引文格式：董延东. 利用改进水循环优化SVR的边坡变形预测[J]. 地理空间信息, 2024, 22(10): 46-49. doi:10. 3969/j.issn. 1672-4623.2024.10.012

利用改进水循环优化SVR的边坡变形预测

董延东[1]
（1. 国能运输技术研究院有限责任公司，北京 100080）

摘　要：边坡变形与地质活动，气候变化以及人工切坡等众多因素相关，是一种典型的非线性、非平稳随机过程，传统边坡变形预测方法存在预测精度低和泛化能力弱等问题。提出一种基于改进水循环算法（improved water cycle algorithm，IWCA）优化支持向量回归（suppor vector regression，SVR）的边坡变形预测方法（IWCA-SVR）。SVR利用核函数将低维空间中的非线性边坡位移量数据映射到高维空间进行建模分析，不仅能够获得较高的预测精度，同时具有较强的泛化能力。由于SVR核参数和惩罚因子对预测性能影响较大，提出IWCA算法对其进行全局寻优，提升预测性能。最后将所提IWCA-SVR方法与粒子群优化的SVR（PSO-SVR）和极限学习机（ELM）等方法进行对比，结果表明IWCA-SVR在平均相对误差和均方根误差两项指标方面分别提升超过55.8%和54.9%，并且具有更强的泛化能力。

关键词：铁路边坡；位移预测；水循环算法；支持向量回归；泛化能力
中图分类号：P258　　**文献标志码：**B　　**文章编号：**1672-4623（2024）10-0046-04

Slope Deformation Prediction Based on IWCA-SVR

DONG Yandong[1]
(1. Guoneng Transportation Technology Research Institute Co., Ltd., Beijing 100080, China)

Abstract: Slope deformation is related to many factors such as geological activity, climate change and artificial slope cutting. Slope deformation is a typical nonlinear and non-stationary stochastic process. The traditional slope deformation prediction model has the problems of low prediction accuracy and weak generalization ability. We proposed a slope deformation prediction method based on improved water cycle algorithm optimized support vector regression (IWCA-SVR). SVR uses kernel function to map nonlinear slope displacement data in low-dimensional space to high-dimensional space for modeling and analysis, which can not only obtain high prediction accuracy, but also have strong generalization ability. SVR kernel parameters and penalty factors have a great impact on prediction performance. So we used IWCA algorithm to optimize it globally to improve prediction performance. Finally, we compared IWCA-SVR method with particle swarm optimization SVR and limit learning machine. The results show that the average relative error and root mean square error of IWCA-SVR have increased by more than 55.8% and 54.9% respectively, and it has stronger generalization ability.

Key words: railway slope, displacement prediction, water cycle algorithm, SVR, generalization ability

我国属于多山国家，大部分的铁路建设都会产生边坡。边坡上的土体或岩体受河流冲刷，地质活动，雨水浸泡以及人工切坡等因素影响，坡体应力状态产生变化，当滑动力或倾覆力达到甚至超过抗滑力或抗倾覆力而失去平衡时，边坡会发生位移、变形、滑动甚至坍塌等地质灾害，给工农业生产以及人民群众的生命财产安全造成巨大损失。因此及时准确地掌握边坡变形状态并对其未来变形趋势进行预测具有重要意义[1-2]。

近年来，随着人工智能技术的发展，将其与变形监测数据相结合得到的边坡变形智能预测方法引起了众多学者的广泛关注[3-4]。文献[5]针对大型边坡短期变形预测问题，提出一种抗差卡尔曼滤波模型实现了对粗差存在情况下的边坡变形高精度预测；文献[6]将灰色理论与自动回归相结合建立GM-AR非线性模型，获得了比单一GM和AR模型更高的预测精度；文献[7]将小波神经网络引入边坡变形预测领域，并利用遗传算法对其进行优化，预测结果的均方根误差为0.68 mm；文献[8]提出一种联合使用局部均值分解和极限学习机（ELM）的多尺度变形预测模型，将其应用于甘肃某地边坡变形数据的实验结果表明，该方法在运行速度和预测精度方面表现优良。

支持向量回归（SVR）是以机器学习理论为基础，基于结构风险最小化准则的回归模型，在解决小样本，高维度，非线性数据建模问题时表现出了特有

收稿日期：2023-04-20。
项目来源：国家能源集团科技创新项目(GJNY-20-231)；国能朔黄铁路公司科技创新项目（[2021]367）。
作者简介：董延东（1982—），本科，高级工程师，研究方向为铁路运输，E-mail：Fdeignaity@163.com。

