引文格式：陈凯. 基于EMD-SVR的高挡墙护坡位移预测方法[J]. 地理空间信息, 2024, 22(11): 109-112. doi:10.3969/j.issn.1672-4623.2024.11.022

基于EMD-SVR的高挡墙护坡位移预测方法

陈　凯[1]
（1. 国能包神铁路有限责任公司，内蒙古 鄂尔多斯 017000）

摘　要：针对传统基于单一模型的护坡位移预测方法预测精度较低的问题，提出了一种基于经验模态分解（EMD）和支持向量回归（SVR）的预测模型（EMD-SVR）。首先对护坡位移时间序列进行EMD分解，将原始复杂序列分解为一系列结构相对简单的本征模函数（IMF）；然后分别对每个IMF建立SVR模型进行变形趋势预测，同时提出改进的粒子群算法对SVR核参数进行全局寻优，提升预测性能；最后综合叠加各IMF预测值获得最终护坡位移变化趋势预测结果。实验结果表明，该方法比SVR、BP神经网络等单一模型的预测精度更高，最大预测误差等4项指标表现更优。

关键词：位移预测；高挡墙护坡；EMD；SVR
中图分类号：P258　　**文献标志码：**B　　**文章编号：**1672-4623（2024）11-0109-04

Displacement Prediction Method of High Retaining Wall Slope Protection Based on EMD-SVR

CHEN Kai[1]
(1. National Energy Baotou-Shenmu Railway Co., Ltd., Ordos 017000, China)

Abstract: Aiming at the low prediction accuracy of traditional slope protection displacement prediction methods based on a single model, we proposed a prediction model based on empirical mode decomposition (EMD) and support vector regression (SVR). Firstly, we performed EMD decomposition on the time series of slope protection displacement, decomposing the original complex sequence into a series of relatively simple intrinsic mode functions (IMF). Then, we established SVR model for each IMF to predict deformation trend, and proposed an improved particle swarm algorithm to globally optimize the SVR kernel parameters and improve prediction performance. Finally, we obtained the final prediction trend of slope protection displacement by comprehensively stacking various IMF prediction values. The test results show that the proposed method has higher prediction accuracy than single models such as SVR and BP neural network, and performs better in four indicators such as maximum prediction error.

Key words: displacement prediction, high retaining wall slope protection, EMD, SVR

公路和铁路建设对于一个地区的经济发展极为重要。随着我国现代化进程的不断推进，截至2022年底，我国公路通行总里程达到535万km，铁路营业里程达到15.5万km，并仍在加速发展中，“市市通高铁、县县通高速”已逐渐成为现实。由于我国山地较多，很多公路、铁路建设都会产生护坡工程。然而，在公路、铁路使用维护过程中，受地壳运行、气候变化和人类活动等因素影响，护坡会发生缓慢、持续的位移变形，当日积月累这些位移达到一定程度时将引发泥石流和山体滑坡等地质灾害，严重威胁人民群众的生命财产安全。因此，实时掌握护坡工程的位移变形状态，并对其未来发展趋势进行预测具有重要意义[1-3]。

目前国内外学者对护坡位移预测的研究可分为统计建模法和神经网络法两大类。统计建模法以自回归滑动平均模型（ARMA）、卡尔曼滤波和灰色理论等方法为代表，属于模型驱动类方法，即利用确定的数学模型表征位移时间序列的变化趋势，进而根据历史位移时间序列求解模型中的参数[4]。容静[5]等利用ARMA模型对铁路边坡位移时间序列进行建模分析，并将结果与自回归模型和滑动平均模型进行对比发现，ARMA预测精度更高；熊迪[6]等针对公路边坡工程短时位移预测问题，建立了卡尔曼滤波模型，实现了在存在测量粗差情况下对位移变形趋势的高精度预测；盛建

收稿日期：2023-08-09。
项目来源：国能包神铁路有限责任公司科技创新资助项目（GJNY-19-130）。
作者简介：陈凯（1990—），工程师，研究方向为路基、轨道线路养护维修，E-mail：Seig5okmm@163.com。

