

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

杨背背¹, 殷坤龙¹, 杜娟²

(1. 中国地质大学 工程学院, 湖北 武汉 430074; 2. 中国地质大学 教育部长江三峡库区地质灾害研究中心, 湖北 武汉 430074)

摘要: 针对滑坡演化的动态特性和传统静态预测模型的不足, 提出一种基于时间序列与长短时记忆网络(long and short term memory neural network, LSTM)的滑坡位移动态预测模型。该模型首先采用移动平均法将滑坡累积位移分解为趋势项位移和周期项位移。然后采用多项式函数预测趋势项位移; 基于滑坡变形特征与诱发因素的响应分析, 建立 LSTM 模型进行周期项位移预测。最后将各分项位移叠加, 即实现滑坡累积位移的预测。以三峡库区典型阶跃型滑坡——白水河滑坡为例, 并与支持向量机模型(support vector machine, SVM)进行对比分析。结果表明, 与静态模型 SVM 相比, 动态模型 LSTM 的预测精度较高, 在阶跃式变形期的预测优势尤为突出, 且不依赖于训练数据时效性的分析。该模型为三峡库区阶跃型滑坡位移预测提供了新的思路和探索。

关键词: 边坡工程; 阶跃型滑坡; 位移预测; 动态模型; 时间序列; 长短时记忆网络

中图分类号: P 642

文献标识码: A

文章编号: 1000 - 6915(2018)10 - 2334 - 10

A model for predicting landslide displacement based on time series and long and short term memory neural network

YANG Beibei¹, YIN Kunlong¹, DU Juan²

(1. Faculty of Engineering, China University of Geosciences, Wuhan, Hubei 430074, China; 2. Three Gorges Research Center for Geohazard, Ministry of Education, China University of Geosciences, Wuhan, Hubei 430074, China)

Abstract: To address the transient characteristics of landslide processes and to overcome the deficiency of static forecasting models, a model for predicting the transient landslide displacement was proposed based on time series theory and long and short term memory neural network(LSTM). In the model, the moving average method was applied to decompose the cumulative displacement into the trend term and periodic term. Subsequently, the trend displacement was predicted by a polynomial model. A LSTM model, based on the response of inducing factors, was established to predict the periodic displacement. Finally, the trend displacement and periodic displacement were superposed to achieve the cumulative displacement. Baishuihe landslide, a typical stepped landslide in Three Gorges Reservoir area, was taken as an example to test the prediction performance of the proposed model and the support vector machine(SVM) was used for comparison. The results demonstrate that the transient model(LSTM) achieves higher prediction accuracy than the static model(SVM), especially during the period of stepped deformation. Furthermore, the prediction accuracy of the LSTM model is not limited by the timeliness analysis of

收稿日期: 2018 - 05 - 14; **修回日期:** 2018 - 06 - 23

基金项目: 国家自然科学基金资助项目(41572292, 41572289)

Supported by the National Natural Science Foundation of China(Grant Nos. 41572292 and 41572289)

作者简介: 杨背背(1990 -), 女, 2013年毕业于中国地质大学(武汉)岩土工程专业, 现为博士研究生, 主要从事滑坡灾害预测预报等方面的研究工作。E-mail: cugyangbeibei@163.com

DOI: 10.13722/j.cnki.jrme.2018.0468

training sets.

Key words: slope engineering; step-like landslide; displacement prediction; dynamic model; time series; long and short term memory neural network

1 引言

滑坡位移预测是实现滑坡灾害预报的有效手段,对降低灾害导致的财产损失及人员伤亡具有重要意义^[1]。目前针对三峡库区广泛分布的“阶跃型”滑坡位移预测的方法,主要是将滑坡累积位移进行分解,然后对各位移分量进行预测^[2]。如张俊等^[3-4]利用移动平均法将滑坡累积位移分解为趋势项位移和周期项位移,随后采用支持向量机模型(support vector machine, SVM)对周期项位移进行预测,但模型在滑坡阶跃式变形期的预测能力有限,个别点的位移预测误差较大。杜娟等^[5-6]基于诱发因素的响应分析,通过平移指数法分解累积位移,然后建立滑坡位移的神经网络模型(neural network, NN)。以上模型存在的主要问题是并没有很好地考虑滑坡演化的动态特性。支持向量机模型 SVM 以及神经网络模型 NN 都属于静态模型,均将滑坡位移预测视为静态回归问题而忽略了滑坡演化的动态系统本质,从而制约了预测精度的提升^[7]。因此,为了实现滑坡位移的准确预测,需要建立能够更好地模拟滑坡位移变化过程的动态预测模型^[8]。

目前,动态预测模型的建立主要基于递归神经网络(recurrent neural network, RNN)^[9]。不同于传统神经网络(artificial neural network, ANN),递归神经网络 RNN 的内部节点采用递归连接,使得前一时刻的状态能够对后一时刻的状态造成影响,实现了网络的状态反馈。长短时记忆网络(long short-term memory, LSTM)是一种特殊的 RNN 网络,在处理长序列数据预测问题上具有明显优势。LSTM 在自然语言处理方面取得了惊人的成就^[10],其在滑坡位移预测中的应用研究目前还较少^[11]。

基于以上研究背景,本文以三峡库区白水河滑坡为例,首先基于时间序列分解原理,将滑坡累积位移分解为趋势项位移和周期项位移。然后利用多项式函数对趋势项位移进行拟合和预测。基于诱发因素的响应建立 LSTM 模型预测周期项位移,并与已具有一定应用基础的 SVM 模型进行对比,以均方根误差 RMSE 和相关性系数 R 评价各模型的预测

