

DOI:10.20174/j.juse.2026.02.07

# 基于GRU神经网络的地下洞室围岩变形预测研究

万晨<sup>1,2</sup>, 王兴霞<sup>3</sup>, 段杭<sup>4</sup>, 郑龙<sup>5</sup>, 黄建文<sup>3</sup>

(1. 湖北省水电工程智能视觉监测重点实验室, 湖北 宜昌 443002; 2. 三峡大学 计算机与信息学院, 湖北 宜昌 443002; 3. 水电工程施工与管理湖北省重点实验室, 湖北 宜昌 443002; 4. 中国三峡建工(集团)有限公司, 成都 610095; 5. 中国葛洲坝集团三峡建设工程有限公司, 湖北 宜昌 443000)

**摘要:** 为了提高围岩变形预测精度, 实时掌握变形状态, 预防围岩变形破坏, 保障施工安全, 针对传统围岩变形预测方法训练效率低、收敛速度慢、泛化能力弱等问题, 提出了一种基于GRU神经网络的地下洞室围岩变形时序预测方法, 构建了相应的围岩变形预测框架流程。结合白鹤滩右岸地下厂房围岩变形监测数据进行预测, 并将其与长短期记忆(LSTM)神经网络算法预测结果进行对比分析。结果表明: GRU神经网络模型能够较好地解决地下洞室围岩变形预测问题, 具有结构简单、参数量相对较少、训练及收敛速度快、预测精度高等优势。与LSTM神经网络算法预测结果相比, 模型训练时长降幅超过70%, 预测误差降低幅度高达50%以上, 累计最大变形的相对误差小于0.3%, 绝对误差小于0.9 mm的概率高达95%, 最大绝对误差仅为2.05 mm。

**关键词:** 地下洞室; 围岩; 变形预测; GRU神经网络

中图分类号: TV52

文献标识码: A

文章编号: 1673-0836(2026)02-0448-11

## Study on the Prediction of Underground Cavern Rock Deformation Based on GRU Neural Network

Wan Chen<sup>1,2</sup>, Wang Xingxia<sup>3</sup>, Duan Hang<sup>4</sup>, Zheng Long<sup>5</sup>, Huang Jianwen<sup>3</sup>

(1. Hubei Key Laboratory of Intelligent Vision Based Monitoring for Hydroelectric Engineering, Yichang, Hubei 443002, P. R. China; 2. College of Computer and Information Technology, China Three Gorges University, Yichang, Hubei 443002, P. R. China; 3. Hubei Key Laboratory of Construction and Management in Hydropower Engineering, Yichang, Hubei 443002, P. R. China; 4. China Three Gorges Construction Engineering Corporation, Chengdu 610095, P. R. China; 5. China Gezhouba Group Three Gorges Construction Engineering Co., Ltd., Yichang, Hubei 443000, P. R. China)

**Abstract:** In order to enhance the prediction accuracy of surrounding rock deformation, enable real-time monitoring of deformation status, prevent deformation failure, and ensure construction safety, a novel underground cavern surrounding rock deformation temporal prediction method based on GRU neural network is proposed to tackle the low training efficiency, slow convergence, and poor generalization of traditional methods, along with the establishment of a corresponding prediction framework. Utilizing monitoring data of surrounding rock deformation from the underground powerhouse on the right bank of the Baihetan Dam, predictions are made and subsequently compared and analyzed with the forecasting results generated by the Long Short-Term Memory (LSTM) neural network algorithm. The results indicate that the GRU neural network model effectively addresses the prediction challenges associated with underground cavern surrounding rock deformation, offering advantages such as

收稿日期: 2025-01-18(修改稿)

作者简介: 万晨(2000—), 男, 武汉人, 硕士生, 主要从事神经网络技术及应用方面的研究。

E-mail: ettalwanc@gmail.com

通讯作者: 王兴霞(1980—), 女, 湖北十堰人, 博士, 副教授、硕士生导师, 主要从事水电工程施工技术方面的研究。

E-mail: xxwang@ctgu.edu.cn

基金项目: 国家自然科学基金(52009069, 51879147)

simplified structure, relatively fewer parameters, rapid training and convergence rates, and high prediction accuracy. Compared to the predictions derived from the LSTM neural network algorithm, the GRU model demonstrates a reduction in training duration by over 70%, with a corresponding decrease in prediction error of more than 50%. The relative error for cumulative maximum deformation is less than 0.3%, the probability of absolute error less than 0.9 mm is as high as 95%, and the maximum absolute error is only 2.05 mm.

**Keywords:** underground cavern; surrounding rock; deformation prediction; GRU neural network

## 0 引言

我国拥有丰富的水资源,位列全球之首,然而这些资源在时空分布上极不均匀,主要集中在西部云贵川藏等地区。由于西部地区典型的地形、地质、环境和水力条件,在大多数情况下水电工程枢纽布置的最优选择为地下洞室。当前,水电工程地下洞室具有显著的“大跨度、高边墙、大埋深、高地应力”特点,变形稳定问题尤为突出,施工中容易发生岩体脱、剥离弹射等变形破坏现象,从而影响施工安全<sup>[1-2]</sup>。因此,合理利用现场监测得到的变形数据,建立合适的预测模型,对地下洞室开挖变形进行实时预测预警,并有效控制围岩变形破坏的产生,是施工安全的重要保证。

近年来,国内外许多学者对地下洞室围岩变形预测展开了研究,提出许多有价值的预测方法,如统计模型法<sup>[3-4]</sup>、数值模拟法<sup>[5-7]</sup>、机器学习智能算法<sup>[8-15]</sup>等,为围岩变形预测提供了解决方案。然而,不同的预测方法各有其独特的优势,适用性条件不尽相同,预测精度也有一定的差异。随着计算机技术和人工智能的飞速发展,机器学习智能算法得到广泛应用,展现出了较强的优势,目前常用的机器学习智能算法主要有遗传算法<sup>[8]</sup>、粒子群算法<sup>[9-10]</sup>、支持向量机<sup>[10-11]</sup>、神经网络<sup>[12-16]</sup>等。在众多的机器学习智能算法中,神经网络具有较强的推理泛化能力、非线性映射能力和自组织自学习能力,而门控循环单元(Gate Recurrent Unit, GRU)神经网络与传统的反向传播(Back Propagation, BP)神经网络、循环神经网络(Recurrent Neural Network, RNN)和长短期记忆(Long Short-Term Memory, LSTM)神经网络相比具有模型结构简单、参数量相对较少、训练及收敛速度快、预测精度高等优势,目前在水利<sup>[17-18]</sup>、电力<sup>[19-20]</sup>、能源<sup>[21]</sup>、智慧交通<sup>[22-24]</sup>、环境<sup>[25]</sup>等领域中得到广泛应用,并取得较好的预测效果。徐冬梅等<sup>[18]</sup>提出采用变分模态分解(VMD)将月径流序列分解为一系列相对平稳的子序列,然后利用GRU分别预测各子序列,叠加得到最终的点预测结果;姚程文

