比模型,并以 ZG110 测点的周期项和随机项位移作为模型训练数据,以验证所提模型在多因素和单因素预测任务中有效性。实验结果如图 13 和表 4 所示。结果表明在周期项预测(多因素)中,由于 CNN 和注意力模块的引入,预测精度均有较大提升。在随机项预测(单因素)中,CNN 模块和注意力模块对预测精度均有提升,其中注意力模块对预测精度的提升较为显著。


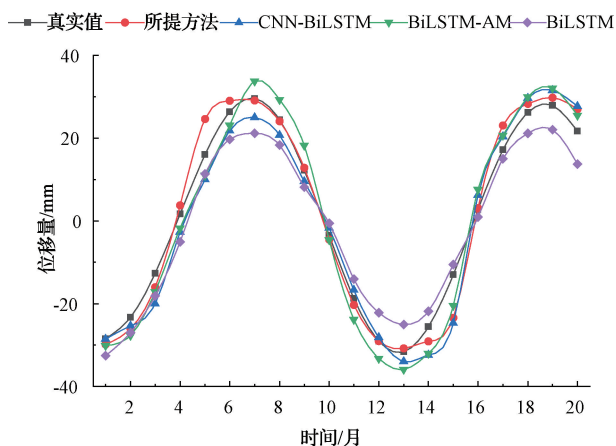


图 13 消融实验结果

表 4 消融实验数据

位移分量类型	评价	本文方法	CNN-BiLSTM	BiLSTM-AM	BiLSTM
周期项	RMSE	3.976	4.899	4.620	5.39
	MAE	2.826	4.242	4.430	5.052
	R^2	0.964	0.945	0.951	0.933
随机项	RMSE	1.556	1.846	1.683	1.903
	MAE	1.294	1.619	1.562	1.589
	R^2	0.833	0.765	0.804	0.750

3 结论

本文针对三峡库区八字门阶跃型滑坡,提出一种时序分析和结合注意力机制的 CNN-BiLSTM 组合模型。选取三峡库区八字门滑坡监测点 ZG110 及 ZG111 历时 120 个月的位移监测数据,结合库水位和降雨量数据进行了预测实验验证。

1) 本文考虑阶跃型滑坡演化规律。使用变分模态分解方法将累积位移曲线分解为趋势项、周期项及随机项位移。充分考虑影响周期项位移的各类影响因子,引入最大互信息系数法筛选高相关性影响因子以作为预测模型输入。

2) 使用双指数平滑法预测趋势项位移,对于周期项和随机项位移则建立结合注意力机制的 CNN-BiLSTM 组合预测模型进行多因素及单因素预测。1D-CNN 能够提取输入数据的局部特征,从而更好地捕捉这些因素对预测结果的影响。BiLSTM 在具有记忆历史信息能力的基础上,能有效学习时序数据的双向特征。在 BiLSTM 之后加入注意力机制为隐藏状态分配注意力权重来选择关键信息,增强模型对不同时间步的相关性关注,解决 BiLSTM 长期依赖问题。

3) 针对八字门滑坡 ZG110 和 ZG111 两个测点进行实验分析。本文所提模型在最终累积位移预测结果 RMSE 分别为 6.196 和 4.941, MAE 分别为 5.334 和 3.947, R^2 分别为 0.984 和 0.987。实验结果表明,所提预测模型具有较好的预测效果,能够为“阶跃型”滑坡位移预测提供参考。

