

基于数据分解重构和 AM-CRU-MLR 模型的 基坑变形研究与应用

Research and Application of Excavation Deformation based on Data Decomposition and
Reconstruction and AM-CRU-MLR Model

王安东, 张学钢, 宁波

(陕西铁路工程职业技术学院, 陕西 渭南 714000)

摘要: 为有效掌握基坑变形特性, 以基坑位移变形监测成果为基础, 在开展基坑变形现状特征分析基础上, 利用集成经验模态和样本熵分别实现变形数据的分解、重构, 以准确将其分解为真实变形项和不确定变形项, 再进一步通过 CRU 神经网络和多元线性回归分别实现不同变形项的预处理, 实现基坑变形的高精度预测, 并借其结果掌握基坑变形特性。结果表明: 通过数据分解、重构处理, 能有效分解基坑变形数据, 且较传统分解思路的优越性明显; 通过 AM-CRU-MLR 模型预测, 预测精度相对更优, 充分验证了预测思路的有效性, 为基坑变形特性分析提供了一定的技术支持。

关键词: 基坑; 变形数据; 分解处理; 变形预测; 变形特征

中图分类号: P642 文献标志码: A 文章编号: 1005-8249 (2024) 05-0065-06

DOI: 10.19860/j.cnki.issn1005-8249.2024.05.012

WANG Andong, ZHANG Xuegang, NING Bo

(Shaanxi Railway Institute, Weinan 714000, China)

Abstract: In order to effectively grasp the deformation characteristics of foundation pits, based on the displacement and deformation monitoring results of foundation pits, and based on the analysis of the current deformation characteristics of foundation pits, the integrated empirical mode and sample entropy are used to decompose and reconstruct the deformation data, accurately decomposing it into real deformation terms and uncertain deformation terms. Furthermore, CRU neural network and multiple linear regression are used to preprocess different deformation terms, achieving high-precision prediction of foundation pit deformation, and using the results to grasp the deformation characteristics of foundation pits. The results shows that through data decomposition and reconstruction processing, the deformation data of foundation pits can be effectively decomposed, and its superiority is obvious compared to traditional decomposition methods; The AM-CRU-MLR model showed relatively better prediction accuracy, fully verifying the effectiveness of the prediction approach and providing theoretical support for the analysis of deformation characteristics of foundation pits.

Keywords: foundation pit; deformation data; decomposition treatment; deformation prediction; deformation characteristics

0 引言

随着市政工程的快速发展, 基坑工程数量日益增加, 在带来巨大经济效益的同时, 也引发了一定的工程问题, 如基坑多处于建、构筑物密集区, 基

岩土力学

坑失稳会引发一系列连续破坏；为确保基坑安全施工，变形控制显得尤为重要。因此，开展基坑变形特性分析显得十分必要^[1-3]。在基坑变形特性分析中，大致可分为两部分内容，一是结合现有变形监测成果，开展现阶段变形规律总结；二是立足于现阶段变形监测成果，开展变形预测分析，以掌握其发展规律。一般来说，基坑现阶段变形规律总结相对较易处理，但变形预测分析相对较为困难，因此，重点需开展基坑变形预测研究。在基坑变形监测过程中，存在多种影响因素干扰，如施工机械、温度等，这会造成基坑变形数据难以完全代表基坑真实变形，对预测精度造成一定影响^[4]，因此，有必要先考虑基坑数据的分解处理。据李柏侠等^[5]、王景春等^[6]的研究成果得知，经验模态分解适用于基坑变形数据的分解处理，以其为理论基础，构建基坑变形数据的分解模型是可行的。但值得指出的是，以往数据分解过程均未考虑分解量的重构问题^[7]，即未考虑通过数据重构来减少运算量，因此可以进一步拓展此方面研究。同时，在基坑变形预测模型的构建过程中，门控循环单元神经网络对非线性预测的适用性较强^[8]，加之多元线性回归能实现残余项补充预测^[9]，以此两类模型进行基坑变形预测也是可行的。

综上，以基坑位移变形监测为基础，先开展基坑变形现状特征分析，再进行变形预测研究，且在预测模型构建过程中，先进行基坑变形数据分解、重构处理。通过研究，以期为基坑变形控制提供技术支持。