精度。最后,将趋势项位移和周期项位移预测值叠加,即可得到滑坡累积位移预测值。

2 滑坡位移预测模型

2.1 时间序列分析

滑坡位移的产生与变化是坡体自身地质条件和外界诱发因素共同作用的结果。在滑坡自身地质条件(如岩土体类型及其工程性质、地质构造、地形地貌等)的控制下,其位移表现为大时间尺度的近似单调递增函数;在外界诱发因素(如季节性降雨、库水位变动)的影响下,其位移则体现为小时间尺度的近似周期性函数。故滑坡总位移可进行如下分解^[12]:

$$S(t) = \phi(t) + \eta(t) \quad (1)$$

式中: $S(t)$ 为位移时间序列; $\phi(t)$ 为趋势项位移,由坡体自身条件决定,反映了滑坡位移的长期变化趋势; $\eta(t)$ 为周期项位移,受降雨、库水位变化等外界诱发因素的控制。

2.2 递归神经网络(RNN)与长短时记忆网络(LSTM)

传统神经网络 ANN 中,不同层(输入层、隐藏层和输出层)之间的节点互相连接,每层之间的节点互相独立。而在递归神经网络 RNN 中,隐藏层相邻的节点之间互相连接,每个隐藏层的节点同时接收当前时间点输入层传递的信息和上一时间点隐藏层传递的信息。即 RNN 构建的网络会对历史时间点的信息进行记忆,将记忆留下的信息应用到当前神经元的输出计算中,并随着新数据的输入而不断更新(见图 1)。基于这种特殊的设计, RNN 在时间序列预测方面显示出一定的优势^[13]。




图 1 ANN 与 RNN 对比示意图

Fig.1 Difference between ANN and RNN

在理论上, RNN 可以处理任意长度的时间序列^[14]。而实际上, RNN 对于距离较近的信息, 具有良好的学习能力; 对距离较远的信息, 其学习能力会减弱, 存在所谓的“梯度消失或爆炸”问题, 从而难以捕捉长期时间关联^[15]。为了解决这一问题, S. Hochreiter 和 J. Schmidhuber^[16]在 1997 年提出了长短时记忆网络 LSTM。LSTM 是一种新型深度学习神经网络, 该模型在 RNN 的基础上增加了记忆单元(memory cell)、输入门(input gate)、遗忘门(forget gate)及输出门(output gate)等机制, 用来控制信息在不同时刻的传递, 从而大大提升了 RNN 处理长序列数据的能力。LSTM 模型结构示意图如图 2 所示。

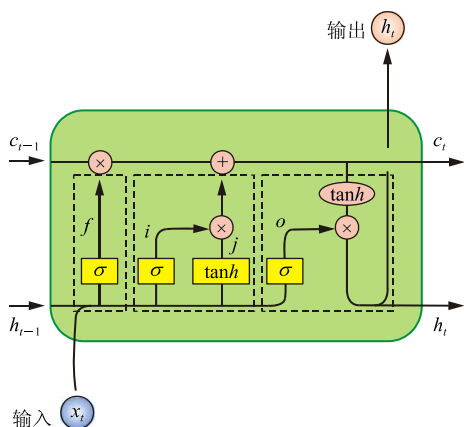


图 2 LSTM 结构示意图

Fig.2 Architecture of LSTM neural network

在 LSTM 模型中, 输入门控制着新的输入进入记忆单元的强度, 即决定有多少新记忆将和老记忆进行合并。遗忘门控制着记忆单元维持上一时刻值的强度, 即对历史信息进行取舍, 如果遗忘门关闭, 任何历史记忆无法通过; 反之, 如果遗忘门完全打开, 则所有的历史记忆都将通过。输出门控制着输出记忆单元的强度, 决定着 LSTM 单元对外界的响应。各门结构相应的函数^[11]如下:

$$I_t = \sigma(W_{i1}x_t + W_{i2}h_{t-1} + b_i) \quad (2)$$

$$f_t = \sigma(W_{f1}x_t + W_{f2}h_{t-1} + b_f) \quad (3)$$

$$O_t = \sigma(W_{o1}x_t + W_{o2}h_{t-1} + b_o) \quad (4)$$

式中: I_t , f_t 和 O_t 分别为 LSTM 神经网络某节点在 t 时刻输入门、遗忘门和输出门的向量值; b_i , b_f , b_o 分别为各结构对应的偏置项; x_t 为 t 时刻的输入; W_1 为输入节点与隐藏节点的连接权值; W_2 为隐藏节点与输出节点的连接权值; h_{t-1} 为 $t-1$ 时刻的输出,

代表了 LSTM 的隐藏状态(hidden state), 可表示为 $h_{t-1} = O_{t-1} \tanh(c_{t-1})$, 其中 c_{t-1} 为 $t-1$ 时刻记忆单元的向量值, \tanh 为双曲正切函数, 可将实数映射到 $[-1, 1]$; σ 为 sigmoid 激活函数, 能够将实数映射到 $[0, 1]$, 1 表示上一时刻单元的信息全部保留, 0 表示上一时刻单元的信息全部丢弃。

3 种门的计算方式类似, 但有着完全不同的参数, 各自以不同的方式控制着记忆单元^[17]。在该模型中, 对于每个存储单元, 连接权值 W 从输入训练中通过不断迭代得到; 隐藏状态 h_t 依据当前输入 x_t 和前一时刻隐藏状态 h_{t-1} 来改变, 不断循环这一过程直至处理完毕。

2.3 模型精度评价

本文采用均方根误差(root mean square error, RMSE)和相关性系数(correlation coefficient, R)等指标评估模型预测精度^[18]。此外, 绝对误差和相对误差也用于分析预测结果。RMSE 和 R 的计算式为

