

DOI: 10.20040/j.cnki.1000-7709.2025.20241777

基于多层感知机和编码器解码器架构的混凝土坝长期变形预测

陶丛丛

(国网电力科学研究院有限公司, 江苏 南京 211106)

摘要: 混凝土坝变形的长期预测是实际运行中保持其结构完整性的重要要求。为提高混凝土长期变形预测的准确性,构建了基于多层感知机(MLP)和编码器—解码器(Ecoder-Decoder)架构的大坝变形长期预测模型MLP-Ecoder-Decoder(MED),该模型通过深度自动相关(Deep-Auto-Correlation)机制捕获大坝变形与环境荷载的长期依赖性,利用时间序列分解和深度自动相机制进行多步变形预测,并采用该模型对青海省的一座250 m高拱坝在复杂环境条件下的变形进行预测。结果表明,MED模型有效提升了预测精度,在提取长时间特征方面具有强大的优势。

关键词: 混凝土坝; 长期变形预测; 多层感知机; 深度学习; 长期预测; 特征提取

中图分类号: TV698.1

文献标志码: A

文章编号: 1000-7709(2025)09-0136-05

1 引言

混凝土坝是由混凝土建造的大型水工建筑物^[1],大坝的变形能够直观地展示整个大坝系统在各种环境压力作用下结构性能的整体波动行为^[2]。因此,必须对大坝变形实施定期的健康监测和有效预警。近年来,Transformer不断发展使更强大的模型成为可能^[3],但依然存在较多缺陷。首先,由于复杂的长期时间模式,模型无法建立可靠的依赖关系;其次,Transformer类的模型使用稀疏自注意力以获得长时间序列的特征,无法充分利用时间数据。此外,多特征输入时模型似乎存在过拟合的问题即时间特征的提取能力不足,特别是当目标时间序列与输入特征为非线性关系时^[4]。对此,WU H X等^[5]提出的Autoformer增强了对复杂变形序列的渐进分解能力,使其能够在长期错综复杂的时间模式中识别可信依赖关系^[6]。深度学习的基础在于多层感知机(MLP)^[7],且深度学习的基础多层感知机能有效地提高模型的时间特征提取能力,提供非常好的数据增强效果^[8-9]。鉴此,本文构建了基于多层感知机(MLP)和编码器—解码器(Ecoder-Decoder)

架构的大坝变形长期预测模型MLP-Ecoder-Decoder(MED),并采用该模型对青海省的一座250 m高拱坝在复杂环境条件下产生的变形进行预测,以评估其长期健康状态。

2 模型构建理论基础

2.1 MLP 模块

多层感知机(MLP)也叫人工神经网络(ANN)。深度自动相关(Deep-Auto-Correlation)机制不同于传统的自注意力方法,它通过计算深度自相关序列,并使用时间延迟聚合来聚合相关子序列,以获取深层次的时间依赖性。

2.1.1 多层感知机

每个隐藏单元(神经元)通过非线性(标量)激活函数连接,然后通过线性映射连接各层,形成深度全连接前馈神经网络。 N 层的深度全连接前馈神经网络可表示为:

$$h_n = \sigma(A_n h_{n-1} + b_n) \quad n = 1, \dots, N-1,$$
$$h_N = A_N h_{N-1} + b_N \quad (1)$$

式中, $h_n \in R^{m_n}$ 为隐藏状态; $\sigma(\cdot)$ 为非线性激活函数; $A_n \in R^{m_n \times m_{n-1}}$ 为权重; $b_n \in R^{m_n}$ 为所有层的偏差 $n = 1, 2, \dots, N$ 。

收稿日期: 2024-09-19, **修回日期:** 2024-12-08

基金项目: 抽水蓄能电站建设期的水工结构动态多维感知与预测预警技术研究(5108-202218280A-2-301-XG)

作者简介: 陶丛丛(1985-),女,高级工程师,研究方向为工程安全监测智能分析,E-mail:taocongcong@sgepri.sgcc.com.cn

2.1.2 时间依赖关系提取模块

当前的大坝变形观测趋势与历史时间序列密切相关。当前的时间模式在过去的子序列中可能有规律可循。以一个实时离散序列 X_t 为例,使用深度自相关 $R_{XX}(\tau)$ 来表示子序列之间的相似性。即:

$$R_{XX}(\tau) = \lim_{L \rightarrow +\infty} \frac{1}{L} \sum_{t=1}^L X_t X_{t-\tau} \quad (2)$$

