

基于ICEEMDAN与Attention-LSTM的 矿山边坡位移预测

李 荟, 韩晓飞, 朱万成, 毛嘉石
(东北大学 资源与土木工程学院, 辽宁 沈阳 110819)

摘 要: 为了提高矿山边坡位移预测的精度,提出了1种基于改进自适应噪声完备集合经验模态分解(ICEEMDAN)、最小二乘拟合与融入注意力机制的长短时记忆网络的矿山边坡位移预测模型. 首先,针对矿山边坡位移监测数据的时序性、非线性等特点,引入改进的模式分解方法将累积位移进行时频分解,获得趋势项、周期项和随机项,有效降低了数据复杂度. 其次,针对趋势项预测,采用最小二乘拟合方法建立三次多项式回归预测模型;针对周期项预测,引入注意力机制区分不同时刻位移数据的重要程度,有效捕捉了长时间位移序列内部的依赖关系. 最终,通过整合趋势项和周期项预测结果,获得矿山边坡累积位移的预测结果. 以西藏巨龙铜矿边坡为例,测试了该模型的性能. 结果表明,提出的边坡位移预测模型的均方根误差和平均绝对百分比误差分别为5.99 mm和5.94%,与传统长短时记忆网络模型相比,分别下降了51.30%和55.17%,预测精度显著提高.

关 键 词: 位移预测;露天矿;滑坡;长短时记忆网络;注意力机制

中图分类号: TD 804; TP 18 文献标志码: A 文章编号: 1005-3026(2025)07-0163-08

Mine Slope Displacement Prediction Based on ICEEMDAN and Attention-LSTM

LI Hui, HAN Xiao-fei, ZHU Wan-cheng, MAO Jia-shi

(School of Resources & Civil Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: LI Hui, E-mail: lihui@mail.neu.edu.cn)

Abstract: In order to improve the accuracy of mine slope displacement prediction, a mine slope displacement prediction model based on an improved complete ensemble empirical mode decomposition with adaptive noise (ICEEMDAN), least squares fitting method and long short-term memory network integrated into the attention mechanism was proposed. Firstly, considering the temporal and nonlinear characteristics of the mining slope displacement monitoring data, an improved mode decomposition method was employed to perform the time-frequency decomposition of cumulative displacement, resulting in trend, periodic, and random components, thereby effectively reducing the data complexity. Secondly, to predict the trend component, a cubic polynomial regression prediction model was developed by using the least squares fitting method. To predict the periodic component, an attention mechanism was introduced to distinguish the importance of displacement data at different times, which effectively captured the internal dependencies within the long-term displacement sequences. Finally, the predicted results of the trend and periodic components were integrated to obtain the cumulative displacement of the mining slope. Taking the slope of Julong Copper Mine in Xizang as an example, the performance of the proposed method was tested. The results demonstrate that the proposed slope displacement prediction model achieves a root mean square error (RMSE) of

收稿日期: 2024-10-30

基金项目: “十四五”国家重点研发计划项目(2022YFC2903903);国家自然科学基金资助项目(52304167);中央高校基本科研业务费专项资金资助项目(N2301020);辽宁省自然科学基金联合基金资助项目(2023-MSBA-122).

作者简介: 李 荟(1990—),女,辽宁锦州人,东北大学副教授,硕士生导师;朱万成(1974—),男,新疆呼图壁人,东北大学教授,博士生导师.

5.99 mm and a mean absolute percentage error (MAPE) of 5.94%. The RMSE and MAPE decrease by 51.30% and 55.17% compared with the traditional LSTM model, respectively. These results highlight the significant improvement in prediction accuracy achieved by the proposed method.

Key words: displacement prediction; open-pit mining; landslide; long short-term memory (LSTM) network; attention mechanism

露天开采是矿山高效、经济开采的常见方式,每增大 1° 的矿山边坡角就可以节约大量剥离成本^[1].为了提高矿山开采的经济效益,露天矿山的边坡不断变高、变陡,高陡边坡产生的滑坡灾害时有发生,造成了严重的生命财产损失,如,内蒙古阿拉善新井煤业有限公司露天煤矿“2·22”特别重大坍塌事故,造成53人死亡、6人受伤,直接经济损失20 430.25万元.预测矿山边坡位移对于滑坡灾害的预防具有重要意义.