1 分析方法构建

1.1 数据分解、重构模型的构建

1.1.1 数据分解处理

EMD 模型法是一种较优的自适应数据时频处理方法，对非平稳信号的分析能力较强。据 EMD 模型基本原理，其分解过程大致为：将基坑原始变形数据分解为若干模态分量和一个误差分量。由于模态分量间会存在一定混合现象，造成其分解不精确，为解决该问题，集成经验模态分解（简称 EEMD）应运而生，其处理方式是在基坑原始变形数据中添加白噪声，而此噪声会在后续计算中抵消，从而集成

均值计算结果可作为基坑变形数据分解的最终结果。

EEMD 模型的基坑原理为：

(1) 先将白噪声加入基坑原始变形数据中，得到新的变形序列 $Y_i(t)$ ：

$$Y_i(t) = y(t) + w_i(t) \quad (1)$$

式中： $w_i(t)$ 为第 i 次添加的白噪声信息。

(2) 利用 EMD 模型对序列进行分解处理，得到各阶模态分量，即：

$$Y_i(t) = \sum_{j=1}^m C_{ij}(t) + R_i(t) \quad (2)$$

式中： $C_{ij}(t)$ 为白噪声的模态分量； m 为模态分量的个数； $R_i(t)$ 为白噪声的残余分量。

(3) 由于白噪声在频谱上的均值应为 0，将上述各分量进行均值求解，即：

$$C_j(t) = \sum_{i=1}^N C_{ij}(t) / N \quad (3)$$

$$R(t) = \frac{1}{N} \sum_{i=1}^N R_i(t) \quad (4)$$

式中： N 为白噪声信号，具等长特征； $C_j(t)$ 为第 j 个集成平均后的模态分量； $R(t)$ 为最终残余分量。

经过上述处理，将基坑变形数据分解为若干模态分量和最终残余分量。

1.1.2 数据重构处理

在 EEMD 模型分解结果中，具有若干模态分量，若对各分量均进行单独预测，势必增加计算量，因此，提出利用样本熵理论对各模态分量进行相关性评价，并以相关性评价结果进行模态分量的重构处理。

根据样本熵理论，先计算两评价序列在不同匹配点数条件上的概率，即：

$$B^m(r) = \sum_{i=1}^{L-m} B_i^m(r) / (L-m) \quad (5)$$

$$A^m(r) = \sum_{i=1}^{L-m} A_i^m(r) / (L-m) \quad (6)$$

式中： $B^m(r)$ 为两序列在容限 r 条件下匹配 m 个点的概率； $A^m(r)$ 为两序列在容限 r 条件下匹配 $m+1$ 个点的概率； L 为序列长度； m 为维数； $B_i^m(r)$ 为在匹配 m 个点条件下的统计比值； $A_i^m(r)$ 为在匹配 $m+1$ 个点条件下的统计比值。

在上述两概率统计上，定义样本熵 S 为：

$$S = -\ln \left[\frac{A^m(r)}{B^m(r)} \right] \quad (7)$$

利用样本熵理论分别计算原始变形序列、各模态分量及残余分量的样本熵。当分量样本熵小于原始变形序列的样本熵时，将其进行合并处理，得到重构后的分量；反之，则不进行处理。

通过上述 EEMD-SE 模型可实现基坑变形数据分解及重构处理，即将基坑变形数据合理分解为真实变形项和不确定变形项。

结合以往经验，提出以信噪比和均方根误差为基础指标，其中，信噪比值越大，分解效果越优；而均方根误差值越小，分解效果越优。为便于不同分解模型的对比分析，提出构建综合评价指标 g ，其值越大，说明分解效果最优，计算公式为：

$$g = g_1 + g_2 \quad (8)$$

式中： g_1 为信噪比的归一化值； g_2 为均方根误差倒数的归一化值。

1.2 变形预测模型的构建

由于对基坑变形数据进行了分解处理，单一模型已无法完成预测，需分别针对真实变形项和不确定变形项构建模型。

1.2.1 真实变形项的预测模型

考虑 GRU 神经网络是 2014 年提出的新型神经网络，且也是相较 LSTM 神经网络的最成功变体模型，具有架构简单、参数少等优点，因此，提出利用 GRU 实现基坑真实变形项的预测处理^[10-11]。