参考文献

- [1] 童仁园,李青,李明. 基于时域反射的分布式地表变形探测技术[J]. 仪器仪表学报, 2011, 32(11): 2572-2578.
- [2] 任桂香,唐立军,任晓周,等. 远程实时堤坝边坡监测系统[J]. 电子测量技术, 2017, 40(6): 190-196.
- [3] JIANG J, EHRET D, XIANG W, et al. Numerical simulation of Qiaotou Landslide deformation caused by drawdown of the Three Gorges Reservoir, China[J]. Environmental Earth Sciences, 2011, 62: 411-419.
- [4] MUFUNDIRWA A, FUJII Y, KODAMA J. A new practical method for prediction of geomechanical failure-time [J]. International Journal of Rock Mechanics and Mining Sciences, 2010, 47(7): 1079-1090.
- [5] 张俊,殷坤龙,王佳佳,等. 基于时间序列与 PSO-SVR 耦合模型的白水河滑坡位移预测研究[J]. 岩石力学与工程学报, 2015, 34(2): 382-391.
- [6] 李麟玮,吴益平,苗发盛,等. 基于变分模态分解与 GWO-MIC-SVR 模型的滑坡位移预测研究[J]. 岩石力学与工程学报, 2018, 37(6): 1395-1406.
- [7] 马飞燕,李向新. 基于改进麻雀搜索算法-核极限学习机耦合算法的滑坡位移预测模型[J]. 科学技术与工程, 2022, 22(5): 1786-1793.
- [8] 安冬,宋琨,仪政,等. 一种基于 EEMD-RFR 的水库滑坡台阶状位移预测模型[J]. 山地学报, 2021, 39(1): 143-150.
- [9] YAO W, ZENG Z, LIAN C, et al. Training enhanced reservoir computing predictor for landslide displacement[J]. Engineering Geology, 2015, 188: 101-109.
- [10] MENG Q, WANG H, HE M, et al. Displacement prediction of water-induced landslides using a recurrent deep learning model[J]. European Journal of Environmental and Civil Engineering, 2023, 27(7): 2460-2474.
- [11] 杨背背,殷坤龙,杜娟. 基于时间序列与长短时记忆网络的滑坡位移动态预测模型[J]. 岩石力学与工程学报, 2018, 37(10): 2334-2343.
- [12] 张振坤,张冬梅,李江,等. 基于多头自注意力机制的 LSTM-MH-SA 滑坡位移预测模型研究[J]. 岩土力学, 2022, 43(S2): 477-486, 507.
- [13] 王朝阳,李丽敏,温宗周,等. 基于时间序列和 CNN-LSTM 的滑坡位移动态预测[J]. 国外电子测量技术, 2022, 41(3): 1-8.
- [14] LIN Z, SUN X, JI Y. Landslide displacement prediction based on time series analysis and double-BiLSTM model [J]. International Journal of Environmental Research and Public Health, 2022, 19(4): 2077.
- [15] LI Y, ZHU Z, KONG D, et al. EA-LSTM: Evolutionary attention-based LSTM for time series prediction [J]. Knowledge-Based Systems, 2019, 181: 104785.
- [16] ZHANG Y, TANG J, CHENG Y, et al. Prediction of landslide displacement with dynamic features using intelligent approaches [J]. International Journal of Mining Science and Technology, 2022, 32(3): 539-549.
- [17] RESHEF D N, RESHEF Y A, FINUCANE H K, et al. Detecting novel associations in large data sets[J]. Science, 2011, 334(6062): 1518-1524.
- [18] NIU X, MA J, WANG Y, et al. A novel decomposition-ensemble learning model based on ensemble empirical mode decomposition and recurrent neural network for landslide displacement prediction[J]. Applied Sciences, 2021, 11(10): 4684.
- [19] 姜宇航,王伟,邹丽芳,等. 基于粒子群-变分模态分解、非线性自回归神经网络与门控循环单元的滑坡位移动态预测模型研究[J]. 岩土力学, 2022, 43(S1): 601-612.
- [20] 郭璐,贺可强,周云,等. 水库型滑坡复合水动力增载位移响应比物理预测模型及其应用[J]. 工程地质学报, 2022, 30(5): 1561-1572.
- [21] YU C, HUO J, LI C, et al. Landslide displacement prediction based on a two-stage combined deep learning model under small sample condition [J]. Remote Sensing, 2022, 14(15): 3732.
- [22] XING Y, YUE J, CHEN C. Interval estimation of landslide displacement prediction based on time series decomposition and long short-term memory network[J]. IEEE Access, 2019, 8: 3187-3196.
- [23] BAI D, LU G, ZHU Z, et al. Prediction interval estimation of landslide displacement using bootstrap, variational mode decomposition, and long and short-term time-series network[J]. Remote Sensing, 2022, 14(22): 5808.
- [24] ZENG T, YIN K, JIANG H, et al. Groundwater level prediction based on a combined intelligence method for the Sifangbei landslide in the Three Gorges Reservoir Area[J]. Scientific Reports, 2022, 12(1): 11108.

作者简介

杨进昆,硕士研究生,主要研究方向为边坡状态预测、数字孪生。

E-mail: 940688917@qq.com

党建武,博士,教授,主要研究方向为智能信息处理、交通信息工程及控制。

E-mail: dangjw@mail.lzjtu.cn