传统的矿山边坡滑坡研究方法主要为数值模拟方法,通过模拟矿山边坡在不同条件下的形变,得到边坡变形趋势和破坏过程^[2-5].然而,基于数值模拟的边坡变形研究方法在建模过程中需要确定大量力学参数和应力边界条件,这些信息的确定往往依赖于经验,导致数值模拟模型无法真正反映矿山边坡的实际情况,从而使边坡位移预测结果存在偏差.随着传感技术在矿山边坡监测方面的应用,监测系统采集了大量能够反映矿山地表变形特征的监测数据.近年来,利用机器学习和深度学习方法解决矿山边坡位移预测问题成为新的研究热点.Jiang等^[6]提出了结合变量选择、麻雀搜索算法(sparrow search algorithm, SSA)及深度极限学习机(deep extreme learning machine, DELM)的边坡位移预测模型,提高了陕西凤翔某水泥矿山边坡位移预测的精度.Dai等^[7]针对不同蠕变阶段滑坡突变位移预测精度低的问题,利用具有足够监测数据的相似滑坡案例与目标案例之间的时空关联,提高对边坡突变位移的预测能力.Hao等^[8]针对露天边坡地表变形预测存在的预测误差大、收敛速度慢、泛化能力差等问题,提出了基于蜉蝣算法(mayfly algorithm, MA)优化的支持向量机(support vector machine, SVM)智能预测模型,以安家岭露天矿北边坡为例,验证了该预测模型的有效性.这些基于人工智能的矿山边坡预测方法虽然利用了能够反映矿山边坡变形特征的变形监测数据,但是采用的方法是直接对原始累积位移进行建模预测,没有考虑数据本身的时序性、非线性、复杂性等特点,预测结果往往存在较大的误差.模态分解技术能够将累积位移进行时频分

解,有效降低数据的复杂度.边坡累积位移分解后,一般得到趋势项、周期项和随机项,分别用于表征边坡自身地质条件、外界诱发因素及随机干扰的影响^[9].长短时记忆(long short-term memory, LSTM)网络能够较好地处理时序性数据,与模态分解技术相结合,能够提高预测精度,这种方法已经普遍用于解决滑坡位移预测问题.Yang等^[10]通过时间序列分析,将累积位移分解为趋势项和周期项,基于LSTM构建滑坡位移动态预测模型,通过对三峡坝区白水河滑坡和八字门滑坡的预测,验证了该模型的有效性.Lin等^[11]采用加权移动平均(weighted moving average, WMA)方法将滑坡累积位移分解为趋势项和周期项,采用多项式拟合与添加全连接层的LSTM预测方法,预测了山体滑坡位移.Liu等^[12]利用趋势分析和周期分析对滑坡位移进行了描述,运用LSTM预测了三峡坝区阶梯式滑坡位移.Yang等^[13]利用ICEEMDAN进行累积变形分解、去噪,并基于遗传算法(genetic algorithm, GA)优化的LSTM和反向传播(back propagation, BP)神经网络建立了位移预测模型(GA-LSTM-BP),准确预测了煤矿开采过程中的坑道变形.然而,在露天矿边坡位移预测方面,基于深度学习的累积位移分解预测方法应用较少.

此外,矿山边坡位移监测数据具有历史性与长期依赖性的特点,传统的LSTM对于长时间序列可能会遗忘较早学习的特征,忽视数据内部依赖关系,从而导致一些重要信息的丢失^[14].注意力机制与LSTM的结合可以更好地捕捉时间序列的长期时间依赖性,提高LSTM模型预测能力.如,张振坤等^[15]、唐宇峰等^[16]、曹鑫宇等^[17]提出了融入注意力机制的LSTM方法,对地表变形监测数据中的重要特征进行关注和学习,捕捉整个序列内部的依赖关系,提取数据不同尺度的特征,进一步提升了地表变形预测的效果.因此,本文采用ICEEMDAN方法,将矿山边坡累积位移分解为趋势项、周期项和随机项.利用三次多项式拟合(cubic polynomial fitting, CPF)方法对趋势项位移进行预测,采用Attention-LSTM方法对周期项位移进行预测.最后,通过趋势项与周期项

位移预测结果的叠加,获得累积位移的预测值.本文提出的方法应用于西藏巨龙铜矿边坡位移预测问题中,验证了方法的有效性.