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{N}} \quad (5)$$

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(\hat{x}_i - \bar{\hat{x}})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (\hat{x}_i - \bar{\hat{x}})^2}} \quad (6)$$

式中: x_i 和 \hat{x}_i 分别为真实值和预测值, \bar{x} 和 $\bar{\hat{x}}$ 分别为真实值和预测值的平均值, N 为样本数。

3 白水河滑坡概况

3.1 工程地质概况

白水河滑坡位于三峡库区秭归县, 长江南岸, 距离三峡大坝 56 km。滑坡前缘没入长江; 左右两侧以基岩山脊为界; 后缘以岩土分界处为界。滑坡主滑方向约为 NE20°, NS 向长约 600 m, EW 向宽约 700 m, 平均厚度 30 m, 体积约 $1.26 \times 10^7 \text{ m}^3$, 属大型堆积层滑坡^[19]。

白水河滑坡为老滑坡, 历史上已发生多次较大的变形。2003 年 6 月, 滑坡东部前缘出现长 300 余米的横向裂缝。2004 年 7 月, 滑坡变形导致 21 处民房遭到破坏, 专家根据滑坡变形特征划定了预警区边界(见图 3)。2005 年 8 月~2006 年 8 月, 滑坡地表多处出现下沉拉裂缝。2007 年 6 月 30 日, 预警区后缘发生较大规模坍塌。2009 年 8 月, 滑坡西部边界裂缝呈羽状断续扩展^[20]。

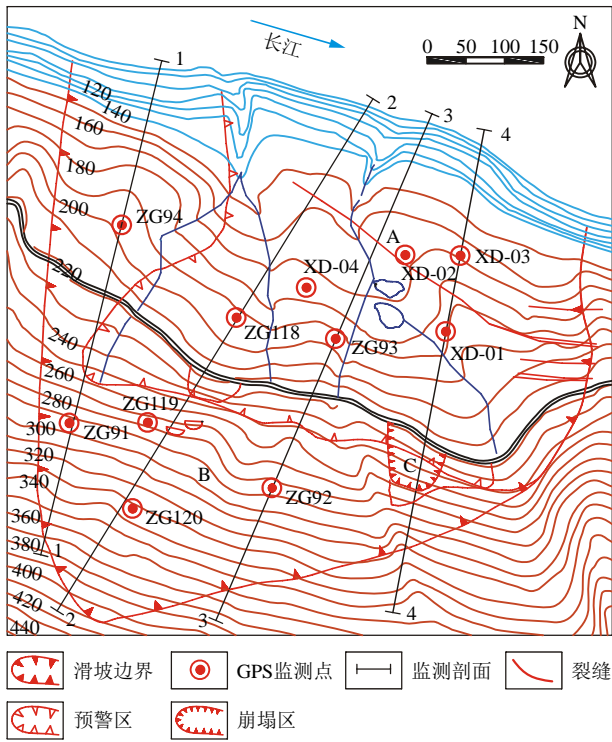


图 3 白水河滑坡监测平面布置图

Fig.3 Diagram of monitoring arrangement in Baishuihe landslide

3.2 基于监测数据的滑坡变形特征分析

白水河滑坡为典型的牵引式滑坡，即滑坡前缘岩土体先发生局部垮塌或滑移变形，形成新的临空面，继而导致紧临前缘的岩土体接着发生局部垮塌或滑移变形，依次类推^[6, 19]。

滑坡体上现布有 11 个 GPS 监测点，考虑滑坡的变形模式以及监测数据的完整性，本文选取位于滑坡预警区内正中部的 ZG118 监测点进行详细分析，其累积位移、库水位及降雨量监测曲线如图 4 所示。根据水库水位调度情况，将监测曲线划分为 3 个时段依次进行分析。

(1) 2003 年 8 月~2006 年 8 月(a 段)，库水位在 135~139 m 波动，该时段内库水位的影响范围和波

动幅度均较小，滑坡变形主要受降雨的影响。每年 5 月~9 月为降雨量集中的汛期，滑坡均出现明显的变形阶段；10 月~次年 4 月为降雨量稀少的非汛期，滑坡位移趋于平稳。如 2004 年汛期和非汛期降雨量分别为 804.3 和 287 mm，滑坡最大位移增长速率分别为 63 和 32 mm/月。

(2) 2006 年 9 月~2008 年 9 月(b 段)，库水位在 145~155 m 波动，该时段内库水的影响范围和波动幅度均大幅增加。在库水位上升期间，累积位移曲线较为平稳，最大位移增长速率仅为 19 mm/月。当水库水位首次由 155 m 下降至 145 m，累积位移增长幅度发生突变，最大位移增长速率达 334 mm/月(2007 年 7 月)。这是由强烈的外界因素导致的(汛期降雨和库水位大幅度下降)。随后这两种影响因素减弱，累积位移监测曲线逐渐恢复平稳^[19]。

(3) 2008 年 10 月~2013 年 12 月(c 段)，库水位在 145~175 m 周期性波动，监测点累积位移持续呈“阶跃型”增长。监测点最大位移增加速率均出现在库水位下降及低水位时段。5 a 内最大位移增长速率分别为 99(2009 年)、74(2010 年)、84(2011 年)、63(2012 年)和 63 mm/月(2013 年)。随着库水位的长期调度，滑坡进行了长期的应力调整，逐渐适应了新的库水位调度模式，其位移增长逐渐趋于平稳。