式中, $R_{XX}(\tau)$ 为 X_t 序列与 τ 滞后序列 $X_{t-\tau}$ 之间的时延相似度。

利用深度自相关 $R(\tau)$ 确定 τ 非标准化置信区间的预测周期长度,选择最长的 k 周期长度 $\tau_1, \tau_2, \dots, \tau_k$ 来计算基于周期的依赖关系,然后使用相关的深度自相关进行加权。

2.1.3 时间延迟模块

通过时间序列依赖关系量化历史子序列与当前预测序列之间的相似性,利用时滞序列 $\tau_1, \tau_2, \dots, \tau_k$ 和聚合块对序列进行滚动处理,并通过聚合每个子序列来执行 Softmax 激活函数。即:

$$\begin{cases} \tau_1, \tau_2, \dots, \tau_k = \arg \text{Top}k (R_{Q,K}(\tau_k)) \\ \tau \in \{1, 2, \dots, L\} \\ \hat{R}_{Q,K}(\tau_1), \dots, \hat{R}_{Q,K}(\tau_k) = \text{Softmax}(R_{Q,K}(\tau_1), \dots, R_{Q,K}(\tau_k)) \\ \text{Deep-AutoCorrelation}(Q, K, V) = \\ \sum_{i=1}^k \text{Roll}(X, \tau_i) \hat{R}_{Q,K}(\tau_i) \end{cases} \quad (3)$$

式中, $\arg \text{Top}M(\cdot)$ 为用于获取 Top k 深度自相关的参数,且 $k = \lceil c \log L \rceil$; $R_{Q,K}$ 为序列 Q 与 K 之间的深度自相关; K, V 均为编码器解码; Q 为自解码器的前块; $\text{Softmax}(\cdot)$ 为激活函数; $\text{Deep-AutoCorrelation}(\cdot)$ 为深度自相关机制函数; $\text{Roll}(X, \tau)$ 为对序列 X 进行滚动操作; τ 为时间步长,移到第一个位置外的元素将在最终一个位置重新引入。

2.2 MED 模型框架

MED 模型由编码器、解码器和时间序列处理模块组成。编码器通过序列去除多级趋势分量,并专注于季节分量;解码器利用多层深度自相关机制处理季节分量,并累加趋势分量;时间序列处理模块侧重于提高数据质量,并有助于提高模型的预测准确性和性能。

2.2.1 序列分解模块

分解是时间序列分析中最重要的方法之一,时间序列数据被分为季节分量和趋势分量。时间分解模块作为模型内部的基本组成部分被集成到 MED 模型中,它可从预测的中间潜在变量中逐步

提取长期静态趋势。长度为 L 的时间序列 $X_t \in R^{L \times d}$, 其分解可表示为:

$$\begin{cases} X_t = \text{AvgPool}(\text{Padding}(X)) \\ X_s = X - X_t \end{cases} \quad (4)$$

式中, $X_s, X_t \in R^{L \times d}$ 分别为季节分量、趋势分量, L 为时间序列的长度, d 为时间序列的维度; $\text{AvgPool}(\cdot)$ 为模型内块和用于移动平均处理(与平均池化方法结合使用时); $X \in R^{L \times d}$ 为传感器得到的监测数据。

因此,整个分解过程可表示为:

$$X_s, X_t = \text{SeriesDecomp}(X) \quad (5)$$

式中, $\text{SeriesDecomp}(\cdot)$ 为序列分解函数。

2.2.2 模型的输入输出

本文模型的输入因子为变形、水位、温度,序列长度均为前 $L-N$ (L 为序列长度, N 为所需要预测的时间长度)条监测数据,输出的变量为所需要预测的 N 步的变形, N 分别设置为 300、450、600 三种情况。

编码器使用前面的 I 个时间步(如 $X_{en} \in R^{I \times d}$)作为输入,而解码器使用序列分解模块得到的季节分量 $X_{des} \in R^{(I/2+O) \times d}$ 和趋势分量 $X_{det} \in R^{(I/2+O) \times d}$ 。初始化包括预测长度 O 和编码器输入 X_{en} 的后 $I/2$ 分解信息。其计算公式为:

$$\begin{cases} X_{ens}, X_{ent} = \text{SeriesDecomp}(X_{en(L_{seq}/2; L_{seq}))} \\ X_{des} = \text{Concat}(X_{ens}, X_0) \\ X_{det} = \text{Concat}(X_{ent}, X_{mean}) \end{cases} \quad (6)$$