1 矿山边坡位移预测

矿山边坡累积位移数据具有非线性和时序性等特点,累积位移可以分解为趋势项、周期项和随机项.趋势项位移是指受边坡自身地质条件(如地质构造、岩性等)影响,总体变形趋势呈单调递增,能够反映边坡位移的长期变化趋势;周期项是边坡因外部因素周期性作用而产生的变形,反映由外界诱发因素(如降水、温度、开采扰动等)引起的边坡周期性变化;随机项一般为模型误差及一些非常规因素造成的数据波动,具有频率高、幅值低的特点,反映了由非季节性降雨、监测误差等引起的地表变形随机性变化.矿山边坡累积位移预测主要包括趋势项位移预测和周期项位移预测,随机项在边坡位移预测过程中往往被忽略不计.

1.1 ICEEMDAN 方法

模态分解技术能够将累积位移进行时频分解,得到高频、低频和残差序列.高频序列重组为随机项,低频序列重组为周期项,残差序列为趋势项.经验模态分解(empirical mode decomposition, EMD)通过不断地迭代将原始数据分解为一系列简单的振荡分量和一个反映时间趋势的残差序列,这些振荡分量包括多个具有不同特征尺度的本征模态函数(intrinsic mode function, IMF),但 IMF 之间可能存在模态混叠现象,容易导致去噪后的信号失真.ICEEMDAN 方法采用前一步计算的残差与本次计算的多个噪声信号的平均残差之差作为本次迭代的 IMF,可以进一步解决模型混叠问题,减少分解结果中 IMF 的假分量^[18].引入 2 个新的算子: $M(\cdot)$ 与 $E_k(\cdot)$.其中, $M(\cdot)$ 表示通过 EMD 产生的原始信号的局部平均值, $E_k(\cdot)$ 表示通过 EMD 分解得到的第 k 个 IMF.具体 ICEEMDAN 分解步骤如下:

步骤 1 向原始信号中添加高斯白噪声,构造噪声可控的信号,如式(1)所示:

$$x^{(t)} = x + \beta_0 E_1(w^{(t)}). \quad (1)$$

其中: x 为原始信号; $x^{(t)}$ 为第 t 次构造信号, $t = 1, 2, 3, \dots, n$; β_0 为信号第 1 次分解时的噪声标准差; $w^{(t)}$ 为零均值单位方差的高斯白噪声; $E_1(w^{(t)})$ 为 EMD 分解得到的第 1 个 IMF.

步骤 2 第 1 个残差分量由式(2)计算:

$$r_1 = \frac{1}{I} \sum_{i=1}^I M(x^{(t)}). \quad (2)$$

其中: I 为原始信号 x 的数据点数; r_1 为第 1 个残差分量.

步骤 3 定义 d_k 为分解生成的第 k 个模态分量,当 $k=1$ 时,计算得到第 1 个模态分量:

$$d_1 = x - r_1. \quad (3)$$

当 $k=2$ 时,计算第 2 个残差分量,如式(4)所示:

$$r_2 = \frac{1}{I} \sum_{i=1}^I M(r_1 + \beta_1 E_2(w^{(t)})). \quad (4)$$

计算 r_1 与 r_2 的差值,就可以得到第 2 个模态分量:

$$d_2 = r_1 - r_2. \quad (5)$$

步骤 4 当 $k=3, 4, 5, \dots, n$ 时,计算第 k 个残差分量 r_k ,如式(6)所示:

$$r_k = \frac{1}{I} \sum_{i=1}^I M(r_{k-1} + \beta_{k-1} E_k(w^{(t)})). \quad (6)$$

步骤 5 利用式(7)计算第 k 个模态分量 d_k :

$$d_k = r_{k-1} - r_k. \quad (7)$$

步骤 6 令 $k=k+1$,返回步骤 4,直到满足迭代终止条件.

1.2 LSTM 网络

LSTM 是递归神经网络的一种优化变体,可以通过内存模块更好地存储和访问历史数据,从而有效避免“梯度消失”和“梯度爆炸”问题,在长时间序列建模和预测方面具有很强的优势^[19].LSTM 网络结构由输入层、隐藏层和输出层组成.隐藏层由内存块组成,每个存储块由 3 个门结构组成,包括遗忘门、输入门和输出门,如图 1 所示.