龙[7]等引入灰色理论对铁路高挡墙边坡位移数据进行分析发现，相对于ARMA和卡尔曼滤波模型，灰色理论在小样本情况下的预测性能更优。统计建模法具有算法简单、实时性高和短时预测性能好的优点，但在面对非线性、非平稳序列预测问题时，预测性能会明显下降，且不适合长时间预测应用。神经网络法是将人工智能技术与变形监测数据处理相结合而得到的数据驱动类方法，无需建立精确的数学模型，只需建立一个类似于人脑的高度复杂的非线性动态学习系统，通过对历史位移时间序列的自适应和自学习分析实现对未来变化趋势的预测[8]。张世佳[9]等将BP神经网络应用于某铁路护坡工程监测系统中，对于非线性、非平稳位移数据，获得了较高的预测精度；李胜[10]等提出了一种基于极限学习机的公路护坡变形预测方法，并针对某地铁路高挡墙护坡实际位移数据进行分析发现，该方法比ARMA和卡尔曼滤波方法的预测精度提升超过9.4%，对复杂位移时间序列的适应性更强。基于此，本文对铁路高挡墙护坡位移变形预测开展研究，采用“分解—预测—重构”的思路，提出了一种基于经验模态分解（EMD）和支持向量回归（SVR）的EMD-SVR模型。

1 算法原理

1.1 EMD分解

EMD是美籍华裔学者黄鄂于1998年提出的一种针对非线性、非平稳数据进行多尺度分析的自适应分解算法[11]。不同于传统傅里叶变换和小波变换需要预设基函数，EMD能通过“筛选”从时间序列中直接提取一系列基函数，即本征模函数（IMF），因此更能反映原始时间序列中隐含的不同尺度的内在特征。对于时间序列 $x(t)$，利用EMD对其进行分解，进而获取IMF的具体步骤为：①算法初始化，定义过程变量 $r(t)$，并令 $r(t)=x(t)$；②计算上包络函数 $r_{\max}(t)$，遍历搜索 $r(t)$ 中所有局部极大值，并利用三阶样条函数对其进行插值，获得 $r(t)$ 的 $r_{\max}(t)$；③计算下包络函数 $r_{\min}(t)$，遍历搜索 $r(t)$ 中所有局部极小值，并利用三阶样条函数对其进行插值，获得 $r(t)$ 的 $r_{\min}(t)$；④计算瞬时包络函数 $m(t)$，计算 $r_{\max}(t)$、$r_{\min}(t)$ 的算术平均值，记为瞬时包络函数 $m(t)=(r_{\max}(t)+r_{\min}(t))/2$；⑤计算IMF，从 $r(t)$ 中减去 $m(t)$，并令 $r(t)=r(t)-m(t)$，判断当前 $r(t)$ 是否满足以下两个成为IMF函数的条件，即 $r(t)$ 中过零点的个数与极值点的个数相等或相差为1和 $r(t)$ 的 $m(t)$ 均值为0，若满足上述条件，则转至步骤⑥，否则重复步骤②~④，直至 $r(t)$ 成为IMF；⑥迭代提取IMF，得到第一个IMF（imf_1）后，从原始时间序列中减去该IMF，即 $x(t)-\mathrm{imf}_1$，将其作为新的过程变量 $r(t)$，对步骤②~⑤进行重复迭代，依次获得剩余IMF，直至连续两次迭代得到的信号间差值小于 10^{-3}，算法终止。此时，原始时间序列的EMD分解为：

$$x(t)=\sum_{i=1}^{L}\mathrm{imf}_i+r_L \tag{1}$$

式中，imf_i 为第 i 个IMF，$i=1,2,\cdots,L$，L 为分解得到的IMF个数；r_L 为余项。

1.2 SVR

SVR是一种基于结构风险最小化准则的贝叶斯统计学习方法，通过核函数将低维空间中的复杂非线性问题映射到高维空间，使其成为高维空间中的线性问题，从而有效避免机器学习中的“过拟合”和“维数灾难”，在面对小样本、非线性数据分析时能比传统线性模型和神经网络模型表现出更明显的优势。因此，其被广泛应用于矿区边坡，公路、铁路护坡工程等位移变形预测领域，并取得了一系列研究成果。

对于EMD分解得到的 imf_i，利用SVR对其进行建模预测，则有：

$$y=\boldsymbol{\omega}^{\mathrm{T}}\times\varphi(\mathrm{imf}_i)+e \tag{2}$$

式中，y 为SVR预测值；$\varphi(\cdot)$ 为非线性映射函数，用于将 imf_i 映射到高维空间；e 为预测值与真实值之间的偏差；$\boldsymbol{\omega}$ 为权值。