式中, $X_{ens}, X_{ent} \in R^{\frac{I}{2} \times d}$ 分别为 X_{en} 的季节分量、趋势分量; $X_0, X_{mean} \in R^{O \times d}$ 分别为补齐 X_{en} 输入的零值、平均值。

2.2.3 编码器结构

MED 模型包含 2 个编码器模块。第 1 个编码器模块接收时间序列数据,输出分量和季节分量。为了更好地利用 Auto-Correlation 提取长期的时间依赖性,将 p 个全连接层放置在自相关(Auto-Correlation)中的 Q 和 K 上。经试验证实,当 p 设置为 3 时,试验精度达到最佳。因此,第 1 个编码器模块的总流程表示为:

$$\begin{cases} X_{en}^l = \text{Encoder}(X_{en}^{l-1}) \\ S_{en}^{l,1}, \dots = \text{SeriesDecomp}(\text{MLP} - \\ \text{AutoCorrelation}(X_{en}^{l-1}) + X_{en}^{l-1}) \\ S_{en}^{l,2}, \dots = \text{SeriesDecomp}(\text{FeedForward}(S_{en}^{l,1}) + S_{en}^{l,1}) \end{cases} \quad (7)$$

式中, $X_{en}^l = S_{en}^{l,2}, l \in \{1, 2, \dots, N\}$ 为第 l 层编码器的输出, $\text{Encoder}(\cdot)$ 为编码器函数; $S_{en}^{l,i}, i \in \{1, 2\}$ 为不同层的季节分量; $\text{MLP-AutoCorrelation}(\cdot)$

为耦合了全连接层的自相关机制函数；FeedForward(·)为前馈神经网络。

2.2.4 解码器结构

MED 模型有 1 个解码器模块,该模块利用多层深度自相关机制处理季节分量,并累加趋势分量。解码器由 3 个序列分解块、关联编码器、深度自相关模块及前馈模块构成。第 1 个解码器块的整个操作可描述为:

$$\begin{cases} S_{de}^{l,1}, T_{de}^{l,1} = \text{SeriesDecomp}(\text{MLP} - \\ \text{AutoCorrelation}(X_{de}^{l-1}) + X_{de}^{l-1}) \\ S_{de}^{l,2}, T_{de}^{l,2} = \text{SeriesDecomp}(\text{MLP} - \\ \text{AutoCorrelation}(S_{de}^{l,1}, X_{en}^N) + S_{de}^{l,1}) \\ S_{de}^{l,3}, T_{de}^{l,3} = \text{SeriesDecomp}(\text{FeedForward}(S_{de}^{l,2}) + S_{de}^{l,2}) \\ T_{de}^l = T_{de}^{l-1} + W_{l,1} T_{de}^{l,1} + W_{l,2} T_{de}^{l,2} + W_{l,3} T_{de}^{l,3} \end{cases} \quad (8)$$

式中, $X_{de}^l = S_{de}^{l,3}, l \in \{1, 2, \dots, M\}$ 为第 l 层解码器的输出; $S_{de}^{l,1}, T_{de}^{l,1}, i \in \{1, 2, 3\}$ 分别为第 i 个序列分解后的趋势分量、季节分量; X_{en}^N 为第 N 层编码器的输出; $W_{l,i}, i \in (1, 2, 3)$ 分别为第 i 个序列权重系数。

2.3 MED 模型工作流程

MED 建模的具体步骤如下。

步骤 1 数据预处理。基于大坝现场监测数据,利用水位、气温和变形生成 MED 模型的输入。所需预测的时间步长作为输出。将数据集分为训练集、验证集和测试集。同时,对数据进行归一化处理。

步骤 2 时间序列分解。将输入的时间序列分解为趋势分量和季节分量。使用平均池化方法提取趋势分量和季节性的特征。

步骤 3 编码器工作。编码器主要提取时间序列的长期依赖关系。使用 MLP 结合深度自相关(Deep Auto-Correlation)机制捕获历史子序列与当前序列之间的依赖性。