等<sup>[19]</sup>采用K-means聚类方法对地区内的样本数据集进行分组后,再运用CNN网络提取特征与负荷在高维空间的联系,构造时序序列的高维特征向量,并将结果输入到GRU网络中,并输出负荷预测值;辛付宇等<sup>[21]</sup>利用GRU长时间记忆能力与CNN避免了对数据的复杂前期预处理,模型拥有更高的计算精度,以及更稳定的预测结果;寇敏等<sup>[22]</sup>引入鲸鱼优化算法对GRU模型的各类超参数进行寻优,提升模型预测性能,进而提高高速公路交通流预测精度;黎煜昭等<sup>[25]</sup>将水质因子变化的物理规律作为一种先验知识约束,建模于门控循环单元神经网络GRU之中,提供了一种在神经网络模型中融入水质先验知识的研究思路,有助于提升水质预测模型辅助决策的水平。

上述研究有效地拓展了GRU在时序预测的应用范围,并取得了显著的效果。鉴于此,本文基于长时期严格监测的地下洞室围岩变形数据,引入神经网络架构,构建GRU地下洞室围岩变形时序预测模型。通过对实测数据特征的学习,模型获得数据预测能力,能根据围岩变形趋势准确长期预测围岩变形的收敛值。结合多种方法对不同检测点位实测数据进行预测,通过结果的对比较验证了模型预测精度,为地下洞室围岩变形预测提供一种有效途径。

## 1 基于GRU神经网络的围岩变形预测模型

### 1.1 GRU神经网络基本原理

门控循环单元(GRU)神经网络是循环神经网络(RNN)的一种特殊变体,也是长短期记忆(LSTM)神经网络的改进优化模型,是解决非线性可变时序预测问题的一个常用选择,在处理长时间序列预测问题时能发挥独特的优势<sup>[20]</sup>。传统RNN模型在训练时采用反向传播,适合对非线性时间序列进行有效处理,但是存在梯度消失、梯度爆炸及长期记忆不足问题。LSTM神经网络在RNN的基础上增加了记忆和遗忘功能,具有长期学习能力,但是内部结构比较复杂,训练效率较低,收敛速度较慢甚至存在不收敛等问题。而GRU神

神经网络通过巧妙的设计,使记忆单元动态控制网络计算过程,不仅避免了常见于 RNN 的梯度消失、爆炸及长期记忆不足问题,而且解决了 LSTM 神经网络存在的结构复杂、训练效率低、收敛速度慢的问题,同时还简化了模型参数,具备过滤无用信息和抗噪功能,可以在样本量不大的情况下完成高准确率预测。GRU 神经网络结构如图 1 所示,模型训练计算过程如式(1)所示。




图 1 GRU 神经网络结构图

Fig. 1 Structure diagram of GRU neural network

$$\begin{cases} z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \\ r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \\ \tilde{h}_t = \tanh(W \cdot [r_t \times h_{t-1}, x_t]) \\ h_t = (1 - z_t) \times h_{t-1} + z_t \times \tilde{h}_t \\ y_t = \sigma(W_o \times h_t + b_y) \end{cases} \quad (1)$$

图 1 与式(1)中,  $x_t$ 、 $h_{t-1}$ 、 $h_t$ 、 $y_t$  分别表示当前时刻的输入、前一个时刻输出的状态记忆变量、当前时刻的状态记忆变量、当前时刻的输出。 $z_t$ 、 $r_t$  表示重置门和更新门的状态。 $W$ 、 $b$  分别表示  $x_t$ 、 $h_{t-1}$ 、 $h_t$ 、 $y_t$ 、 $z_t$ 、 $r_t$  计算时,与  $h_{t-1}$  和  $x_t$  构成的连接向量相乘相加的权重和偏置,在网络训练的过程中不断优化,直到得到最佳值;  $[\ ]$  表示矩阵连接,“ $\cdot$ ”表示矩阵点乘;“ $\times$ ”表示矩阵乘积;  $\sigma(x)$ 、 $\tanh(x)$  分别表示 sigmoid 和 tanh 激活函数,  $\sigma(x)$  最终输出值在  $[0, 1]$  范围内,  $\tanh(x)$  的输出值范围在  $[-1, 1]$ , 数学表达式为:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3)$$

## 1.2 围岩变形预测流程

地下洞室围岩变形具有很强的不确定性和高度的非线性,结合 GRU 算法在解决非线性时序预测问题上的优势,以现场实际监测数据为基础,构建围岩变形预测流程如图 2 所示。

步骤 1: 数据处理。采集实测围岩变形数据,依据采集时间将数据处理为等时间间隔数据,剔除异

常数据并封装得到数据集;同时,为保证计算速度及损失函数的收敛性,需要对数据进行归一化和反归一化处理,处理公式为:

$$x_{\text{std}} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (4)$$

$$x_{\text{scaled}} = x_{\text{std}} \times (x_{\max} - x_{\min}) + x_{\min} \quad (5)$$

式中:  $x_{\text{std}}$ 、 $x_{\text{scaled}}$  分别为数据归一化和反归一化后的结果;  $x$  为原始数据;  $x_{\min}$ 、 $x_{\max}$  为数据集中数据的最小值和最大值。