同时，考虑到注意力机制 (Attention Mechanism, AM) 能在人注意力有限条件下，不会对视野内所有物体均具有相同的关注度，而是对重要区域进行主要关注，并忽略非重要区。因此，为保证 GRU 神经网络对基坑真实变形项的预测效果，提出将注意力机制引入至 GRU 神经网络中，构建 AM-GRU 模型，对基坑真实变形项的预测处理。

AM-GRU 模型预测步骤如下：

(1) 对基坑真实变形项数据进行初始化处理，再将注意力机制加入 GRU 神经网络中，以确定时间步长参数，完善非线性映射关系；

(2) 在相应时间节点处，利用注意力机制将一个原始数据转移至隐藏层中，再按照 GRU 神经网络

实现后续预测。

AM-GRU 模型虽具较优的预测效果，但考虑基坑真实变形项具较强的非线性特征，其预测结果仍会存在一定的误差。为保证最终预测精度，将该预测误差叠加至基坑不确定变形项中，得到新的不确定变形项。

1.2.2 不确定变形项的预测模型

考虑新的不确定变形项具多方面成因，且 MLR 模型无需复杂的迭代过程及参数调整，加之其收敛速度较快，预测精度较高，因此，提出利用 MLR 模型对新的不确定变形项进行预测^[12]。

据 MLR 模型基本原理，其预测精度由最小二乘法控制，且其最重要的是计算回归系数 β ，其求解公式为：

$$\beta = (X^T X)^{-1} X^T Y \quad (9)$$

式中： Y 为不确定变形向量； X 为影响因素向量。

通过 AM-GRU 模型和 MLR 模型分别对基坑真实变形项和不确定变形项进行预测，并将两者预测结果叠加，即为基坑变形的最终预测结果。

2 实例分析

2.1 工程概况

某地铁车站设计为地下二层岛式车站，共设计为东、西两基坑，尺寸参数见表 1。

据钻探成果^[13]可知，在基坑开挖及影响范围内，各类土层的物理力学参数见表 2。

表 1 基坑尺寸特征参数

Table 1 Characteristic parameters of foundation pit size /m					
基坑分类	长度	标准段宽度	标准段深度	端头井宽度	端头井深度
东基坑	103	19.7	16.96	23.8	17.97
西基坑	397	19.7	16.96	23.8	18.95

表 2 土层的物理力学参数统计

Table 2 Statistics of physical and mechanical parameters of soil layer					
土层名称	埋深 /m	厚度 /m	含水率 /%	黏聚力 /kPa	内摩擦角 /°
杂填土	1.5 ~ 3.8	1.6 ~ 3.9	42.3	14.9	9.9
黏土	4.0 ~ 6.8	8.0 ~ 12.5	51.9	13.4	9.2
淤泥质黏土	15.4 ~ 17.9	0.6 ~ 0.7	31.5	14.7	10.8
粉砂	13.6 ~ 17.6	0.6 ~ 3.4	32.6	15.9	10.5
粉质黏土	14.4 ~ 20.1	0.8 ~ 10.3	44.1	13.9	9.5
淤泥质黏土	21.4 ~ 39.5	0.6 ~ 19.1	43.3	25.3	13.0

基坑采用地下连续墙作为临时支护结构，墙厚 80 cm，标准段采用 4 道钢支撑 + 1 道混凝土支撑，

岩土力学

端头井再增加 1 道钢支撑；标准段地连墙的插入比为 1.07，东、西基坑的端头段插入比分别为 1.14 和 1.22。

2.2 基坑位移变形特征

以东基坑为例，通过位移分析来掌握基坑变形特征。东基坑共计布设 14 个监测点，具体布置如图 1 所示。




图 1 基坑位移监测点示意图

Fig. 1 Schematic diagram of side displacement monitoring points of foundation pit

监测时间为 2019 年 2 月 17 日~2019 年 4 月 28 日，共计 70 d，按 2 d 数据进行一次统计，得到 35 期监测成果。

各监测点最大位移及对应的开挖深度、最大值所处深度见表 3。基坑位移最大值分布范围为 16.2~82.7 mm，平均位移值为 58.5 mm，标准差为 21.12 mm，波动性相对较大。其中，北侧以 CX3 监测点位移值 77.9 mm 相对最大，南侧以 CX8 监测点