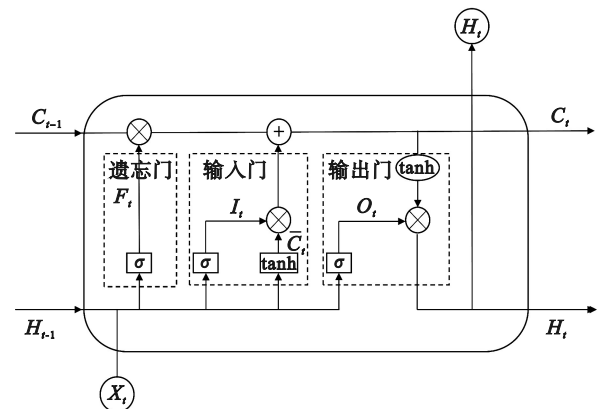


图 1 长短时记忆网络结构图

Fig. 1 Structure diagram of the long short-term memory network

其中: C_{t-1} 为前一时刻记忆单元状态; C_t 为当前时刻记忆单元状态; \otimes 为向量乘法; I_t 为输入门; F_t 为遗忘门; O_t 为输出门; \tanh 为双曲正切函数; σ 为 sigmoid 激活函数, 取值范围为 $(0, 1)$; X_t 为当前时刻的序列输入; H_t 为当前时刻隐藏层状态; H_{t-1} 为前一时刻隐藏层状态.

1.3 注意力机制

注意力机制有选择地关注一些最有影响力的信息, 忽略不必要的信息, 并增强理想信息^[20]. 具体步骤为^[21]: 首先, 计算输入数据中不同部分的注意力权重, 这些权重反映了模型对这些部分的关注程度. 然后, 模型将这些部分按照权重进行加权求和, 得到 1 个加权后的表示. 最后, 这个加权后的表示被用作模型的输出或进一步处理的输入. 注意力机制的结构如图 2 所示. 其中 W_q, W_k, W_v 是对输入进行线性映射的系数矩阵, 输入序列与系数矩阵相乘分别得到 Q (query)、 K (key)、 V (value).

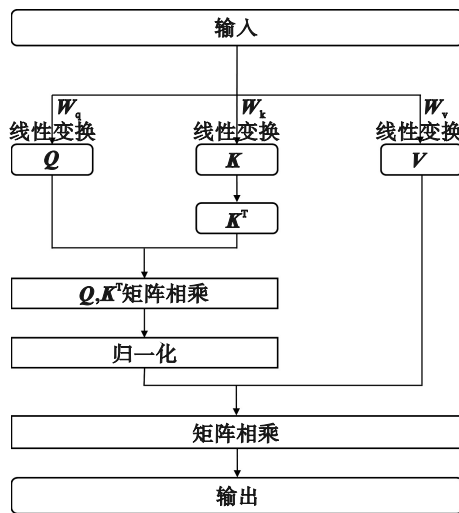


图 2 注意力机制结构图

Fig. 2 Structure diagram of the attention mechanism

1.4 评价指标

本文采用平均绝对百分比误差(MAPE)、均方根误差(RMSE)和拟合优度(R^2)对预测模型进行评价. 计算公式如式(8)~(10)所示:

$$e_{MAPE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100\%, \quad (8)$$

$$e_{RMSE} = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}}, \quad (9)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}. \quad (10)$$

其中: e_{MAPE} 为平均绝对百分比误差; e_{RMSE} 为均方根误差; y_i 为 i 时刻的真实值; \hat{y}_i 为 i 时刻的预测值; \bar{y}

为所有真实值的算术平均值; n 为样本数. e_{MAPE} 越小、 e_{RMSE} 越小、 R^2 越大, 模型的预测效果越好.

2 基于 ICEEMDAN 与 Attention-LSTM 的矿山边坡位移预测模型

2.1 Attention-LSTM 模型结构

传统的 LSTM 预测模型虽然考虑了监测数据的历史信息, 但对于长时间序列无法兼顾输入信息前后的特征, 可能造成重要信息的丢失^[22]. 因此, 本研究建立了一种融合注意力机制的 LSTM 矿山边坡位移预测模型, 对变形监测时间序列进行建模分析, 模型结构如图 3 所示. 采用注意力机制计算相关权重, 分层表示边坡时序信息, 将各隐层状态的加权和作为输出. 图中 $x_1 \sim x_i$ 为输入序列, $y_1 \sim y_i$ 为输出的中间状态.