为求解 $\boldsymbol{\omega}$，通常采用拉格朗日乘子对式（2）进行转化，将其转变为式（3）所示优化问题：

$$\begin{cases}\max\left[\begin{array}{l}\displaystyle\sum_{k=1}^{L}\left(\eta_k-\eta_k^*\right)y_k\\ \displaystyle-\frac{1}{2}\sum_{k=1}^{L}\sum_{j=1}^{L}\left(\eta_k-\eta_k^*\right)K\left(\mathrm{imf}_i,\mathrm{imf}_j\right)\\ \displaystyle-\sum_{k=1}^{L}\left(\eta_i+\eta_i^*\right)e\end{array}\right]\\ \text{s.t.}\ \displaystyle\sum_{k=1}^{L}\left(\eta_k-\eta_k^*\right)=0\end{cases} \tag{3}$$

$$K\left(\mathrm{imf}_k,\mathrm{imf}_j\right)=\exp\left[-\frac{\left\|\mathrm{imf}_k-\mathrm{imf}_j\right\|^2}{2\delta^2}\right] \tag{4}$$

式中，η_k、η_k^* 为拉格朗日乘子；$K\left(\mathrm{imf}_k,\mathrm{imf}_j\right)$ 为SVR核函数；δ 为高斯核参数。

利用梯度下降法对式（3）进行求解，从而得到SVR回归模型为：

$$f\left(\mathrm{imf}_k\right)=\sum_{l=1}^{L}\left(\eta_k-\eta_k^*\right)K\left(\mathrm{imf}_k,\mathrm{imf}_l\right)+e \tag{5}$$

式中，imf_l 为第 l 个IMF，$l=1,2,\cdots,L$。

1.3　IPSO-SVR

SVR模型的预测精度受核参数 δ 取值影响较大，目前常用交叉验证法对其进行寻优。然而，交叉验证法存在运算量大、实时性差等问题。粒子群算法（PSO）[12]是一种启发式优化算法，具有算法简单、实时性高的优点，但因其采用固定惯性因子将导致全局优化能力减弱，易陷入局部极小值。因此，本文提出了一种指数迭代步长的改进PSO算法（IPSO）对SVR核参数进行全局寻优，从而提升预测性能。

PSO算法由自然界中鸟群觅食过程抽象而来，将鸟群中的每个个体抽象为一个具有速度 $\boldsymbol{V}=\left[v^1,v^2,\cdots,v^D\right]^{\mathrm{T}}$ 和位置 $\boldsymbol{X}=\left[x^1,x^2,\cdots,x^D\right]^{\mathrm{T}}$ 的粒子，假设第 i 个粒子觅食过程中经历的最优位置（离食物最近的位置）为 $\boldsymbol{P}_i=\left[p_i^1,p_i^2,\cdots,p_i^D\right]^{\mathrm{T}}$，整个种群觅食过程中经历的最优位置为 $\boldsymbol{P}_g=\left[p_g^1,p_g^2,\cdots,p_g^D\right]^{\mathrm{T}}$，PSO算法则根据式（6）对每个粒子的速度和位置进行更新，即

$$\begin{cases} v_i^{d+1}=w\times v_i^d+c_1r_1\left(p_i^d-x_i^d\right)+c_2r_2\left(p_g^d-x_i^d\right) \\ x_i^{d+1}=x_i^d+v_i^d \end{cases} \tag{6}$$

式中，r_1、r_2 为模型中的随机量，取值范围为 $[0,1]$；c_1、c_2 为非负的加速因子；w 为惯性因子，通常为[0,1]的固定值。

由式（6）可知，w 与模型的收敛能力密切相关，取值越大，模型的全局搜索能力越强，开始迭代时收敛速度较快，但在接近最优解时会出现振荡现象；反之，取值越小，模型的局部搜索能力越强，在最优解附近的搜索精度越高，但开始迭代时的收敛速度较慢。因此，本文将 w 的取值与迭代次数关联，提出指数形式的惯性因子，即

$$w=w_{\min}+\left(w_{\max}-w_{\min}\right)\exp\left(-\frac{t^2}{\max_t^2}\right) \tag{7}$$

式中，t 为当前迭代次数；$\max_t$ 为最大迭代次数；$w_{\min}$、$w_{\max}$ 分别为 w 取值的最小和最大值。

指数形式的惯性因子使IPSO算法在迭代初期能够快速向最优解附近逼近，随着迭代的进行 w 的取值近乎呈线性下降，从而有利于后续在最优解附近进行高精度搜索。

2　EMD-SVR预测模型

利用EMD-SVR模型对护坡位移变形时间序列变化趋势进行预测，其中数据预处理主要实现错误数据剔除、缺失数据补全等操作，本文采用三阶多项式插值法对缺失数据进行补全；EMD分解即利用EMD算法对预处理后的位移时间序列进行自适应分解，将复杂位移时间序列分解为一系列结构简单的IMF；IPSO-SVR预测即分别对每个IMF建立最优IPSO-SVR模型，实现变形趋势预测；预测结果综合即根据式（1）对各IMF的预测结果进行综合叠加，从而获得原始序列位移变形趋势。