在滑坡的孕育和发展演化过程中，其累积位移与时间关系曲线可分为初始变形阶段、匀速变形阶段和加速变形阶段，加速变形阶段可进一步划分为初加速、中加速、临滑 3 个亚阶段^[19]。白水河滑坡自 2003 年以来，累积位移持续增加。2007 年 7 月滑坡位移增长速率达到最大，随后位移增长逐渐趋于平稳，可知白水河滑坡至 2013 年 12 月仍处于等速变形阶段。

综上所述，白水河滑坡变形模式为牵引式，变形始于坡脚，继而向后缘牵引发展。滑坡变形受库水位波动和降雨的共同影响。当库水位上升时，坡

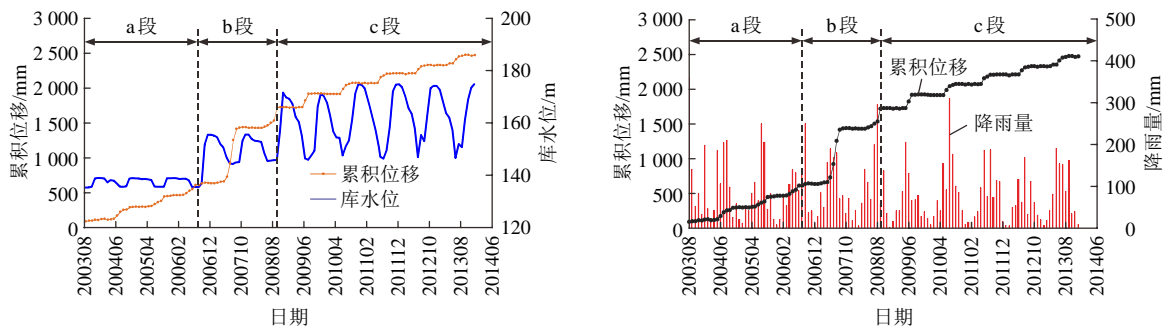


图 4 滑坡累积位移 - 库水位 - 降雨量监测曲线

Fig.4 Monitoring curves for cumulative displacement, reservoir water level and rainfall

体内地下水位抬升，但库水同时为其提供了与坡面正交且指向坡面的静水压力，有利于滑坡稳定；当库水位下降时，由于地下水位的滞后于库水位的变化，产生指向坡外的动水压力，不利于滑坡稳定。降雨通过改变坡体结构、坡体容重、滑带土强度参数和动静水压力等效效应降低滑坡稳定性。在库水位周期性波动和降雨的影响下，该滑坡的累积位移曲线显示出“阶跃型”特征。根据累积位移-时间曲线分析，该滑坡仍处于等速变形阶段。

4 白水河滑坡位移预测

基于滑坡变形特征、变形模式及变形阶段等分析，本文选取位于滑坡预警区内的 ZG118 监测点 2003 年 8 月~2013 年 12 月的 GPS 累积位移监测数据为时间序列原始样本。取 2003 年 8 月~2012 年 12 月的监测数据为模型训练集，以 2013 年 1~12 月的数据作为预测集。

4.1 趋势项位移提取及预测

趋势项位移反映了滑坡位移的长期变化趋势，本文采用移动平均法提取。设 $S_i = \{s_1, s_2, \dots, s_t\}$ 为原始位移时间序列，则趋势项位移的计算方法如下：

$$\phi(i) = \frac{s_i + s_{i-1} + \dots + s_{i-n+1}}{n} \quad (i = n, n+1, n+2, \dots, t) \tag{7}$$

式中： $\phi(i)$ 为趋势项位移； n 为周期值，鉴于三峡水库水位以年为单位进行周期性调度，本文取 $n=12$ 。趋势项位移提取值如图 5 所示。




图 5 趋势项位移提取值
Fig.5 Extracted values of trend displacement

滑坡趋势项位移显示出分段函数特点，因此将其划分为 3 个时段(2004 年 5 月~2007 年 5 月，2007 年 6 月~2009 年 8 月，2009 年 9 月~2012 年 12 月)，

采用 Matlab R2015b 分别对各时段数据进行三次多项式拟合，拟合计算式为

$$y = a_1x^3 + a_2x^2 + a_3x + a_4 \tag{8}$$

拟合计算结果如表 1 所示。将拟合函数直接用于趋势项位移的预测，其平均绝对误差为 6.971 mm，平均相对误差为 2.859%，标准差为 5.401。将前一期次的趋势项位移预测结果加入训练集中重新拟合，并用于预测当期趋势项位移。预测值平均绝对误差为 3.269 mm，平均相对误差为 1.387%，标准差为 1.624，趋势项位移预测结果如图 6 所示。对比可知，将趋势项位移预测结果加入训练集中，保证模型得到不断更新，能进一步提高趋势项位移的预测精度，且预测结果更为平稳。

表 1 趋势项位移三次多项式拟合结果
Table 1 Parameters of the trend displacement based on polynomial fitting

时段	a_1	a_2	a_3	a_4	R^2
y_1	0.001 0	-0.006 5	14.055	114.74	0.999 2
y_2	0.044 1	-3.910 0	98.947	529.50	0.995 6
y_3	0.000 9	-0.130 3	16.382	1 766.30	0.999 8