步骤 4 解码器工作。利用深度自相关机制处理编码器的输出。

步骤 5 生成大坝变形的最终预测。最终预测结果为变形趋势分量和变形季节分量的累加。

3 实例研究

3.1 数据的收集和获取

以青海省的一座 250 m 高拱坝为例,自 2004 年以来,大坝建设过程中安装了大量的传感器来监测大坝温度、变形和沉降等状态,收集的大量监

测数据用于大坝安全评价。如图 1 所示,在不同位置嵌入 36 个传感器来监测大坝变形。




图 1 大坝垂线布置图

Fig. 1 Vertical line plan of dam

为综合评价模型的性能,选取 3 个监测点 PL2-1、PL4-1、PL4-2 的径向变形数据进行对比分析。试验结果表明,坝体下游变形与实测值呈正相关。图 2 为拱坝的长期变形、上游水位及气温随时间的波动情况图,图 2 中监测数据的时间序列涵盖了 9 年数据(即从 2012 年 1 月~2021 年 7 月)。采用前 5 年(2012 年 1 月~2017 年 12 月)的数据用于模型训练,后 2 年(2017 年 12 月~2019 年 12 月)的数据用于验证模型,而剩余的数据(2019 年 12 月~2021 年 7 月)用于测试。由于径向位移数据的时间间隔不均(1~7 d),采用线性插值法处理以确保数据的连续性。




图 2 长期变形、气温及上游水位过程线图

Fig. 2 Long-term deformation, temperature and upstream water level process line chart

3.2 试验参数设置

在大坝变形的多步预测方面,本文考虑 300、450、600 3 个预测步长,设置 300、450、600 d 的预测周期,并与 MED、Autoformer、Informer、LSTM、MLR 5 个深度学习模型开展对比试验。

为确保预测模型之间的公平比较,所有模型在相同的试验设计下训练,使用 Nvidia RTX 4080 GPU 及相同的监测序列数据(上游水位、温度和降雨量)作为输入。同时,本文统一使用 365 d 的滑动窗口时间步长。滑动窗口将时间序列数据分割为多个固定大小的窗口。每个窗口内包含了一段时间内的连续数据点。对于大坝监测数据,一个滑动窗口即包含了 365 d 内的水位、温度、变形等数据。所以滑动窗口这种可在不同时间段提取时间序列的特征的方法可让 MED 模型学习到不同时间段内数据的模式,从而更好地预测大坝健康监测的未来趋势。由于环境和位移数据的变化通常每年发生一次变化,使用 365 d 的滑动窗口时间步长能够完整地涵盖这些年度变化周期,有助于更准确地捕捉数据中的规律,进而提高模型预测的准确性。

3.3 不同预测时间长度下的表现

为进一步确定 MED 模型在各种情况下的预测效果,在不同预测时间和不同测点下比较了多个时间序列预测模型的有效性。为防止使用不同规模的数据构建模型产生负面影响,对每个输入数据序列进行归一化处理:

$$x_{norm} = (x - x_{min}) / (x_{max} - x_{min}) \quad (9)$$

式中, x 、 x_{norm} 分别为大坝的监测数据序列、归一化的大坝监测数据序列; x_{max} 、 x_{min} 分别为输入大坝监测数据序列的最大值、最小值。

选取均方根误差 (R_{RMSE})、平均绝对误差 (M_{MAE})和均方差 (M_{MSE})作为评价指标来衡量模型的预测精度和识别异常值。

表 1 为不同模型在不同测点的不同预测阶段的评价指标。由表 1 可看出, MED 模型在不同测点、不同步长下均有良好的性能,尤其是在 600 步的预测中,展示出 MED 模型在长期多步的预测中强大的时间特征提取能力。与其他深度学习模型相比, MED 模型和 Autoformer 具有更好的性能。MED 模型的 M_{MSE} 、 M_{MAE} 分别比 Autoformer 低 51.84%、32.66%,预测效果更好。此外, LSTM 模型在 PL4-2 测点的 300 步预测中效果略优于 MED 模型, MED 模型在短期预测中具有一定的局限性。但相较于 Autoformer, MED 模型在 300 步预测中的 M_{MSE} 、 M_{MAE} 、 R_{RMSE} 分别提高了 58.01%、40.03%、36.59%。由于 LSTM 为一步预测模型,其在动态预测过程中可能累积大量误差。Informer 相对于其他模型误差较大,表明其注意机制在长期多步的预测中捕捉历史特征的能力较弱。本文对比试验还采用了统计模型 MLR,其结果也在长期预测中表现出的预测性能远低于 MED 模型,这也是由于 MLR 模型本身难以获取数据间的复杂非线性关系。因此,在预测长度达 600 步时预测性能更显不足。