3　实验与结果分析

3.1　实验数据

为验证EMD-SVR模型的预测性能，本文采用包神铁路神瓷线CK0+600+CK2+580高挡墙护坡监测系统记录的实际位移数据开展实验。该段坡体地层下部为厚层砂岩，上层靠近顶部为薄层砂岩夹泥岩，且风化较严重，雨水下渗至层面，层面摩擦力减小，形成了潜在薄弱面；后期雨水下渗、列车震动，加之护坡上部公路上车辆荷载，岩层沿着薄弱面向下滑动，在护坡处形成了鼓胀、裂缝。随着坡体稳定性的逐渐降低，易沿薄弱面发生滑动形成滑坡，影响铁路的安全运营。

根据边坡的具体地质结构特征，为更好地分析边坡位移数据，充分采集边坡体地表、地下和环境信息，边坡共布设5个监测点位、1个预警广播站、1个预警信息发布屏。采用2020年1月—2021年12月的位移变形监测数据，采样间隔为1周，共获得96期样本数据。整个变形监测数据变化曲线见图1，可以看出，该护坡位移时间序列表现出较明显的非线性、非平稳特征，且波动较大，给位移变形趋势预测带来了较大挑战。实验以Matlab R2018a为数据处理与算法实现的软件平台，以联想ThinkPadX1Carbon为硬件平台，主要配置为处理器I7-7200u、主频2.4 GHz、内存16 GHz、操作系统Windows10。为了对EMD-SVR模型的位移预测性能进行定量评估，实验采用最大预测误差 $e_{\max}$、最小预测误差 $e_{\min}$、误差均值 e_{mean} 和均方根误差 e_{std} 进行评价。

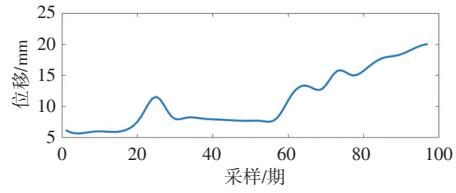


图1　实际变形曲线

3.2　实验结果

利用EMD对位移时间序列进行EMD分解的结果见图2，经过EMD分解后，原始序列被分解为3个IMF和1个余项，每个IMF的起伏变化比原始序列简单平滑，变化趋势更容易预测；从IMF1中能看到较平滑且明显的上升趋势，表明IMF1获取了原始序列中隐含的趋势性信息；从IMF2中能看到局部接近正余弦函数的周期性，表明IMF2获取了原始序列中隐含的周期

性信息；IMF3波形变化较剧烈，表明IMF3获取了原始序列中隐含的波动性信息；余项序列变化杂乱且幅度较小，表明余项主要为原始序列中的噪声分量。

完成EMD分解后，利用SVR分别对每个IMF分量进行建模预测。利用IPSO对SVR核参数进行全局寻优的参数变化曲线以及在相同条件下采用传统PSO算法进行参数寻优的核函数取值变化曲线见图3，可以看出，IPSO只需约8次迭代即可实现收敛，而PSO由于采用较小的固定惯性因子($w=0.3$)，收敛速度较慢，需要14次迭代才最终收敛。