表 3 基坑位移及特征参数

Table 3 Characteristic parameters of lateral displacement of foundation pit

监测点序号/ 特征参数	位移最大值 δ/mm	基坑开挖 深度 H/m	最大值所处 深度 H_0/m
CX1	27.5	18	16.5
CX2	74.5	17	20.0
CX3	77.9	17	20.0
CX4	61.7	17	20.0
CX5	76.4	17	21.0
CX6	50.0	17	17.0
CX7	58.5	17	19.5
CX8	82.7	17	20.5
CX9	78.1	17	19.0
CX10	75.9	17	18.5
CX11	68.4	17	20.0
CX12	16.2	18	14.0
CX13	31.2	18	20.5
CX14	40.0	17	12.5
最大值	82.7	18.0	21.0
最小值	16.2	17.0	12.5
平均值	58.5	17.2	18.5
标准差	21.12	0.42	2.49

位移值 82.7 mm 相对最大，西侧以 CX14 监测点位移值 40.0 mm 相对最大，东侧以 CX13 监测点位移值 31.2 mm 相对最大；对比四侧的最大位移值，得出长边较短边的位移量相对更大，分析其主要原因是长边支护刚度相对更小，而短边支护刚度相对更大。在位移最大值对应的开挖深度方面， H 值分布范围为 17.0~18.0 mm，平均位移值为 17.2 mm，标准差为 0.42 mm，波动性相对很小；在位移最大值所处深度方面， H_0 值分布范围为 12.5~21.0 mm，平均位移值为 18.5 mm，标准差为 2.49 mm，波动性相对一般。

为进一步了解 3 个位移参数间的关联性，对 3 个位移参数进行统计，见表 4。

表 4 基坑位移关联性参数

Table 4 Correlation parameters of lateral displacement of foundation pit

监测点序号	参数 1 (δ/H) /‰	参数 2 (H_0/H)	参数 3 (δ/H_0) /‰
CX1	1.53	0.92	1.67
CX2	4.38	1.18	3.73
CX3	4.58	1.18	3.90
CX4	3.63	1.18	3.09
CX5	4.49	1.24	3.64
CX6	2.94	1.00	2.94
CX7	3.44	1.15	3.00
CX8	4.86	1.21	4.03
CX9	4.59	1.12	4.11
CX10	4.46	1.09	4.10
CX11	4.02	1.18	3.42
CX12	0.90	0.78	1.16
CX13	1.73	1.14	1.52
CX14	2.35	0.74	3.20

在参数 1 (δ/H) 的计算结果中，参数变化范围为 0.90‰~4.86‰，平均值为 3.424‰，基坑位移最大值与其对应基坑开挖深度的相关性有限；参数 2 (H_0/H) 变化范围为 0.74~1.24，平均值为 1.076，且位移最大时，基坑开挖深度 H 与最大值所处深度 H_0 相当，具较强的关联性；参数 3 (δ/H_0) 变化范围为 1.16‰~4.11‰，平均值为 3.107‰，基坑位移最大值与其所处深度的相关性一般。

为进一步开展后续基坑变形特性分析，选取位移最大的监测点进行代表性分析，即 CX3、CX8、CX13 和 CX14，得到位移变形曲线如图 2 所示，4 个监测点位移变形随时间增大而持续增加，中期位移增加速率较大。




图2 基坑位移变形曲线

Fig. 2 Lateral displacement deformation curve of foundation pit

2.3 基坑变形数据的分解、重构处理

在 EEMD-SE 模型的构建过程中，其组合过程可进一步细分为三类模型，即 EMD 模型、EEMD 模型和 EEMD-SE 模型，三者的分解效果见表 5。依次按照 EMD 模型、EEMD 模型、EEMD-SE 模型顺序，信噪比不断增大，且均方根误差逐步减小，说明随分解、重构过程的持续组合，基坑变形数据的分解效果逐步变优，直接验证了 EEMD-SE 模型的构建过程具较强的合理性。