图 6 趋势项位移预测结果
Fig.6 Predicted values of trend displacement

4.2 周期项位移预测

(1) 周期项位移提取

从滑坡累积位移中剔除趋势项位移，即可得到周期项位移，如图 7 所示。

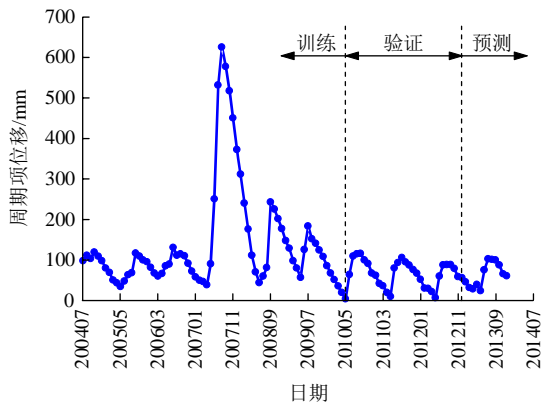


图 7 周期项位移提取值

Fig.7 Extracted values of periodic displacement

(2) 影响因子选取

影响因子的选取对于滑坡位移预测精度的好坏至关重要。白水河滑坡累积位移 - 时间曲线呈阶跃型，降雨及周期性水库水位波动是导致该变形特征的主导因素。此外，滑坡所处的状态对于外界诱发


因素下滑坡位移的精确预测也有着重要影响。

① 降雨


降雨是导致三峡库区滑坡变形破坏的重要因素，一方面通过冲刷坡面改变坡体结构；另一方面通过入渗改变坡体容重、滑带土强度参数和动静水压力^[21]。降雨入渗是一个相对缓慢的过程，滑坡发生前一到两月的有效降雨量对滑坡变形有较大影响^[5, 22]。如图 8(a)所示，ZG118 监测点周期项位移波动规律与当月降雨量及前两月降雨量高度一致。因此，选取当月降雨量、前两月降雨量表征降雨影响因素。

② 库水位


库水位升降对滑坡变形的影响主要表现在 2 个方面：一方面通过造成边坡干湿循环的加卸载作用，影响岩土体的物理力学性质；另一方面，通过改变坡体内渗流场进而影响坡体内外力学效应^[23]。在相同的库水位变化条件下，滑坡所处的初始库水位高程不同，对滑坡变形的影响也不同。此外，库水位变化对滑坡变形的产生存在一定的滞后效应。因此，选取库水位高程、当月库水位变化及双月库水位变化表征库水影响因素，如图 8(b)所示。



(a) 周期项位移与降雨量关系



(b) 周期项位移与库水位变化关系



(c) 周期项位移与累积位移增量关系

图8 周期项位移与影响因子关系

Fig.8 Relationships between periodic displacement and influence factors

③ 滑坡变形状态

处于不同变形状态的滑坡，在相同外界激励下的位移响应存在差异^[24]。当滑坡处于稳定状态时，即使是强烈的外界因素也不足以引起滑坡的大范围变形；而当滑坡处于临界状态时，外部因素的轻微扰动就可能破坏滑坡系统的原有平衡，从而引起滑坡变形^[25-26]。因此，选取滑坡当月位移量、前2月位移量及前3月位移量表征滑坡变形状态影响因素^[18]，如图8(c)所示。

为验证所选影响因子的合理性，采用灰色关联度分析法计算各影响因子与滑坡周期项位移的关联度。其中，分辨系数取0.5，当关联度超过0.6时，即认为影响因子与周期项位移密切相关^[27]。关联度结果如表2所示，表明所选影响因子均与滑坡周期项位移显著相关。因此，选取降雨(当月降雨量、双月降雨量)、库水位(库水位高程、当月库水位变化、双月库水位变化)及滑坡变形状态(当月位移量、前2月位移量和前3月位移量)共计8个影响因子，用于滑坡周期项位移的预测。

(3) LSTM模型建立及参数选取

将样本划分为训练集和预测集，在训练集中，70%的样本用于建立模型，30%的样本用于检验模型的预测能力，如图7所示。

将选取的8个影响因子作为LSTM模型的输

入，周期项位移作为模型的输出。为消除数据量纲的影响，将周期项位移及影响因子数据归一化到[-1, 1]。使用Keras框架搭建LSTM模型，以TensorFlow为后端，利用python语言编写。采用网格搜索法(Grid search method)进行参数寻优，最终设定该模型包含3层神经网络(前2层为LSTM层，第3层为dense层)。输入序列长度(input sequence length)对模型的预测精度有重要影响，控制着用于预测某时刻滑坡位移的前期历史数据点的个数^[11]。采用网格搜索法确定最优输入序列长度为12。

(4) 周期项位移预测结果对比及分析

采用已在滑坡位移预测方面有较好应用的支持向量机模型(SVM)进行模型预测效果的对比评价。以粒子群优化算法(particle swarm optimization, PSO)进行参数寻优，其原理可查阅张俊等^[3-4]。将所有数据归一化到[-1, 1]，PSO参数采用LIBSVM工具箱中的默认值，即粒子种群数为20，最大进化代数为200，学习因子 $c_1 = 1.5$ ， $c_2 = 1.7$ ，惯性权重 $w = 1$ 。设定惩罚因子 $C = [0, 100]$ ，核函数参数 $g = [0, 100]$ ，得到最优参数组合为 $C = 4.8$ ， $g = 0.01$ 。

周期项位移预测结果如图9所示，各模型预测精度及误差对比如表3所示。LSTM模型预测结果的相关性系数R和均方根误差RMSE分别为0.972和7.351 mm，整体预测精度较高，具体分析如下：

表2 周期项位移与影响因子关联度

Table 2 Degrees of grey correlation between the period term displacement and influence factors

降雨		库水位			滑坡演化状态		
当月降雨量	双月降雨量	库水位高程	当月库水位变化量	双月库水位变化量	当月位移增量	前2月位移增量	前3月位移增量
0.777	0.783	0.836	0.864	0.851	0.858	0.841	0.813