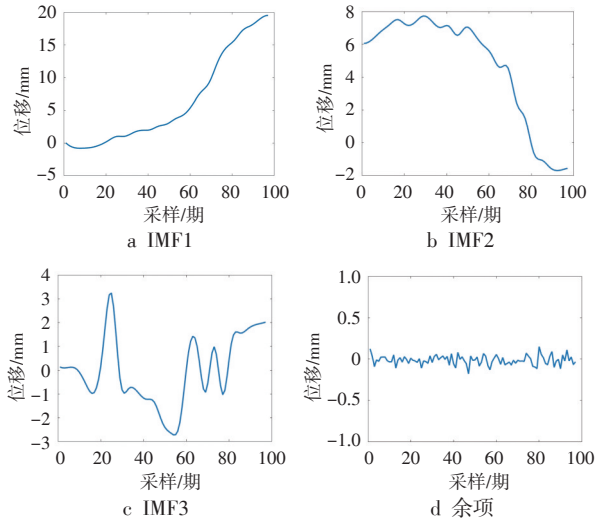


图2 EMD分解结果

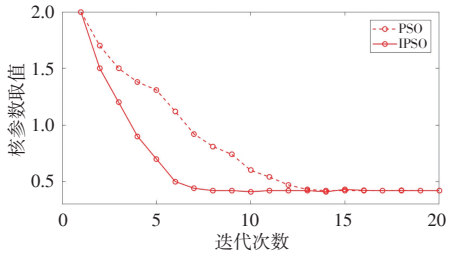


图3 SVR核参数变化曲线

利用EMD-SVR模型对位移时间序列进行预测得到的预测结果和对应的预测误差曲线，以及在相同条件下采用SVR和BP神经网络模型得到的预测结果和误差曲线见图4。不同方法预测结果的定量对比分析见表1，可以看出，相较于SVR和BP神经网络模型，EMD-SVR模型对每一期观测样本的预测结果均更接近于实际位移值，且在e_{max}、e_{min}、e_{mean}和e_{std}指标方面均有较大提升。

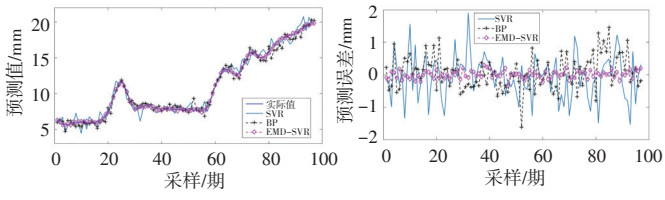


图4 不同方法预测结果

表1 不同方法预测结果

指标	SVR模型	BP神经网络模型	EMD-SVR模型
e_{max}	1.93	1.42	0.32
e_{min}	0.62	0.37	0.03
e_{mean}	0.89	0.77	0.08
e_{std}	1.35	1.14	0.78

4 结 语

公路、铁路护坡位移受多种因素影响，变形趋势较复杂，传统基于单一模型的预测方法精度有限，难以满足实际应用需求。本文基于“分解—预测—重构”的思路，将EMD和SVR相结合构成EMD-SVR预测模型，一方面EMD分解获得的IMF比原始位移序列结构简单，对后续预测模型复杂度要求低，有利于提升预测精度；另一方面经过IPSO优化后的SVR模型收敛速度更快，预测精度更高。实验结果表明，本文所提模型的预测精度更高，更能适应实际工程应用场景。

参考文献

[1] 冯杭华,胡俊凯. 基于二次指数平滑和Elman网络的滑坡位移预测[J]. 地理空间信息,2022,20(3):103-105

[2] 冯子帆,成枢,董娟. 残差修正的GM(1,1)模型在滑坡位移预测中的应用[J]. 地理空间信息,2019,17(9):113-115

[3] 谢勇. 建筑桩基础状态对邻近基坑稳定性影响分析[D]. 西安:长安大学,2019

[4] 王玉斌. 地震降雨耦合作用下铰链式砌块生态边坡稳定性研究[D]. 南京:东南大学,2017

[5] 容静,刘立龙,康昊华,等. 基于方差补偿自适应Kalman滤波的ARMA与PSO-SVM模型变形预测[J]. 大地测量与地球动力学,2018,38(7):689-694

[6] 熊迪,吴浩,杨剑,等. 回归分析与抗差卡尔曼滤波协同下大型边坡短期变形的预测方法[J]. 金属矿山,2019(4):163-167

[7] 盛建龙,张鑫,胡斌. 基于GM(1,1)模型的老鹰嘴边坡位移变形预测[J]. 矿业研究与开发,2022,42(11):82-87

[8] 肖玉辉,段劲,胡静轩,等. 平接缝预制块拱形骨架护坡应力位移监测研究[J]. 公路工程,2017,42(1):170-173

[9] 张世佳,饶运章,王文涛,等. GA-BP神经网络模型在稀土矿边坡位移监测中的应用[J]. 有色金属科学与工程,2022,13(1):115-121

[10] 李胜,韩永亮,高宏,等. 边坡变形的LMD-ELM多尺度预测模型研究[J]. 中国安全科学学报,2015,25(11):16-21

[11] 鲍怀谦,魏永长,王金瑞,等. EMD-CSF在滚动轴承早期微弱故障诊断中的应用[J]. 噪声与振动控制,2022,42(6):105-110

[12] 王力,贾欣雨. 基于PSO-PF-SVM的模拟电路故障诊断[J]. 江苏大学学报(自然科学版),2023,44(2):221-228