图 3 为不同模型的 600 步变形预测效果。由图 3 可看出, MED 模型能较好地预测曲线的收敛

表 1 不同模型预测结果的评价指标

Tab. 1 Evaluation indicators of the prediction results of different models

测点	天数 /d	MED			Autoformer			Informer			LSTM			MLR		
		M_{MSE}	M_{MAE}	R_{RMSE}	M_{MSE}	M_{MAE}	R_{RMSE}	M_{MSE}	M_{MAE}	R_{RMSE}	M_{MSE}	M_{MAE}	R_{RMSE}	M_{MSE}	M_{MAE}	R_{RMSE}
PL2-1	600	0.454	0.538	0.674	1.063	0.825	1.031	5.017	2.016	2.239	2.274	1.409	1.508	7.146	2.187	2.673
	450	0.316	0.456	0.558	0.906	0.737	0.952	6.318	2.189	2.513	3.950	1.544	1.987	4.820	1.668	2.195
	300	0.541	0.504	0.710	1.071	0.894	1.035	5.704	2.067	2.388	1.166	0.945	1.080	6.892	2.227	2.625
PL4-1	600	0.954	0.725	0.977	1.865	1.011	1.365	21.56	4.100	4.644	19.61	3.821	4.429	17.216	3.368	4.149
	450	2.318	1.367	1.522	5.087	1.957	2.255	26.37	4.396	5.135	10.11	4.190	4.256	12.846	2.756	3.584
	300	1.193	0.972	1.092	2.040	1.192	1.428	28.78	4.705	5.364	4.911	1.924	2.216	18.709	3.795	4.325
PL4-2	600	0.080	0.236	0.283	0.196	0.391	0.443	3.021	1.597	1.738	1.056	0.890	1.027	10.046	2.969	3.169
	450	0.091	0.366	0.302	0.285	0.413	0.518	6.108	2.414	2.491	0.445	0.556	0.667	6.918	2.433	2.630
	300	0.238	0.370	0.487	0.820	0.782	0.906	2.553	1.553	1.598	0.107	0.271	0.317	6.777	2.428	2.603

注: M_{MSE} 单位为 mm^2 ; M_{MAE} 、 R_{RMSE} 单位均为 mm 。




图 3 不同测点 600 步的预测结果可视化

Fig. 3 Visualization diagram of 600-step prediction result of different measuring points

点和变化趋势。虽然 Autoformer、Informer、LSTM 和 MLR 模型能够生成多样化的预测,但 MED 模型在 600 步长保持稳定的预测性能,尽管 MED 模型在短期内预测效果相对较差。总体而言,MED 模型对变形趋势的预测是可靠的。

3.4 有关 MLP 层数的讨论

为验证 MLP 策略的有效性,基于 Autoformer 模型的 PL2-1 测点进行 9 组测试,每组增加 1~9 个 MLP 层,以确定添加到框架中 MLP 层数的最佳数量。最后,利用 M_{MSE} 、 M_{MAE} 、 R_{RMSE} 评价指标(见表 2)分析模型在预测 300、450、600 时间步预测结果的性能。

表 2 全连接层数预测的评价指标

Tab. 2 Evaluation indicators of full connected layer count prediction

测点	预测步长	评价 指标	全连接层数								
			1	2	3	4	5	6	7	8	9
PL2-1	600	M_{MSE}	1.260	1.884	0.467	1.918	1.978	0.892	0.584	2.483	4.761
		M_{MAE}	0.793	1.040	0.542	1.034	1.038	0.724	0.583	1.343	1.772
		R_{RMSE}	1.122	1.373	0.683	1.385	1.406	0.945	0.764	1.576	3.182
450		M_{MSE}	0.676	0.629	0.564	0.752	0.546	0.892	0.554	3.330	1.929
		M_{MAE}	0.677	0.694	0.546	0.648	0.556	0.817	0.593	1.565	1.176
		R_{RMSE}	0.822	0.793	0.754	0.867	0.739	0.945	0.744	1.825	1.389
300		M_{MSE}	1.174	0.799	0.515	1.408	1.169	1.665	0.844	1.114	3.543
		M_{MAE}	0.843	0.633	0.541	0.915	0.804	1.175	0.731	0.773	1.635
		R_{RMSE}	1.084	0.894	0.718	1.187	1.081	1.290	0.918	1.055	1.882