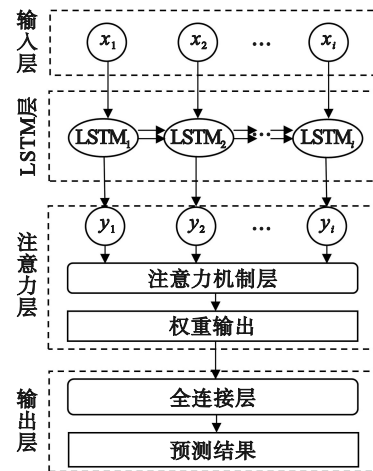


图 3 Attention-LSTM 结构图

Fig. 3 Structure diagram of Attention-LSTM

2.2 基于 ICEEMDAN 与 Attention-LSTM 的边坡位移预测流程

基于 ICEEMDAN, CPF 及 Attention-LSTM 进行边坡位移预测, 具体步骤如图 4 所示:

步骤 1 矿山边坡位移监测数据收集.

步骤 2 对原始数据进行预处理. 利用 Savitzky-Golay(S-G)滤波技术去除时序数据的高频噪声, 保证信号不失真的同时提高信号的平滑性. 然后, 将平滑处理后的数据集划分为训练集和测试集.

步骤 3 采用 ICEEMDAN 方法分解边坡累积位移为趋势项、周期项和随机项.

步骤 4 根据趋势项和周期项分解结果, 分别构建趋势位移及周期位移数据集.

步骤 5 运用 CPF 方法对趋势项位移进行预测.

步骤 6 构建 Attention-LSTM 模型对周期项位移进行预测.

步骤 7 将预测的各位移分量求和,得到累积位移预测结果.

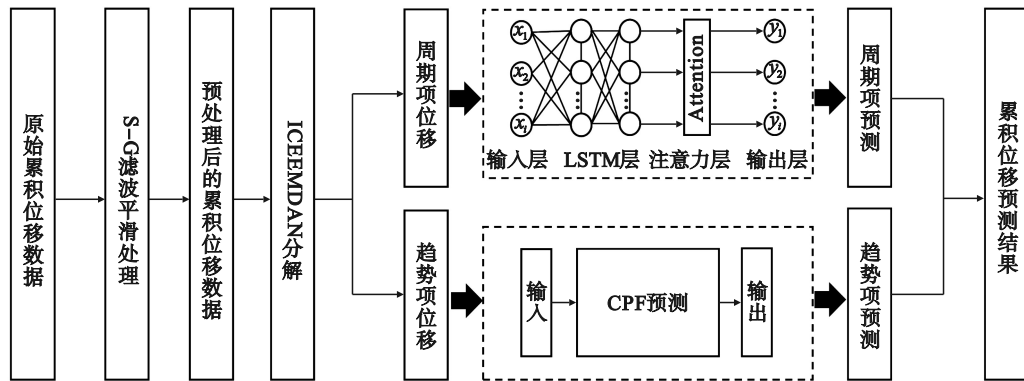


图 4 累积位移预测流程图

Fig. 4 Flowchart of cumulative displacement prediction

3 巨龙铜矿边坡位移预测

3.1 巨龙铜矿边坡概况

西藏自治区墨竹工卡县巨龙铜矿地处青藏高原冈底斯山脉东段,为极高山地带,平均海拔大于 5 200 m.岩石、矿石主要为块状构造,均为坚硬至半坚硬岩石.随着矿山的开采,形成了较多的高陡边坡,矿山北侧边坡坡高为 520 m,南侧边坡坡高为 420 m.该矿山存在的主要工程地质问题是采场边坡的形变问题.边坡位移的准确预测对矿山的安全生产和工作人员的生命安全至关重要.

为了监测及分析矿山边坡地表长时间变形特征,选用了欧洲空间局(ESA)的 Sentinel-1 合成孔径雷达(InSAR)来监测巨龙铜矿在高寒高海拔复杂条件下的边坡形变情况.获得了矿山北露天采场 2022 年 1 月至 2023 年 12 月的 InSAR 监测数据,选取该区域形变较为明显的监测点作为研究对象,其中 2022 年 1 月至 2023 年 6 月的监测数据作为训练集,2023 年 7 月至 2023 年 12 月的监测数据作为测试集.利用本文提出的方法对矿山边坡位移进行预测,并对比不同预测模型

的性能.