表5 不同分解、重构过程的分解结果

Table 5 Decomposition results of different decomposition and reconstruction processes

模型名称	信噪比/dB	均方根误差/(10^{-4} mm)
EMD 模型	22.39	6.03
EEMD 模型	26.07	4.62
EEMD-SE 模型	30.22	4.11

2.4 基坑变形预测分析

经数据分解及重构处理，将变形数据分解为真实变形项和不确定变形项，且考虑预测过程具多模型组合特征，以 CX3 监测点为例进行预测结果分析，以 1~30 周期进行训练，31~35 周期数据进行验证，36~39 周期数据进行外推预测。

2.4.1 CX3 监测点预测分析

为验证注意力机制对 GRU 神经网络的优化效果，对 GRU 模型和 AM-GRU 模型的预测结果进行统计，见表 6。在对应预测节点处，AM-GRU 模型的相对误差值较小，MAPE 指标值为 2.57%，而 GRU 模型的 MAPE 指标值为 3.44%，说明 AM-GRU 模型较 GRU 模型预测精度高，注意力机制对 GRU 神经网络的优化是有效果的。

AM-GRU 模型的 MAPE 指标值为 2.57%，预测效果相对一般，加之不确定变形项的存在，进行后续 MLR 模型预测，得到 CX3 监测点通过 AM-GRU-

MLR 模型预测后的最终预测结果见表 7。经 MLR 模型不确定变形项预测，CX3 监测点在最终预测结果中的相对误差变化范围为 1.98%~2.14%，MAPE 指标值为 2.06%，预测效果较优；对比真实变形项预测结果，预测精度显著提高。

表6 CX3 监测点的真实变形项预测结果

Table 6 Prediction results of real deformation items at CX3 monitoring points

监测周期/期	真实变形项/mm	GRU 模型		AM-GRU 模型	
		预测值/mm	相对误差/%	预测值/mm	相对误差/%
31	70.33	67.74	3.68	68.53	2.56
32	71.06	68.49	3.62	69.35	2.41
33	72.11	69.58	3.51	70.09	2.80
34	72.98	70.67	3.16	71.11	2.56
35	74.02	71.64	3.21	72.14	2.54

表7 CX3 监测点的最终预测结果

Table 7 Final prediction results of CX3 monitoring points

监测周期/期	实测值/mm	真实变形项预测值/mm	不确定变形项预测值/mm	最终预测值/mm	相对误差/%
31	73.4	68.53	3.40	71.93	2.04
32	74.4	69.35	3.45	72.80	2.14
33	75.4	70.09	3.84	73.93	1.98
34	76.5	71.11	3.88	74.99	2.02
35	77.9	72.14	4.10	76.24	2.13

2.4.2 剩余监测点预测结果及外推预测结果

参照 CX3 监测点的预测结果，再对剩余 3 个监测点进行类似预测，并对 4 个监测点进行外推预测，结果见表 8。4 个监测点的预测结果中，相对误差范围为 1.98%~2.15%，MAPE 值范围为 2.03%~2.09%，说明 AM-GRU-MLR 模型始终具较优的预测精度，且 MSE 值范围为 0.04%~0.07%，也进一步说明 AM-GRU-MLR 模型预测结果稳健性较好。

由 36~39 周期的外推预测结果可知，基坑位移变形仍会进一步增加，但增加速率相对减弱，趋于稳定。

2.4.3 预测模型的可靠性验证

引入 SVM 模型和 GM(1, 1) 模型与本文模型对比，对 4 个监测点进行类似预测，统计 MSE 值和 MAPE 值，结果见表 9。本文模型 MSE 值和 MAPE 值较其他两模型更小，且差异明显，说明本文模型较 SVM 模型和 GM(1, 1) 模型具有显著的可靠性，充分验证其在实例中的适用性。