由表 2 可看出,MED 模型添加全连接(FC)网络形成的 MLP 层表现优于 Autoformer,这主要是因为 MLP 层能更好提取大坝变形序列的时间特征。且 MED 模型在 3 个 FC 层时达到了最佳预测精度。虽然在某些情况下,增加 FC 层数可能导致预测性能波动和运行时间增加,但适量的 FC 层有助于减少长期变形预测的误差。因此,添加适量的 FC 层可帮助模型学习更深层次的变形序列时间特征。

4 结论

a. 本文构建的基于多层感知机(MLP)和编码器—解码器(Ecoder-Decoder)架构的大坝变形

长期预测模型 MLP-Ecoder-Decoder(MED)在多步预测和多特征预测方面均表现良好,且多特征输入可在正确特征提取下有效提高模型的长期多步预测能力。

b. MED 模型在短期预测方面无实质性的优势,且该模型未评估其他测量点对需要预测点的影响,未来尚需进一步深入研究。

参考文献:

- [1] 周仁练,苏怀智,韩彰,等. 混凝土坝变形的长期预测模型与应用[J]. 水力发电学报,2021,40(9):122-131.
- [2] WEI B W, YUAN D Y, LI H K, et al. Combination forecast model for concrete dam displacement considering residual correction[J]. Structural health monitoring, 2019, 18(1): 232-244.
- [3] 翁鸣昊,项兴华,陈俊涛,等. 基于 LSTM 与 Transformer 的大坝变形预测研究[J]. 中国农村水利水电, 2024(4): 250-257.
- [4] 徐筠雯,陈宗镭,李天瑞,等. 基于季节分解的混合神经网络的时间序列预测[J]. 计算机科学, 2024, 51(增刊 2): 553-559.
- [5] WU H X, XU J H, WANG J M, et al. Autoformer: Decomposition transformers with auto-correlation for long-term series forecasting[C]//35th Conference on Neural Information Processing Systems (NeurIPS 2021), 2021.
- [6] 唐利涛,张智勇,陈俊,等. 基于 Autoformer 的电力负荷预测与分析研究[J]. 华东师范大学学报(自然科学版), 2023(5):135-146.
- [7] CHEN X D, CHEN Z H, HU S W, et al. A feature decomposition-based deep transfer learning framework for concrete dam deformation prediction with observational insufficiency[J]. Advanced engineering informatics, 2023, 58: 102175.
- [8] SHOMOPE I, TAWALBEH M, AL-OTHMAN A, et al. Predicting biohydrogen production from dark fermentation of organic waste biomass using multilayer perceptron artificial neural network (MLP-ANN)[J]. Computers & chemical engineering, 2025, 192: 108900.
- [9] 巨佳丽,武传号,胡晓农,等. 基于 VIC 和 MLP-ANN 模型重建中国陆地水储量数据[J]. 水科学进展, 2024, 35(5): 711-725.

Long-term Deformation Prediction of Concrete Dam Based on MLP and Ecoder-Decoder Framework

TAO Cong-cong

(State Grid Electric Power Research Institute, Nanjing 211106, China)

Abstract: The long-term prediction of concrete dam deformation is an important requirement for maintaining its structural integrity during actual operation. To improve the accuracy of long-term deformation prediction of concrete, a long-term dam deformation prediction model based on multi-layer perceptron (MLP) and ecoder-decoder (Ecoder-Decoder) architecture, MLP-Ecoder-Decoder (MED), was constructed. This model captured the long-term dependence of dam deformation and environmental loads through a deep auto-correlation (Deep-Auto-Correlation) mechanism, and used time series decomposition and deep auto-correlation mechanism for multi-step deformation prediction. The model was used to predict the deformation of a 250 m height arch dam in Qinghai Province under complex environmental conditions. The results show that the MED model effectively improves the prediction accuracy and has a strong advantage in extracting long-term time features.

Key words: concrete dam; long-term deformation prediction; multilayer perceptron; deep learning; long-term forecast; feature extraction