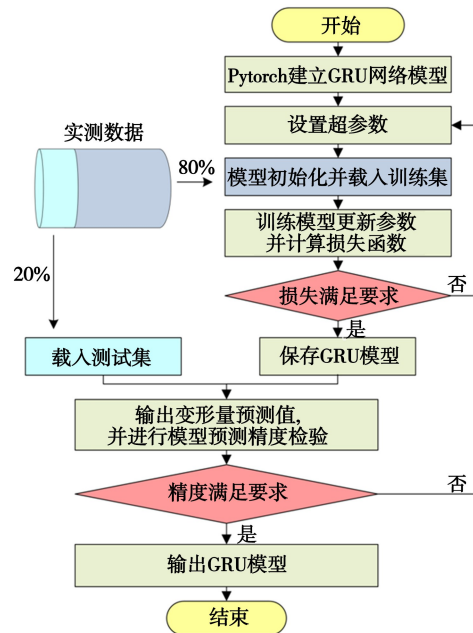


图 2 GRU 变形预测流程图

Fig. 2 GRU deformation prediction flow chart

步骤 2: 模型搭建。充分分析地下洞室围岩变形趋势及特征,以 Pytorch 代码库封装的 GRU 网络结构为基本框架,建立基于 GRU 神经网络的地下洞室围岩变形预测模型。将时间序列为  $n$  的封装数据  $\{x_i(t), i=1, 2, \dots, n\}$  输入模型,输入层通过滑动窗口将输入数据重构为维度为  $s$  的数据组  $\{X_i(t) = x_i(t), x_i(t+1), \dots, x_i(t+s), i=1, 2, \dots, n\}$ ,网络对于输入的每一个变形量数据组预测下一个时刻的围岩变形量,模型预测输出表示为  $\{Y_i(t) = F[X_i(t)], i=1, 2, \dots, n\}$ ,其中  $F(\cdot)$  表示 GRU 隐藏层计算过程。最终设置损失函数对模型参数的训练进行监督与优化。

步骤 3: 初始化网络结构,设置超参数。训练开始首先手动设置 GRU 网络的超参数,运用 Adam 优化器对学习率进行自适应调节,这种动态调整使模型训练效果达到最佳,加快收敛并取得更好的优化性能,具体超参数设置如表 1 所示。

步骤 4: 数据集划分。为训练网络得到最优参

数的模型,并评估训练得到的模型在预测任务中的精准度,本文分别设置了训练集和测试集来对模型进行训练和测试评估。为保证数据特征的多样性,将数据按时序排列并按每 5 个数据划分为一组,在每组数据中随机抽取 4 个数据划入训练集,每组剩余的 1 个数据划入测试集,最终训练集占实测数据集的 80%,测试集占 20%。

表 1 超参数

Table 1 Hyper parameters	
超参数	值
初始学习率	0.001
Epoch	150
隐藏层	128
优化器	Adam
损失函数	MSE loss
GRU 输入维度	3
GRU 输出维度	1

步骤 5:网络训练。将划分完成的训练集载入到围岩变形预测模型中训练,网络学习输入数据的特征,并不断优化模型参数并输出预测值,GRU 预测方法的网络训练模型如图 3 所示。对于输出的预测数据,本文使用均方误差损失函数 (Mean Square Error, MSE) 来对模型进行监督并优化参数,最终保存损失最低的模型参数,损失函数公式为:

$$L_{MSE} = (y_t - \hat{y}_t)^2 \quad (6)$$

式中: $y_t$  为  $t$  时刻实测变形值; $\hat{y}_t$  为  $t$  时刻的预测变形值。

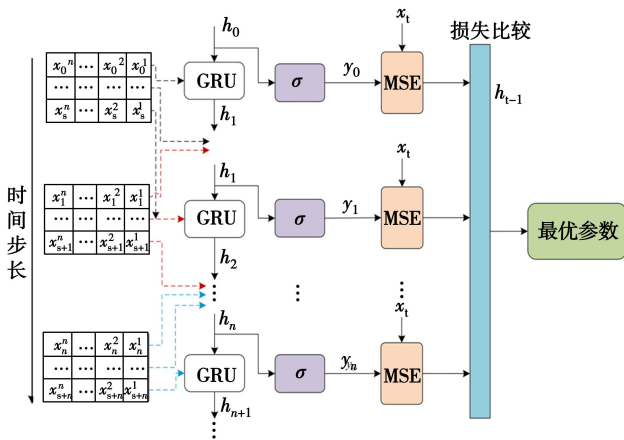


图 3 GRU 预测方法的网络训练模型图

Fig. 3 Diagram of GRU prediction method network training model

步骤 6:变形预测及误差分析。网络训练完成

后得到最优参数模型,而这个模型并不一定能胜任预测任务,需要载入测试集数据进行预测并进行误差分析。选取能突出体现预测值与实测值间离散程度的平均绝对误差 (Mean Absolute Error, MAE) 和均方根误差 (Root Mean Square Error, RMSE),以及能表现预测值与实测值间相对误差的对称平均绝对百分比误差 (Symmetric Mean Absolute Percentage Error, SMAPE) 作为模型预测精度的评价指标,误差指标公式分别为:

$$e_{MAE} = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (7)$$

$$e_{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n [y_t - \hat{y}_t]^2} \quad (8)$$

$$e_{SMAPE} = \frac{1}{n} \sum_{t=1}^n \frac{2|y_t - \hat{y}_t|}{|y_t| + |\hat{y}_t|} \times 100\% \quad (9)$$

式中: $n$  为测试集样本总数; $y_t$  为  $t$  时刻实测变形值; $\hat{y}_t$  为  $t$  时刻的预测变形值。

## 2 工程实例分析

### 2.1 工程概况

白鹤滩水电站右岸地下厂房位于坝肩上游山体内部,地下厂房洞室水平埋深 480~800 m,垂直埋深 420~540 m,地下厂房洞尺寸为 438.00 m×34.00 m×88.70 m (长×宽×高),围岩主要为 P2β33 层~P2β51 层隐晶质玄武岩、斜斑玄武岩、杏仁状玄武岩、角砾熔岩等,层内错动带主要发育于 P2β61 层,位于厂房上游外侧。厂房部位随机裂隙以 NW 向陡倾角裂隙为主,裂隙长度一般 2~5 m,间距大于 50 cm,裂隙面以闭合平直粗糙为主。洞室围岩的变形与施工阶段的进行关系较大,随着洞室开挖,围岩变形量呈跳跃式增长,直到支护完成之后围岩变形量逐渐收敛<sup>[26]</sup>。为了实时掌控洞室围岩变形状况,建设单位分别在右岸厂房 0+227、0+266、0+281、0+331 等断面的围岩体内共布置了 29 个测孔、130 套多点变位计进行监测,记录了围岩内部距临空面不同埋深的围岩变形量,其中右岸地下厂房 0+227 断面的多点变位计布置图如图 4 所示。

### 2.2 实测成果统计及数据处理

右岸地下厂房 0+227 断面一共布置有 13 个测孔 52 个测点,选取岩台梁、顶拱、边墙 3 个典型部位测孔 Myc0+227-6、Myc0+228-2、Myc0+227-9 进行分析,其中 Myc0+227-6 和 Myc0+228-2 测孔选取距临空面 1.5 m 的测点,Myc0+227-9 测孔选取距临空面 1.5 m、3.5 m、6.5 m、15 m 测点,共 6 个测