岩土力学

表 8 所有监测点的最终预测结果

Table 8 Final prediction results of all monitoring points

监测周期 /期	CX3 监测点			CX8 监测点			CX13 监测点			CX14 监测点		
	实测值 / mm	预测值 / mm	相对误差 /%	实测值 / mm	预测值 / mm	相对误差 /%	实测值 / mm	预测值 / mm	相对误差 /%	实测值 / mm	预测值 / mm	相对误差 /%
31	73.4	71.93	2.04	79.1	77.42	2.08	27.3	26.76	2.05	36.2	35.38	2.12
32	74.4	72.80	2.14	79.9	78.33	1.99	28.2	27.59	2.07	37.3	36.55	2.08
33	75.4	73.93	1.98	80.2	78.57	2.01	29.3	28.74	2.01	38.4	37.56	2.05
34	76.5	74.99	2.02	81.8	80.19	2.02	30.7	30.09	2.09	39.2	38.32	2.15
35	77.9	76.24	2.13	82.7	81.00	2.06	31.2	30.54	2.11	40.0	39.18	2.04
36		77.36			81.83			31.39			39.97	
37		78.57			82.64			32.08			40.55	
38		79.63			83.28			32.88			41.21	
39		80.19			83.98			33.27			41.96	

表 9 不同预测模型的结果对比

Table 9 Comparison of results of different prediction models

模型名称	CX3 监测点		CX8 监测点		CX13 监测点		CX14 监测点	
	MSE	MAPE	MSE	MAPE	MSE	MAPE	MSE	MAPE
本文模型	0.07	2.08	0.04	2.03	0.04	2.07	0.05	2.09
SVM 模型	0.34	3.85	0.41	3.64	0.46	3.88	0.51	3.79
GM (1, 1) 模型	0.40	3.45	0.38	3.72	0.45	3.51	0.47	3.49

3 结论

通过对基坑变形数据的分解、重构处理,并经 AM-CRU-MLR 模型预测,得出如下结论:

(1) 在基坑变形数据的分解、重构过程中,得出 EEMD-SE 模型能有效将基坑变形数据分解为变形项和不确定变形项,分解效果较好。

(2) AM-CRU-MLR 模型基坑变形预测,在实例中不仅具有较高的预测精度,还具较优的稳健性。

参 考 文 献

- [1] 钟俊辉,尹培林,滕超,等.福州软土地区地铁车站基坑墙体变形特性分析[J].地下空间与工程学报,2018,14(增刊2):821-827.
- [2] 刘念武,陈奕天,龚晓南,等.软土深开挖致地铁车站基坑及邻近建筑变形特性研究[J].岩土力学,2019,40(4):1515-1525,1576.
- [3] 周勇,叶炜钠,高升.兰州地铁某车站深基坑开挖变形特性分析[J].岩土工程学报,2018,40(增刊1):141-146.
- [4] 郭健,陈健,胡杨.基于小波智能模型的地铁车站基坑变形时序预测分析[J].岩土力学,2020,41(增刊1):299-304.
- [5] 李柏佚,王桂林,袁军.基于关联监测点数据的非线性变形预测模型[J].振动与冲击,2021,40(8):124-130.
- [6] 王景春,宋培林,王炳华,等.基于 EMD-PSO-ELM 的基坑变形时序序列预测研究[J].铁道标准设计,2020,64(9):103-108.
- [7] 侯回位,郑东健,刘永涛,等.基于 EEMD-SE-LSTM 的混凝土坝变形监测模型[J].水利水电科技进展,2022,42(1):61-66.
- [8] 张倩玉,严冬梅,韩佳彤.结合深度学习和分解算法的股票价格预测研究[J].计算机工程与应用,2021,57(5):56-64.
- [9] 马佳佳,苏怀智,王颖慧.基于 EEMD-LSTM-MLR 的大坝变形组合预测模型[J].长江科学院院报,2021,38(5):47-54.
- [10] 黄永涛,刘晓青,季威,等.HCM-PSO-GRU 组合预测模型在大坝变形预测中的应用[J].水电能源科学,2021,39(12):120-123,61.
- [11] 李其峰,杨杰,程琳,等.基于 BO-GRU 的混凝土坝变形预测模型[J].水资源与水工程学报,2021,32(4):180-184,193.
- [12] 杨庆,任超.基于 MLR-WNN 的大坝变形预测[J].水力发电,2018,44(1):102-105.
- [13] 张猛.考虑时空效应的宁波轨道交通深基坑变形特性研究[D].绍兴:绍兴文理学院,2021.