3.2 边坡累积位移分解

本文基于 Matlab 建立了用于边坡累积位移分解的 ICEEMDAN 模型,其噪音与信息标准差之比为 0.2,平均迭代次数为 100,最大迭代次数为 5 000,得到 4 个 IMF 分量和 1 个残余量(residual, RES).其中高频、幅值较低的部分为随机项,低频、幅值较高的部分为周期项,残余部分为趋势项.图 5 为矿山北露天采场 2022 年 1 月至 2023 年 12 月的 InSAR 累积位移监测数据,以及分解后的趋势项、周期项与随机项位移.

3.3 趋势项位移预测


CPF 方法不仅能快速建模,而且在一定程度上能很好地拟合数据的非线性特征^[23].根据趋势位移数据特点,本文采用 CPF 建立趋势项位移预测模型 $f(x)$,如式(11)所示:

$$f(x) = a_1x^3 + a_2x^2 + a_3x + a_4. \quad (11)$$

其中, a_1, a_2, a_3, a_4 为回归系数.

基于趋势项位移训练集进行曲线拟合,确定了三次多项式的系数,最终得到的拟合公式,如式(12)所示:

$$f(x) = -0.0011x^3 + 0.094x^2 - 0.01x - 0.01. \quad (12)$$






图5 监测点累积位移及累积位移分解

Fig. 5 Cumulative displacement of monitoring points and decomposition of cumulative displacement

(a)—累积位移; (b)—趋势项位移; (c)—周期项位移; (d)—随机项位移.

针对趋势项测试集,利用趋势项位移模型对矿山边坡 2023 年 6 月至 2023 年 12 月的趋势项位移进行预测,结果如图 6 所示.CPF 方法预测结果的 e_{RMSE} 和 R^2 分别为 3.37 mm 和 0.977.

3.4 周期项位移预测

采用 Python 软件构建了 LSTM 和 Attention-LSTM 预测模型,针对周期项测试集,其预测结果如图 7 所示.

LSTM 模型预测结果的 e_{RMSE} 和 R^2 分别为 5.84 mm 和 0.849; Attention-LSTM 模型预测结果的 e_{RMSE} 和 R^2 分别为 3.35 mm 和 0.945,相较于 LSTM 模型, e_{RMSE} 降低了 42.64%, R^2 提高了 11.31%.Attention-LSTM 预测模型通过计算输入信息的注意力概率分布,关注信息的重点特征,强化了对输出影响较大的参数,增强了模型预测

能力,得到了更加精准的预测结果.

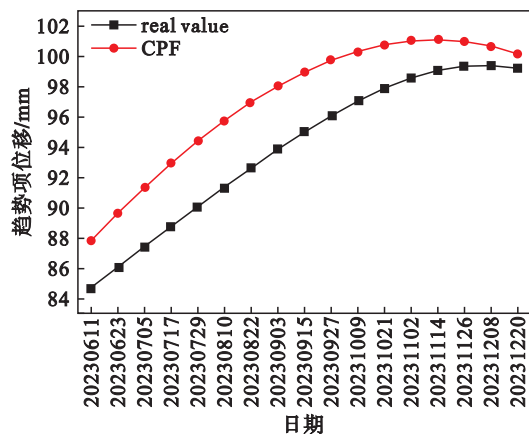


图6 趋势项位移预测

Fig. 6 Prediction of trend displacement

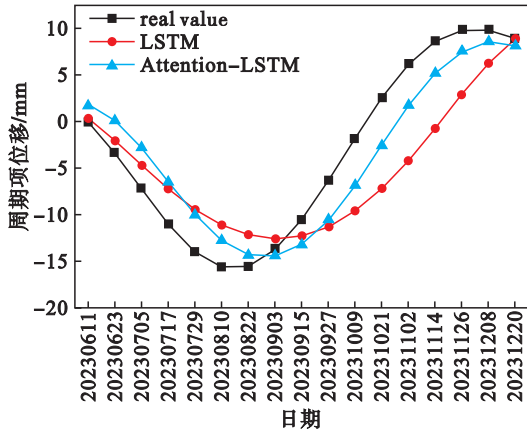


图 7 周期项位移预测

Fig. 7 Prediction of periodic displacement

3.5 边坡累积位移预测

本文将矿山边坡累积位移分解后,基于不同的预测模型对趋势项位移和周期项位移分别预测,再通过叠加获得累积位移预测值.为对比说明本文方法的优越性,本文方法与其他 2 种累积位移预测方法进行了对比:一是直接利用累积位移数据,基于 LSTM 构建预测模型,该方法不涉及累积位移的分解;二是仍采用累积位移分解方式分别预测周期项与趋势项,但在周期项预测中,采用不引入注意力机制的 LSTM 预测模型.预测结果如图 8 及表 1 所示.