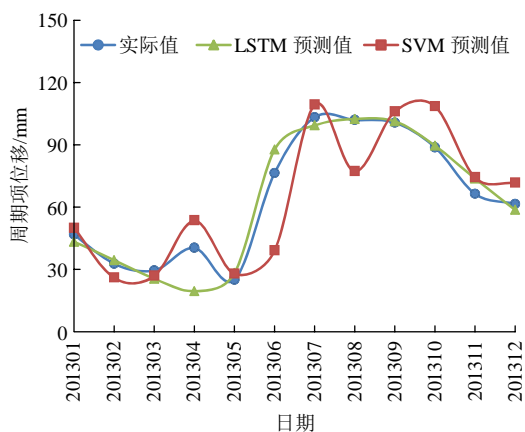


图 9 周期项位移预测结果

Fig.9 Predicted values of periodic displacement

① 2013 年 4 月周期项位移出现极大值点，该点预测值的绝对误差和相对误差分别为 20.832 mm 和 51.195%。② 在预警最关键的 5 月~7 月，水库水位持续下降，降雨量达到 347.3 mm，滑坡累积位移出现阶跃式抬升。该时段内预测值的最大绝对误差和最大相对误差分别为 11.208 mm 和 14.618%，预测效果较为理想。可见该模型在外界诱发因素急剧变动时，显示出了较强的预测能力。③ 在 8 月~12 月期间，水库水位逐渐抬升至 175 m，降雨量相对稀少，周期项位移平稳减小。LSTM 模型在该时段内的预测值和真实值较为一致，最大相对误差和平均相对误差分别为 11.034% 和 3.548%。

SVM 模型预测结果的相关性系数 R 和均方根误差 $RMSE$ 分别为 0.806 和 15.433 mm，整体预测精度低于 LSTM 模型，具体分析如下：① 在阶跃式位移出现之前，该模型表现良好，且对于小幅度波动的位移极值点(2013 年 4 月)的预测显示出一定的优势。② 在 5 月~7 月期间，滑坡位移呈阶跃式剧增，SVM 模型的预测结果出现较大误差，其最大绝对误差和最大相对误差分别 37.176 mm 和 48.485%，明显大于 LSTM 模型(11.208 mm 和 14.618%)。这也与已有研究成果相一致，即当降雨或库水位突然急剧地变动时，采用 SVM 模型预测周期项位移会导致个别点的预测值误差较大^[3-4]。③ 在 8 月之后，SVM 模型的预测值仍存在误差较大点，最大相对误差和平均相对误差分别为 24.063% 和 16.063%。

4.3 滑坡累积位移预测

根据时间序列分解原理，将各分项位移预测值叠加，即可得到滑坡累积位移预测值，如图 10 所示。结果表明：滑坡累积位移预测值与实测值基本一致，相关性系数 R 为 0.993，均方根误差 $RMSE$ 为 2.450 mm，总体预测精度较高且能较好地预测出滑坡位移的阶跃型变化。累积位移预测值和周期项位移预测值的误差最大点均出现在 2013 年 4 月，表明周期项位移的预测精度对滑坡累积位移的预测精度有至关重要的影响。

表 3 周期项位移预测精度及误差对比

Table 3 Accuracy evaluation and comparison of periodic displacement

日期	实际值/mm	LSTM 模型			SVM 模型		
		预测值/mm	绝对误差/mm	相对误差/%	预测值/mm	绝对误差/mm	相对误差/%
201301	47.076	43.574	3.503	7.440	50.315	3.239	6.879
201302	33.041	34.760	1.719	5.202	26.480	6.561	19.856
201303	29.825	25.848	3.977	13.334	27.396	2.429	8.144
201304	40.693	19.861	20.832	51.194	53.894	13.201	32.441
201305	25.351	28.616	3.265	12.881	28.295	2.944	11.613
201306	76.675	87.884	11.208	14.618	39.500	37.176	48.485
201307	103.439	99.512	3.926	3.796	109.625	6.186	5.980
201308	102.132	102.597	0.465	0.456	77.555	24.576	24.063
201309	100.825	101.477	0.652	0.647	106.249	5.424	5.380
201310	88.991	89.783	0.791	0.889	108.811	19.820	22.272
201311	66.632	73.983	7.352	11.034	74.666	8.034	12.057
201312	61.816	58.903	2.913	4.712	72.042	10.227	16.544
最小值			0.465	0.456		2.429	5.380
最大值			20.832	51.194		37.176	48.485
平均值			5.050	10.517		11.651	17.809