点 2 473 组数据。

首先对数据进行预处理,以保证数据的平稳并且等时距。一方面,遵循施工工序,在监测过程中会出现开挖、爆破等情况,从而对监测断面产生不可避免的扰动,为确保施工安全和数据可靠,现场会对监测点位进行复测;因此,监测数据序列中呈现出同一天存在 2 个监测数据的现象,即为复测数据;对于复测数据,对照现场施工实际情况选择将复测前的一组数据进行删除,并备注复测原因,避

免复测数据干扰整个监测数据序列的平稳性。另一方面,由于前后期变形监测数据获取的频率不同(前期每 3 d 获取 1 次数据,后期每 6 d 获取 1 次数据),会导致数据序列前后时期距不等。为了保证数据全序列等时距,本文采用三次样条插值(Cubic Spline Interpolation)的方法进行插值<sup>[27]</sup>,并在 Python 中使用 statsmodels 包的 adfuller 方法对数据的平稳性进行 ADF (Augmented Dickey Fuller) 检验,检验结果如表 2 所示。

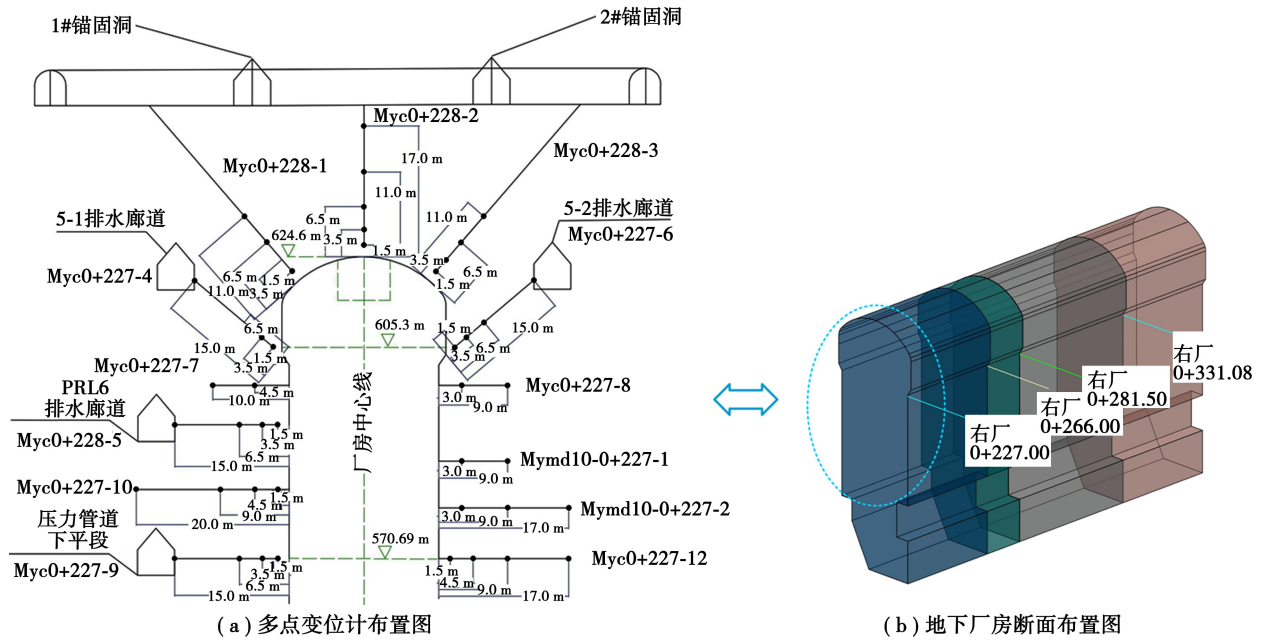


图 4 右岸地下厂房 0+227 断面多点变位计布置图

Fig. 4 Multi-point displacement meter layout diagram about 0+227 cross-section of underground powerhouse on right bank

表 2 ADF 检验结果  
Table 2 Results of ADF test

类型	检验值( <i>t</i> 值)	接受原假设的概率( <i>p</i> 值)
ADF 检验统计量	-3.901 063	0.002 027
评价 指标		
1%显著水平	-3.443 062	-
5%显著水平	-2.867 147	-
10%显著水平	-2.569 756	-

表中整个时间序列的 ADF 检验统计量小于评价标准值(3 种不同显著水平所对应的检验值),而且  $p < 0.05$ ,由此可以判断围岩变形监测数据序列是平稳序列,通过平稳性检验。

### 2.3 预测模型超参数优化

影响 GRU 模型预测准确率的主要超参数有训练周期、神经网络隐藏层数和学习率等,超参数的选取直接影响 GRU 模型的收敛速度和收敛效果,

因此,需要通过不断调节超参数来提高模型预测的准确率,从而优化模型超参数。本文在选择不同超参数的情况下训练预测模型,并比较训练完成后模型预测的准确率,最终结果比较如表 3 和图 5 所示。

表 3 不同超参数下的平均准确率  
Table 3 The average accuracy of different hyperparameters

超参数	超参数	平均准确率/%
训练周期	100 轮	97.65
	150 轮	98.93
	200 轮	98.83
隐藏层数	64	97.99
	128	98.77
	256	85.03
学习率	0.000 1	92.20
	0.001	98.83
	0.01	98.00




图5 GRU模型不同超参数下的预测准确率

Fig. 5 Accuracy of the GRU model under different training epochs

训练结果显示:训练周期分别为100、150、200轮时,平均准确率为97.65%、98.93%和98.83%,模型预测准确率较高,但是训练周期为100轮时,模型的损失函数并没有完全收敛,而训练周期达到200轮时,模型训练出现过拟合,准确率反而下降,所以选择最佳训练周期为150轮。隐藏层数为64层时模型准确率为97.99%,隐藏层数增加到128层时,准确率提升到98.77%,然而隐藏层增加到256层时,准确率急剧下降至85.03%,表明隐藏层数过多会导致数据特征被过度抽象化,反而使得模型变得不敏锐,最优隐藏层数为128层。学习率为0.0001时,模型的损失函数逼近最小值的速度明显较慢,模型准确率仅为92.20%;当学习率提升为0.001时,模型损失函数能以一个合适的速度收敛到最小值,并且准确率高达98.83%;然而,学习率进一步提高到0.01时,模型训练虽然可以快速收敛,但是后续准确率并不稳定,导致平均准确率下降到98.00%,因此选择最佳学习率为0.001。