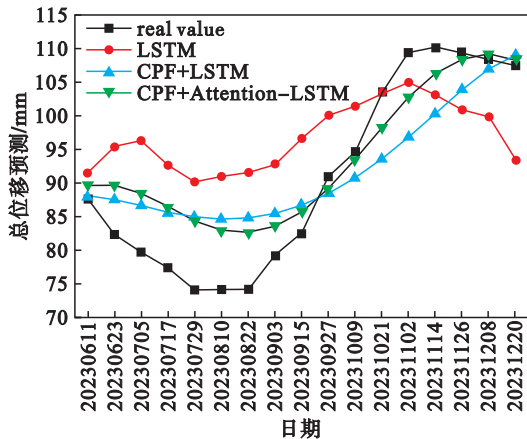


图 8 累积位移预测

Fig. 8 Prediction of cumulative displacement

本文提出的预测模型相较于第 1 种累积位移预测模型, e_{RMSE} 降低了 51.30%, e_{MAPE} 降低了 55.17%, R^2 提高了 20.50%;相较于第 2 种累积位移预测模型, e_{RMSE} 降低了 25.03%, e_{MAPE} 降低了 24.04%, R^2 提高了 6.52%.由对比结果可知:LSTM 预测模型对边坡累积位移整体预测效果较差;通过累积位移分解及融入注意力机制,矿山边坡位移预测结果更加准确.

表 1 边坡累积位移预测结果

Table 1 Prediction results of slope cumulative displacement

指标	LSTM	ICEEMDAN-CPF-LSTM	ICEEMDAN-CPF-Attention-LSTM
$e_{MAPE}/\%$	13.250	7.820	5.940
e_{RMSE}/mm	12.300	7.990	5.990
R^2	0.800	0.905	0.964

4 结 论

1) 通过ICEEMDAN可以有效地将累积位移重构为具有实际意义的趋势项、周期项和随机项位移.

2) CPF方法能有效地描述趋势项的演化特征.Attention-LSTM模型在预测周期项位移方面优于传统的LSTM模型.

3) 累积位移分解和注意力机制的引入,显著提高了矿山边坡变形预测的精度.

4) 本文选取InSAR监测数据中形变较为明显的监测点作为研究对象,未充分考虑不同监测点之间的相关性.后续研究将分析不同监测点的时空演化特征及关联,进一步提高位移的预测精度.

参考文献:

[1] 杨天鸿,王赫,董鑫,等.露天矿边坡稳定性智能评价研究现状、存在问题及对策[J].煤炭学报,2020,45(6):2277-2295.
(Yang Tian-hong, Wang He, Dong Xin, et al. Current situation, problems and countermeasures of intelligent evaluation of slope stability in open pit[J]. *Journal of China Coal Society*, 2020, 45(6):2277-2295.)

[2] 李荟,韩晓飞,朱万成,等.基于多源信息融合的矿山边坡滑坡灾害研究现状与展望[J].工矿自动化,2024,50(6):6-15.
(Li Hui, Han Xiao-fei, Zhu Wan-cheng, et al. Current status and prospects of research on landslide disasters in mine slopes based on multi-source information fusion [J]. *Journal of Mine Automation*, 2024, 50(6):6-15.)

[3] Liu K M, Li H, Pang S H, et al. Numerical simulation analysis of slope instability and failure of limestone mine in Weibei [J]. *Advances in Civil Engineering*, 2021, 2021(1): 5991348.

[4] Azarfar B, Ahmadvand S, Sattarvand J, et al. Stability analysis of rock structure in large slopes and open-pit mine: numerical and experimental fault modeling [J]. *Rock Mechanics and Rock Engineering*, 2019, 52(12): 4889-4905.

[5] Zhang K, Cao P, Meng J J, et al. Modeling the progressive failure of jointed rock slope using fracture mechanics and the strength reduction method [J]. *Rock Mechanics and Rock Engineering*, 2015, 48(2): 771-785.