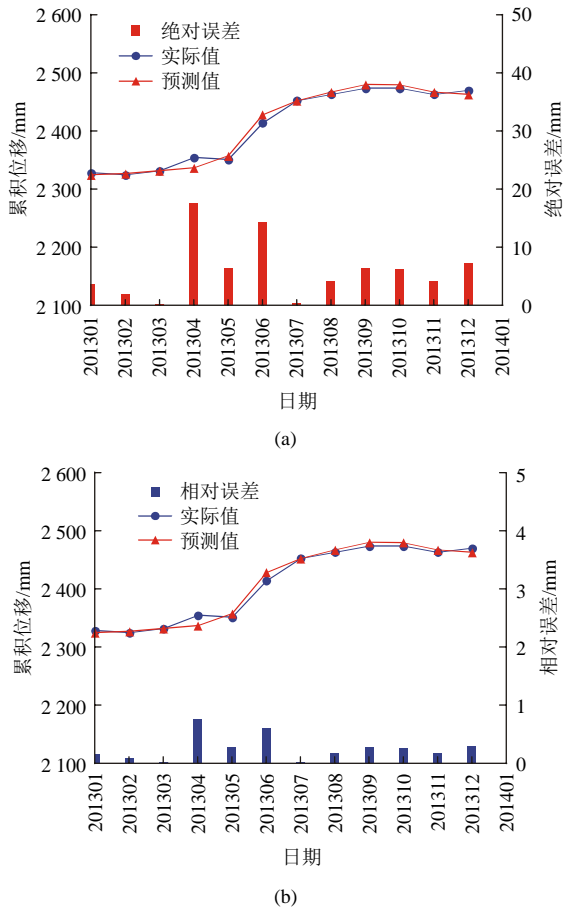


图 10 累积位移预测结果
Fig.10 Predicted values of cumulative displacement

5 讨论

采用长短时记忆网络 LSTM 来构造滑坡周期项位移的预测模型。以影响因子作为模型的输入，以周期项位移作为模型的输出。模型的输入和输出结构描述了影响因素与滑坡位移的因果关系；模型内部节点的状态演化对应于滑坡内部的状态变化；模型的记忆效应则表达了影响因素的长期作用。因此，该模型能够更好地体现滑坡的动态演化过程^[7]。

基于相同的训练集进行周期项位移预测，动态模型 LSTM 的预测精度高于静态模型 SVM。主要原因在于 LSTM 模型能够建立滑坡不同时刻状态之间的联系，将先前的信息应用到当前的任务上，即 LSTM 模型能够保存历史信息并加以利用，充分发挥了其处理时间序列时挖掘前后关联信息的优势，从而有效提高位移预测精度。此外，LSTM 模型在长时间尺度上能够有选择地记忆部分特征。随着信息进入，LSTM 模型会对信息进行判断和筛选，符合要求的信息才会被留下，不符合的信息则会被舍弃。因此，训练数据不存在时效性问题。

对于静态模型(如 SVM)，不同时刻的滑坡状态之间没有连接，模型只能学习和使用当前时刻的信息。随着时间的推移，预测结果的准确性将受到长期历史信息的干扰^[6-18]，即数据存在时效性。李麟玮等^[28]对训练数据的时效性开展了研究，认为滑坡周期项位移预测中，训练数据的时效性由外界诱发因素与滑坡位移之间响应关系的改变所致。为了建立更为精确可靠的预测模型，应及时添加最新数据并剔除失效数据，保持监测数据的不断更新^[6]。但对数据时效性的判断并非易事，目前只能进行定性判断而无法提供有效的定量判断依据，这也在一定程度上限制了 SVM 等静态模型的预测能力。

6 结论

针对滑坡这一复杂的非线性动态系统，提出了一种基于时间序列和长短时记忆网络 LSTM 的滑坡位移动态预测模型。将该模型用于预测三峡库区白水河滑坡的位移，预测值与实际值一致性较好，且在阶跃式变形期的预测优势尤为突出，为三峡库区阶跃型滑坡位移预测提供了新的思路和探索。

与目前流行的静态预测模型相比，该模型具有以下优点：(1) 实现了模型的状态反馈，能更好地反映滑坡演化的动态系统本质；(2) 模型具有记忆功能，能够充分利用滑坡历史信息，从而有效提高位移预测精度；(3) 由于独特的设计结构，LSTM 在模型训练过程中能够对历史信息进行判断和取舍，不需要进行训练数据时效性的分析。

作为一种深度机器学习方法，该模型需要训练的参数较多，可能导致模型输出不稳定且计算时间较长。此外，数据量的大小也是影响该模型预测能力的一个重要因素。有限的训练样本可能导致动态网络模型得不到充分训练，从而影响模型的预测精度。

参考文献(References):

[1] 许强, 黄润秋, 李秀珍. 滑坡时间预测预报研究进展[J]. 地球科学进展, 2004, 19(3): 478 - 483.(XU Qiang, HUANG Runqiu, LI Xiuzhen. Research progress on the landslide time prediction[J]. Advance in Earth Sciences, 2004, 19(3): 478 - 483.(in Chinese))

[2] 邓冬梅, 梁焯, 王亮清, 等. 基于集合经验模态分解与支持向量机回归的位移预测方法: 以三峡库区滑坡为例[J]. 岩土力学, 2017, 38(12): 3 660 - 3 669.(DENG Dongmei, LIANG Ye, WANG Liangqiang, et al. Displacement prediction method based on ensemble empirical mode decomposition and support vector machine regression—a case of landslides in Three Gorges Reservoir area[J]. Rock and Soil Mechanics, 2017, 38(12): 3 660 - 3 669.(in Chinese))