在选择最佳的超参数后,我们探究了样本数对最优超参数预测结果的影响。如表4所示,当样本数降低时,预测结果的相对误差升高。总样本数达到100个以上,模型能实现较高的预测精度。

表4 样本数对优化结果的影响

Table 4 The impact of sample size on optimization results

样本数	50	80	100	150	300
SMAPE/%	4.37	1.69	1.42	1.29	1.09

## 2.4 围岩变形预测及结果分析

对处理后的数据进行封装并划分为训练集与测试集,将训练集分别载入LSTM和GRU神经网络预测模型中训练并优化模型参数,最后将测试集输入模型进行预测,输出预测数据和预测图如表

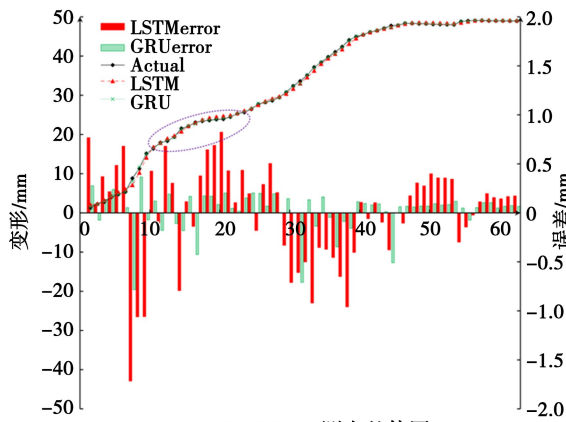
5、图6所示,统计各测点误差和累计最大变形并绘制误差对比图如表6、表7、图7所示。由图6可以直观地看到,整体图(a)中GRU预测模型的预测误差明显低于LSTM预测模型,局部图(b)中GRU预测曲线明显更贴近实测数据曲线,说明GRU预测模型具有较高的精度,然而图(c)中GRU模型的预测精度总体上优于LSTM,而在序号60后的局部上略低,原因是实测变形数据已经趋于收敛,但两者预测的绝对误差相差不超过0.25%。通过表6可以看出,与LSTM预测模型相比,GRU预测模型的误差指标(MAE、RMSE、SMAPE)大幅降低,降低幅度超过50%,并且在Myc0+227-6/1.5m测点围岩变形量变化较为剧烈时,本文模型在预测时仍然可以表现出较强的抗干扰能力,绝对误差控制在0.9mm以内的预测结果高达95%以上,最大绝对误差仅为2.05mm,远低于LSTM模型的最大绝对误差4.67mm,进一步说明GRU预测模型的预测精度较高;同时,GRU预测模型的训练时长也得到大幅降低(降幅均超过70%),证明GRU预测模型训练效率较高、收敛速度快,有更强的实际应用意义;另外,由图7可以更直观地发现,GRU预测模型的误差指标远低于LSTM预测,进一步验证了GRU预测模型精度较高。表7显示,LSTM、GRU两个模型预测的累计最大变形的相对误差都在1%以内,而GRU预测模型则控制在0.3%以内,再次验证了GRU预测模型具有较高的预测精度。从工程角度分析,以测点位置为基准,同一埋深(距临空面1.5m)条件下,岩台梁部位的累积最大变形最大,边墙部位其次,顶拱部位最小,同一测孔不同埋深(边墙部位距临空面1.5m、3.5m、6.5m、15m)条件下,距离临空面越近,累积最大变形越大,反之越小。

表 5 部分测点变形预测数据对比  
Table 5 Comparison of deformation prediction data for some measuring points

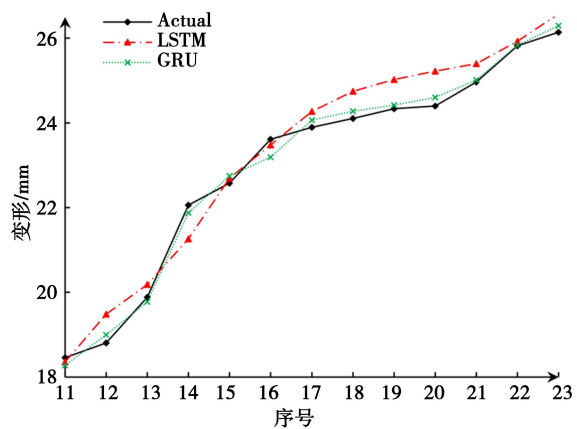
Myc0+227-6/1.5 m 测点(岩台梁)						Myc0+228-2/1.5 m 测点(顶拱)					
序号	实测变形/mm	LSTM 预测		GRU 预测		序号	实测变形/mm	LSTM 预测		GRU 预测	
		变形/mm	绝对误差/mm	变形/mm	绝对误差/mm			变形/mm	绝对误差/mm	变形/mm	绝对误差/mm
1	3.01	6.84	3.83	4.93	1.92	1	0.16	1.64	1.48	0.39	0.23
2	11.73	9.43	2.30	12.85	1.12	2	0.37	1.71	1.34	0.58	0.21
3	13.07	14.02	0.95	14.06	0.99	3	1.88	2.06	0.18	1.94	0.06
4	17.17	16.52	0.65	15.12	2.05	4	2.31	2.99	0.68	2.48	0.17
5	21.60	21.11	0.49	22.35	0.75	5	5.96	4.28	1.68	5.79	0.17
6	22.68	26.01	3.33	23.18	0.50	6	8.99	6.64	2.35	8.43	0.56
7	27.25	29.34	2.09	26.74	0.51	7	10.59	9.45	1.14	10.56	0.03
8	29.62	34.10	4.48	30.19	0.57	8	11.88	11.50	0.38	11.75	0.13
9	61.56	59.87	1.69	61.48	0.08	9	12.60	12.89	0.29	12.66	0.06
10	61.76	62.79	1.04	61.62	0.14	10	13.14	13.78	0.64	13.13	0.01
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
91	88.59	88.73	0.14	88.42	0.17	92	42.16	42.22	0.06	42.21	0.05
92	88.57	88.72	0.15	88.39	0.18	93	42.19	42.28	0.09	42.18	0.01
93	88.50	88.69	0.19	88.32	0.18	94	42.03	42.26	0.23	42.06	0.03
94	88.45	88.61	0.16	88.18	0.27	95	42.05	42.21	0.16	42.06	0.01
95	88.45	88.56	0.11	88.26	0.19	96	42.05	42.19	0.14	42.07	0.02
96	88.51	88.55	0.04	88.26	0.25	97	42.01	42.17	0.16	42.00	0.01
97	88.57	88.61	0.04	88.37	0.20	98	41.97	42.16	0.19	42.05	0.08
98	88.63	88.67	0.04	88.44	0.19	99	42.01	42.14	0.13	42.01	0.00
99	88.62	88.71	0.09	88.49	0.13	100	42.02	42.14	0.12	42.02	0.00
100	88.63	88.73	0.10	88.55	0.08	101	42.06	42.15	0.09	42.06	0.00
Myc0+227-9/1.5 m 测点(边墙)						Myc0+227-9/3.5 m 测点(边墙)					
序号	实测变形/mm	LSTM 预测		GRU 预测		序号	实测变形/mm	LSTM 预测		GRU 预测	
		变形/mm	绝对误差/mm	变形/mm	绝对误差/mm			变形/mm	绝对误差/mm	变形/mm	绝对误差/mm
1	0.85	1.57	0.72	1.23	0.38	1	1.28	2.04	0.76	1.56	0.28
2	1.88	2.02	0.14	1.93	0.05	2	2.29	2.38	0.09	2.22	0.07
3	2.49	2.95	0.46	2.71	0.22	3	2.81	3.17	0.36	2.94	0.13
4	4.07	4.28	0.21	4.30	0.23	4	4.03	4.25	0.22	4.27	0.24
5	4.97	5.62	0.65	5.14	0.17	5	4.74	5.22	0.48	4.74	0.00
6	5.57	6.69	1.12	5.83	0.26	6	5.35	6.03	0.68	5.40	0.05
7	10.58	8.41	2.17	9.93	0.65	7	8.83	7.12	1.71	8.05	0.78
8	15.17	12.36	2.81	12.62	2.55	8	11.33	10.27	1.06	11.70	0.37