[6] Jiang S, Liu H S, Lian M J, et al. Rock slope displacement

- prediction based on multi-source information fusion and SSA-DELM model [J]. *Frontiers in Environmental Science*, 2022, 10: 982069.
- [7] Dai F, Zhu W C, Ren M, et al. Landslide displacement prediction based on spatio-temporal association rule mining between target case and similar cases [J]. *Stochastic Environmental Research and Risk Assessment*, 2023, 37 (11): 4229-4247.
- [8] Hao Y K, Huang B B, Sulowicz M. A practical prediction model for surface deformation of open-pit mine slopes based on artificial intelligence [J]. *Elektronika Ir Elektrotechnika*, 2024, 30(3): 46-53.
- [9] Niu H L, Xu K L, Liu C. A decomposition-ensemble model with regrouping method and attention-based gated recurrent unit network for energy price prediction [J]. *Energy*, 2021, 231: 120941.
- [10] Yang B B, Yin K L, Lacasse S, et al. Time series analysis and long short-term memory neural network to predict landslide displacement [J]. *Landslides*, 2019, 16(4): 677-694.
- [11] Lin Z A, Sun X Y, Ji Y F. Landslide displacement prediction model using time series analysis method and modified LSTM model [J]. *Electronics*, 2022, 11 (10): 1519.
- [12] Liu Z Q, Guo D, Lacasse S, et al. Algorithms for intelligent prediction of landslide displacements [J]. *Journal of Zhejiang University: Science A*, 2020, 21(6): 412-429.
- [13] Yang J F, Ren Y Q, Chai J, et al. Adit deformation prediction based on ICEEMDAN dispersion entropy and LSTM-BP [J]. *Optical Fiber Technology*, 2023, 79: 103364.
- [14] 赵二峰,李章寅,袁冬阳.基于双阶段注意力机制的大坝变形深度学习预测模型[J].河海大学学报(自然科学版), 2023,51(6):44-52.
(Zhao Er-feng, Li Zhang-yin, Yuan Dong-yang. Deep learning model for deformation prediction of dam based on dual-stage attention mechanism [J]. *Journal of Hohai University(Natural Sciences)*, 2023,51(6):44-52.)
- [15] 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(sup2): 477-486, 507.
(Zhang Zhen-kun, Zhang Dong-mei, Li Jiang, et al. Study on LSTM-MH-SA landslide displacement prediction model based on multi-head self-attention mechanism [J]. *Rock and Soil Mechanics*, 2022, 43(sup2): 477-486, 507.)
- [16] 唐宇峰,陈星红,蔡宇,等.基于时序分解和 SSA-LSTM-Attention 模型的尾矿坝位移预测[J].科学技术与工程, 2023,23(29): 12753-12759.
(Tang Yu-feng, Chen Xing-hong, Cai Yu, et al. Tailings dam displacement prediction based on time-series decomposition and SSA-LSTM-Attention model [J]. *Science Technology and Engineering*, 2023, 23 (29) : 12753-12759.)
- [17] 曹鑫宇,朱琳,宫辉力,等.AM-LSTM 网络的北京平原东部地面沉降模拟[J].遥感学报,2022,26(7):1302-1314.
(Cao Xin-yu, Zhu Lin, Gong Hui-li, et al. Land subsidence simulation in the east of Beijing plain based on the AM-LSTM Network [J]. *National Remote Sensing Bulletin*, 2022,26(7):1302-1314.)
- [18] Li L M, Wang C Y, Wen Z Z, et al. Landslide displacement prediction based on the ICEEMDAN, ApEn and the CNN-LSTM models [J]. *Journal of Mountain Science*, 2023, 20(5): 1220-1231.
- [19] Sherstinsky A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network [J]. *Physica D: Nonlinear Phenomena*, 2020, 404: 132306.
- [20] 刘建伟,刘俊文,罗雄麟.深度学习中注意力机制研究进展 [J].工程科学学报,2021,43(11):1499-1511.
(Liu Jian-wei, Liu Jun-wen, Luo Xiong-lin. Research progress in attention mechanism in deep learning [J]. *Chinese Journal of Engineering*, 2021,43(11):1499-1511.)
- [21] Brauwers G, Frasincar F. A general survey on attention mechanisms in deep learning [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35 (4) : 3279-3298.
- [22] Fu X G, Wei Y H, Su Y, et al. Shear wave velocity prediction based on the long short-term memory network with attention mechanism [J]. *Applied Sciences*, 2024, 14 (6): 2489.
- [23] 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.
(Yang Bei-bei, Yin Kun-long, Du Juan. A model for predicting landslide displacement based on time series and long and short term memory neural network [J]. *Chinese Journal of Rock Mechanics and Engineering*, 2018, 37 (10):2334-2343.)