- [3] 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.(ZHANG Jun, YIN Kunlong, WANG Jiajia, et al. Displacement prediction of Baishuihe landslide based on time series and PSO-SVR model[J]. Chinese Journal of Rock Mechanics and Engineering, 2015, 34(2): 382 - 391.(in Chinese))
- [4] ZHOU C, YIN K, CAO Y, et al. Application of time series analysis and PSO-SVM model in predicting the Bazimen landslide in the Three Gorges Reservoir[J]. Engineering Geology, 2016, 204: 108 - 120.
- [5] 杜娟, 殷坤龙, 柴波. 基于诱发因素响应分析的滑坡位移预测模型研究[J]. 岩石力学与工程学报, 2009, 28(9): 1 783 - 1 789.(DU Juan, YIN Kunlong, CHAI Bo. Study of displacement prediction model of landslide based on response analysis of inducing factors[J]. Chinese Journal of Rock Mechanics and Engineering, 2009, 28(9): 1 783 - 1 789.(in Chinese))
- [6] DU J, YIN K, LACASSE S. Displacement prediction in colluvial landslides, Three Gorges Reservoir, China[J]. Landslides, 2013, 10: 203 - 218.
- [7] 姚为, 廉城, 程立. 滑坡位移的动态概率预测模型[J]. 水文地质工程地质, 2015, 42(5): 134 - 139+148.(YAO Wei, LIAN Cheng, CHENG Li. A dynamic model for landslide displacement prediction[J]. Hydrogeology and Engineering Geology, 2015, 42(5): 134 - 139+148.(in Chinese))
- [8] 姚为, 廉城. 基于储备池运算和分形插值的滑坡位移预测[J]. 长江科学院院报, 2014, 31(12): 43 - 48.(YAO Wei, LIAN Cheng. Prediction of landslide displacement based on reservoir computing and fractal interpolation[J]. Journal of Yangtze River Scientific Research Institute, 2014, 31(12): 43 - 48.(in Chinese))
- [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] PALANGI H, DENG L, SHEN Y, et al. Deep sentence embedding using the long short-term memory network: analysis and application to information retrieval[J]. IEEE/ACM Transactions on Audio, Speech and Language Processing, 2016, 24(4): 694 - 707.
- [11] XU S, NIU R. Displacement prediction of Baijiabao landslide based on empirical mode decomposition and long short-term memory neural network in Three Gorges area, China[J]. Computers and Geosciences, 2018, 111: 87 - 96.
- [12] 徐峰, 汪洋, 杜娟, 等. 基于时间序列分析的滑坡位移预测模型研究[J]. 岩石力学与工程学报, 2011, 30(4): 746 - 751.(XU Feng, WANG Yang, DU Juan, et al. Study of displacement prediction model of landslide based on time series analysis[J]. Chinese Journal of Rock Mechanics and Engineering, 2011, 30(4): 746 - 751.(in Chinese))
- [13] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks[C]// Proceedings of International Conference on Acoustics, Speech and Signal Processing Acoustics. Vancouver, Canada: IEEE, 2013: 6 645 - 6 649.
- [14] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: learning useful representation in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3 371 - 3 408.
- [15] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157 - 166.
- [16] HOCHREITE S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1 735 - 1 780.
- [17] 徐聪. 基于卷积长短时记忆神经网络的时序信号多粒度分析处理方法研究[硕士学位论文][D]. 哈尔滨: 哈尔滨工业大学, 2017.(XU Cong. Research on multi-granularity analysis method of time sequence signaling convolution long short term memory network[M. S. Thesis][D]. Harbin: Harbin Institute of Technology, 2017.(in Chinese))
- [18] CAO Y, YIN K, ALEXANDER D, et al. Using an extreme learning machine to predict the displacement of step-like landslides in relation to controlling factors[J]. Landslides, 2016, 13: 725 - 736.
- [19] 许强, 汤明高, 徐开祥, 等. 滑坡时空演化规律及预警预报研究[J]. 岩石力学与工程学报, 2008, 27(6): 1 104 - 1 112.(XU Qiang, TANG Minggao, XU Kaixiang, et al. Research on space-time evolution laws and early warning-prediction of landslides[J]. Chinese Journal of Rock Mechanics and Engineering, 2008, 27(6): 1 104 - 1 112.(in Chinese))
- [20] MIAO F, WU Y, XIE Y, et al. Prediction of landslide displacement with step-like behavior based on multialgorithm optimization and a support vector regression model[J]. Landslides, 2018, 15: 475 - 488.
- [21] YANG B, YIN K, XIAO T, et al. Annual variation of landslide stability under the effect of water level fluctuation and rainfall in the Three Gorges Reservoir, China[J]. Environmental Earth Sciences, 2017, 76: 564 - 580.
- [22] KEEFER D, WILSON R, ROBERT K, et al. Real-time landslide warning during heavy rainfall[J]. Science, 1987, 238: 921 - 925.
- [23] 刘磊. 三峡水库万州区库岸滑坡灾害风险评估研究[博士学位论文][D]. 武汉: 中国地质大学, 2016.(LIU Lei. Assessment of landslide risk along Wanzhou area in Three Gorges Reservoir[Ph. D. Thesis][D]. Wuhan: China University of Geosciences, 2016.(in Chinese))
- [24] 刘勇, 秦志萌, 刘曼, 等. 基于状态划分的滑坡位移预测方法研究[J]. 地质科学情报, 2018, 37(1): 184 - 189.(LIU Yong, QIN Zhimeng, LIU Man, et al. Landslide displacement prediction method based on state division[J]. Geological Science and Technology Information, 2018, 37(1): 184 - 189.(in Chinese))
- [25] 龙辉, 秦四清, 万志清. 降雨触发滑坡的尖点突变模型[J]. 岩石力学与工程学报, 2002, 21(4): 502 - 508.(LONG Hui, QIN Siqing, Wan Zhiqing. Catastrophe analysis of rainfall-induced landslides[J]. Chinese Journal of Rock Mechanics and Engineering, 2002, 21(4): 502 - 508.(in Chinese))
- [26] GLADE T, ANDERSON M, CROZIER M. Landslide hazard and risk[M]. Vienna, Austria: Wiley, 2012: 1 - 40.
- [27] 汪洋, 殷坤龙, 安关峰. 滑坡敏感因子的灰色关联分析[J]. 岩土力学, 2004, 25(1): 91 - 93.(WANG Yang, YIN Kunlong, AN Guanfeng. Grey correlation analysis of sensitive factors of landslide[J]. Rock and Soil Mechanics, 2004, 25(1): 91 - 93.(in Chinese))
- [28] 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): 1 395 - 1 406.(LI Linwei, WU Yiping, MIAO Fasheng, et al. Displacement prediction of landslide based on variational mode decomposition and GWO-MIC-SVR model[J]. Chinese Journal of Rock Mechanics and Engineering, 2018, 37(6): 1 395 - 1 406.(in Chinese))