续表 5


Myc0+227-9/1.5 m 测点(边墙)						Myc0+227-9/3.5 m 测点(边墙)					
序号	实测变形/mm	LSTM 预测		GRU 预测		序号	实测变形/mm	LSTM 预测		GRU 预测	
		变形/mm	绝对误差/mm	变形/mm	绝对误差/mm			变形/mm	绝对误差/mm	变形/mm	绝对误差/mm
9	18.84	17.38	1.46	18.57	0.27	9	15.15	14.10	1.05	15.08	0.07
10	19.85	20.53	0.68	19.95	0.10	10	16.37	16.79	0.42	16.49	0.12
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
47	50.79	51.31	0.52	51.04	0.25	53	47.98	48.33	0.35	48.10	0.12
48	50.70	51.29	0.59	50.87	0.17	54	48.82	48.52	0.30	48.87	0.05
49	50.66	51.22	0.56	50.80	0.14	55	49.00	48.85	0.15	48.92	0.08
50	50.66	51.17	0.51	50.80	0.14	56	49.08	49.06	0.02	49.13	0.05
51	50.62	51.14	0.52	50.76	0.14	57	49.06	49.18	0.12	49.17	0.11
52	50.60	51.11	0.51	50.74	0.14	58	48.99	49.19	0.20	49.10	0.11
53	50.66	51.10	0.44	50.78	0.12	59	48.99	49.14	0.15	49.04	0.05
54	52.19	51.53	0.66	52.31	0.12	60	48.98	49.13	0.15	49.05	0.07
55	52.19	52.22	0.03	52.33	0.14	61	48.95	49.12	0.17	49.03	0.08
56	52.20	52.52	0.32	52.32	0.12	62	48.93	49.10	0.17	49.00	0.07




(a) Myc0-227-9/3.5 m测点整体图




(b) Myc0-227-9/3.5 m测点局部图



(c) Myc0+227-6/1.5 m测点整体图



(d) Myc0+228-2/1.5 m测点整体图



(e) Myc0+227-9/1.5 m测点整体图

图 6 实测值与预测结果对比图 (Myc0-227-9/3.5 m 测点)

Fig. 6 Comparison chart between actual measured data and predicted results (Myc0-227-9/3.5 m)

表 6 预测误差统计分析  
Table 6 Statistical analysis of prediction errors

误差类型	(A)Myc0+227-6/ (岩台梁)1.5 m 测点			(B)Myc0+228-2/ (顶拱)1.5 m 测点		
	LSTM	GRU	降幅/%	LSTM	GRU	降幅/%
最大绝对误差/mm	4.67	2.05	56.10	2.35	0.63	73.19
$e_{MAE}/mm$	0.79	0.27	65.82	0.39	0.08	79.49
$e_{RMSE}/mm$	1.23	0.43	65.04	0.58	0.12	79.31
$e_{SMAPE}/%$	2.60	1.10	57.69	5.08	1.66	67.32
训练时长/s	24.30	4.20	82.72	25.80	5.54	78.53

误差类型	Myc0+227-9/(边墙)											
	(C)1.5 m 测点			(D)3.5 m 测点			(E)6.5 m 测点			(F)15 m 测点		
	实测	LSTM	GRU/%	实测	LSTM	GRU/%	实测	LSTM	GRU/%	实测	LSTM	GRU/%
最大绝对误差/mm	2.92	0.86	70.55	1.72	0.78	54.65	2.30	0.58	75.01	2.13	0.45	78.88
$e_{MAE}/mm$	0.57	0.06	89.47	0.40	0.15	62.50	0.38	0.12	68.97	0.35	0.09	74.20
$e_{RMSE}/mm$	0.76	0.12	84.21	0.51	0.21	58.82	0.56	0.16	71.43	0.54	0.12	77.78
$e_{SMAPE}/%$	4.68	0.85	81.84	3.78	1.14	69.84	4.95	1.13	77.17	6.40	1.90	70.31
训练时长/s	19.40	4.70	75.77	19.50	5.70	70.77	19.50	5.10	73.85	18.60	4.40	76.34

表 7 累积最大变形统计分析  
Table 7 Statistical analysis of accumulated maximum deformation

误差类型	(A)Myc0+227-6/ (岩台梁)1.5 m 测点			(B)Myc0+228-2/ (顶拱)1.5 m 测点		
	实测	LSTM	GRU	实测	LSTM	GRU
累积最大变形/mm	88.63	88.73	88.55	42.06	42.15	42.06
相对误差/%		0.11	-0.10		0.21	0.00

误差类型	Myc0+227-9/(边墙)											
	(C)1.5 m 测点			(D)3.5 m 测点			(E)6.5 m 测点			(F)15 m 测点		
	实测	LSTM	GRU	实测	LSTM	GRU	实测	LSTM	GRU	实测	LSTM	GRU
累积最大变形/mm	52.20	52.52	52.32	48.93	49.10	49.00	38.06	38.25	38.13	31.13	31.24	31.17
相对误差/%		0.61	0.23		0.35	0.14		0.50	0.18		0.35	0.13

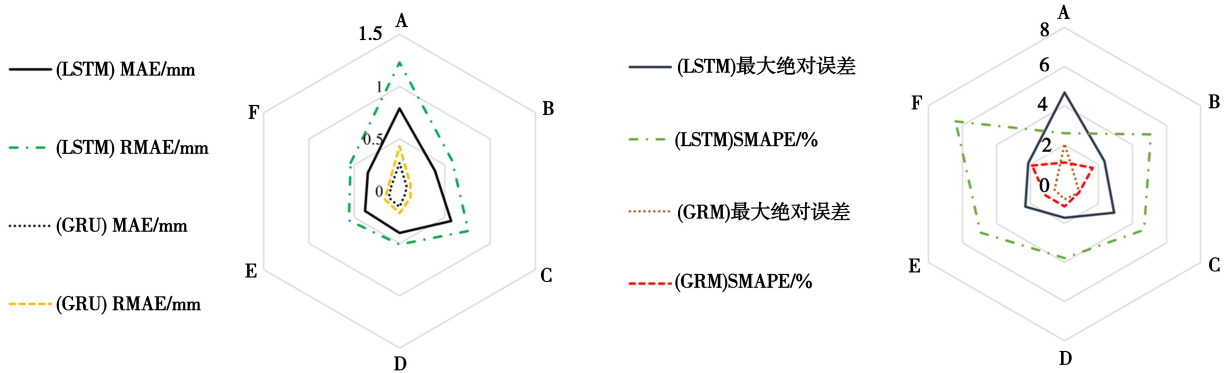


图 7 各测点预测结果误差对比图

Fig. 7 Error comparison chart of prediction results at each point

### 3 结论

(1) 针对围岩变形的不确定性和高度非线性特征,构建了基于GRU的围岩变形预测模型和预测流程框架,主要通过数据预处理、预测模型搭建、超参数优化、预测结果重构和误差分析5个关键步骤实现对围岩变形的精准预测,该模型结构简单,能快速利用实测数据对模型参数进行训练和优化。

(2) 以白鹤滩水电站右岸地下厂房0+227断面共6个测点为例对本文提出的方法进行案例验证,通过优化模型超参数并经过学习和训练以确定最优预测模型,应用结果表明,本文提出的GRU神经网络预测模型能够快速完成对现场实测变形数据特征的学习,训练收敛速度快,预测精度高,95%以上的绝对误差可控制在0.9 mm以内,最大绝对误差仅为2.05 mm。

(3) 将本文提出方法进一步与LSTM神经网络基准算法预测结果相比较,结果表明,本文预测模型的训练时长相比基准方法降幅超过70%,各预测误差指标降幅均超过50%,累计最大变形的相对误差小于0.3%,本文模型训练效率高、收敛速度快、预测结果更精准。

#### 参考文献(References)

- [1] 裴书锋,王驭正,江权,等. 陡倾柱状节理岩体洞室松弛特征与破坏机制[J]. 地下空间与工程学报, 2024, 20(2): 597-605. (Pei Shufeng, Wang Yuzheng, Jiang Quan, et al. Relaxation characteristics and failure mechanism of steeply dipping columnar jointed rock caverns [J]. Chinese Journal of Underground Space and Engineering, 2024, 20(2): 597-605. (in Chinese))
- [2] 熊自明,卢浩,王明洋,等. 我国大型岩土工程施工安全风险研究进展[J]. 岩土力学, 2018, 39(10): 3703-3716. (Xiong Ziming, Lu Hao, Wang Mingyang, et al. Research progress on safety risk management for large scale geotechnical engineering construction in China [J]. Rock and Soil Mechanics, 2018, 39(10): 3703-3716. (in Chinese))
- [3] 王涛,孙文龙,李磊. 基于回归分析与灰色理论的围岩变形组合预测[J]. 地下空间与工程学报, 2017, 13(增1): 48-51. (Wang Tao, Sun Wenlong, Li Lei. Study on surrounding rock deformation combined forecasting method based on regression analysis and grey theory [J]. Chinese Journal of Underground Space and Engineering, 2017, 13(Supp.1): 48-51. (in Chinese))
- [4] 谢建雄,鲁铁定. 一种优化高斯过程回归的隧道围岩变形预测方法[J]. 测绘科学, 2021, 46(4): 50-56. (Xie Jianxiong, Lu Tieding. A deformation prediction method for tunnel surrounding rock based on optimizing Gaussian process regression [J]. Science of Surveying and Mapping, 2021, 46(4): 50-56. (in Chinese))
- [5] 杨林德,颜建平,王悦照,等. 围岩变形的时效特征与预测的研究[J]. 岩石力学与工程学报, 2005(2): 212-216. (Yang Linde, Yan Jianping, Wang Yuezhao, et al. Study on time-dependent properties and deformation prediction of surrounding rock [J]. Chinese Journal of Rock Mechanics and Engineering, 2005(2): 212-216. (in Chinese))
- [6] 付晓东,盛谦,张勇慧. 水电站地下洞室群分步开挖的非连续变形分析[J]. 岩土力学, 2013, 34(2): 568-574. (Fu Xiaodong, Sheng Qian, Zhang Yonghui. Stepwise excavation process of underground caverns of hydropower station using DDA [J]. Rock and Soil Mechanics, 2013, 34(2): 568-574. (in Chinese))
- [7] Feng D L, Wu H N, Chen R P, et al. An analytical model to predict the radial deformation of surrounding rock during shaft construction via shaft boring Machine [J]. Tunnelling and Underground Space Technology Incorporating Trenchless Technology Research, 2023, 140: 105321.
- [8] 周冠南,孙玉永,贾蓬. 基于遗传算法的BP神经网络在隧道围岩参数反演和变形预测中的应用[J]. 现代隧道技术, 2018, 55(1): 107-113. (Zhou Guannan, Sun Yuyong, Jia Peng. Application of genetic algorithm based BP neural network to parameter inversion of surrounding rock and deformation prediction [J]. Modern Tunnelling Technology, 2018, 55(1): 107-113. (in Chinese))
- [9] 张炎,朱珍德,朱姝,等. 龙滩水电站地下洞室围岩变形的智能化预测方法[J]. 水力发电学报, 2013, 32(2): 246-251. (Zhang Yan, Zhu Zhende, Zhu Shu, et al. Intelligent deformation predicting methods for underground chambers of Longtan hydropower station [J]. Journal of Hydroelectric Engineering, 2013, 32(2): 246-251. (in Chinese))
- [10] Li S, Zhao H, Ru Z. Deformation prediction of tunnel surrounding rock mass using CPSO-SVM model [J]. Journal of Central South University, 2012, 19(11): 3311-3319.
- [11] Ma C, Tan Y H, Li E B, et al. Allowable deformation prediction for surrounding rock of underground caverns based on support vector machine [J]. Periodica Polytechnica Civil Engineering, 2016, 60(3): 361-369.
- [12] Pan Y, Chen L, Wang J, et al. Research on

- deformation prediction of tunnel surrounding rock using the model combining firefly algorithm and nonlinear auto-regressive dynamic neural network [J]. *Engineering with Computers*, 2019, 37(2): 1-11.
- [13] Ye X W, Ma S Y, Liu Z X, et al. LSTM-based deformation forecasting for additional stress estimation of existing tunnel structure induced by adjacent shield tunneling [J]. *Tunnelling and Underground Space Technology incorporating Trenchless Technology Research*, 2024, 146: 105664.
- [14] 吕擎峰, 李钰, 牛荣, 等. 基于深度学习的特殊岩土隧道围岩变形预测研究[J]. *应用基础与工程科学学报*, 2023, 31(6): 1590-1600. (Lv Qingfeng, Li Yu, Niu Rong, et al. Research on deformation prediction of surrounding rock in special geotechnical tunnels based on deep learning [J]. *Journal of Basic Science and Engineering*, 2023, 31(6): 1590-1600. (in Chinese))
- [15] 马莎, 肖明. 洞室围岩位移长期预报混沌-神经网络模型[J]. *地下空间与工程学报*, 2011, 7(3): 564-569. (Ma Sha, Xiao Ming. The Chaotic-neural network model on long-term prediction of cavern rock mass displacement [J]. *Underground Space and Engineering*, 2011, 7(3): 564-569. (in Chinese))
- [16] 向文俊, 陈新, 张榴梅. 基于KPCA-IPSO-SVM模型的地下洞室围岩变形预测研究[J]. *水力发电*, 2023, 49(1): 58-62. (Xiang Wenjun, Chen Xin, Zhang Liumei. Prediction of underground cavern surrounding rock deformation based on KPCA-IPSO-SVM model [J]. *Water Power*, 2023, 49(1): 58-62. (in Chinese))
- [17] Hou X, Ge F Z, Chen D B, et al. Temporal distribution-based prediction strategy for dynamic multi-objective optimization assisted by GRU neural network [J]. *Information Sciences*, 2023, 649: 119627.
- [18] 徐冬梅, 王亚琴, 王文川. 基于VMD-GRU与非参数核密度估计的月径流区间预测方法及应用[J]. *水电能源科学*, 2022, 40(6): 1-5. (Xu Dongmei, Wang Yaqin, Wang Wenchuan. Monthly runoff interval prediction method and application based on VMD-GRU nonparametric kernel density estimation [J]. *Water Resource and Power*, 2022, 40(6): 1-5. (in Chinese))
- [19] 姚程文, 杨苹, 刘泽健. 基于CNN-GRU混合神经网络的负荷预测方法[J]. *电网技术*, 2020, 44(9): 3416-3424. (Yao Chengwen, Yang Ping, Liu Zejian. Load forecasting method based on CNN-GRU hybrid neural network [J]. *Power System Technology*, 2020, 44(9): 3416-3424. (in Chinese))
- [20] 王增平, 赵兵, 纪维佳, 等. 基于GRU-NN模型的短期负荷预测方法[J]. *电力系统自动化*, 2019, 43(5): 53-58. (Wang Zengping, Zhao Bing, Ji Weijia, et al. Short-term load forecasting method based on GRU-NN model [J]. *Automation of Electric Power Systems*, 2019, 43(5): 53-58. (in Chinese))
- [21] 辛付宇, 邢丽坤, 刘笑. 基于CNN-GRU神经网络的锂电池SOH估计与RUL预测[J]. *上海节能*, 2024(5): 819-826. (Xin Fuyu, Xing Likun, Liu Xiao. SOH estimation and RUL prediction of lithium battery based on CNN-GRU neural networks [J]. *Shanghai Energy Conservation*, 2024(5): 819-826. (in Chinese))
- [22] 寇敏, 张萌萌, 赵军学, 等. 融合天气特征的WOA-GRU高速公路短时交通流预测[J]. *公路*, 2024, 69(4): 193-199. (Kou Min, Zhang Mengmeng, Zhao Junxue, et al. Short-term traffic flow prediction on highways based on WOA-GRU with integrated weather features [J]. *Highway*, 2024, 69(4): 193-199. (in Chinese))
- [23] Muhammad A, Kamaludin M Y, Benjamin W, et al. Traffic speed prediction using GARCH-GRU hybrid model [J]. *IET Intelligent Transport Systems*, 2023, 17(11): 2300-2312.
- [24] 于德新, 邱实, 周户星, 等. 基于GRU-RNN模型的交叉口短时交通流预测研究[J]. *公路工程*, 2020, 45(4): 109-114. (Yu Dexin, Qiu Shi, Zhou Huxing, et al. Research on short-term traffic flow prediction at intersections based on GRU-RNN model [J]. *Highway Engineering*, 2020, 45(4): 109-114. (in Chinese))
- [25] 黎煜昭, 刘启亮, 邓敏, 等. 基于物理约束GRU神经网络的河流水质预测模型[J]. *地球信息科学学报*, 2023, 25(1): 102-114. (Li Yuzhao, Liu Qiliang, Deng Min, et al. A physics-constrained GRU neural network for river water quality prediction [J]. *Journal of Geo-information Science*, 2023, 25(1): 102-114. (in Chinese))
- [26] 张石磊, 朱赵辉, 段杭, 等. 高应力地下洞室顶拱深部变形及受力特性研究[J]. *地下空间与工程学报*, 2022, 18(1): 341-350. (Zhang Shilei, Zhu Zhaohui, Duan Hang, et al. Research on deep deformation characteristics of roof arch and loading variation of unbonded pre-stressed cable at large underground cavern with high geostress [J]. *Chinese Journal of Underground Space and Engineering*, 2022, 18(1): 341-350. (in Chinese))
- [27] 杨登科. 不同插值方法对GPS时间序列的影响分析[J]. *全球定位系统*, 2019, 44(5): 66-69. (Yang Dengke. Influences of different interpolation methods on GPS time series [J]. *GNSS World of China*, 2019, 44(5): 66-69. (in Chinese))