的优势，因此被广泛应用于矿区边坡，公路边坡以及铁路边坡等众多边坡变形预测领域，并取得了一系列研究成果[9-11]。然而SVR在输入值与预测值之间建立非线性映射关系时，模型中核参数和惩罚因子的选取对结果影响较大，目前常用的交叉验证法和粒子群优化法存在计算复杂，实时性差和易陷入局部极值等问题[12]。为此，本文提出一种改进的水循环优化算法(improved water cycle algorithm, IWCA)对SVR进行优化，利用IWCA的全局寻优能力自动确定SVR的最优核参数和惩罚因子。在此基础上，提出IWCA-SVR模型进行铁路边坡变形预测，并利用工程实际数据对所提方法的预测精度和泛化能力进行验证。

1　模型描述

1.1　SVR模型

对于边坡变形时间序列 x，利用SVR对其进行建模预测可以用下式表示[9]：

$$y=\omega^{\mathrm{T}}\cdot\varphi(x)+e \tag{1}$$

式中，y 为模型预测值；ω 为权值；$\varphi(\cdot)$ 为非线性映射函数；e 为预测值与实际值之间的偏移量。为了对模型中的权值 ω 进行求解，采用拉格朗日乘子将式(1)转化为如下式(2)所示优化问题：

$$\begin{cases}\max\left[\sum\limits_{k=1}^{l}\left(\eta_k-\eta_k^*\right)y_k-\frac{1}{2}\sum\limits_{k=1}^{l}\sum\limits_{j=1}^{l}\left(\eta_k-\eta_k^*\right)K\left(x_k,x_j\right)-\sum\limits_{k=1}^{l}\left(\eta_i+\eta_i^*\right)e\right]\\ s.t.\ \sum\limits_{k=1}^{l}\left(\eta_k-\eta_k^*\right)=0\end{cases} \tag{2}$$

式中，η_k 和 η_k^* 为拉格朗日乘子；$K\left(x_k,x_j\right)$ 为高斯核函数，其具体形式为：

$$K\left(x_k,x_j\right)=\exp\left[-\frac{\left\|x_k-x_j\right\|^2}{2\delta^2}\right] \tag{3}$$

式中，δ 为核函数。利用梯度下降法对式（2）所示优化问题进行求解可以得到最终的SVR回归模型为：

$$f\left(x_k\right)=\sum_{k=1}^{l}\left(\eta_k-\eta_k^*\right)K\left(x_k,x_l\right)+e \tag{4}$$

1.2　IWCA优化算法

SVR模型的预测性能与核参数 δ 和偏移量 e 的取值密切相关，目前常用交叉验证法和PSO算法对其进行寻优，然而交叉验证法运算量大且实时性差，PSO容易陷入局部极小值。WCA是一种启发式优化算法，通过对自然界中溪流和河流等流入海洋的过程进行抽象而得到，相对于PSO，GA和FOA等优化算法具有更高的运算效率和更强的全局寻优能力。因此，本文将WCA引入SVR模型，利用WCA对核参数 δ 和偏移量 e 自动寻优。同时针对WCA采用固定迭代步长导致的振荡现象，提出一种指数迭代IWCA模型，提升参数寻优能力。

IWCA初始种群由海洋（Sea），河流（River）和溪流（Stream）三类个体组成。其中，Sea为当前种群中的适应度函数最小的最优个体，River为当前种群中适应度函数较小的次优个体，剩余适应度函数较大的交叉个体为Stream[13]。初始种群可以表示为：

$$\begin{bmatrix}\mathrm{Sea}\\ \mathrm{River}_1\\ \mathrm{River}_2\\ \vdots\\ \mathrm{Stream}_{N_{\mathrm{sr}}+1}\\ \mathrm{Stream}_{N_{\mathrm{sr}}+2}\\ \vdots\\ \mathrm{Stream}_{N_{\mathrm{pop}}}\end{bmatrix}=\begin{bmatrix}x_1^1 & x_2^1 & \cdots & x_D^1\\ x_1^2 & x_2^2 & \cdots & x_D^2\\ \vdots & \vdots & \ddots & \vdots\\ x_1^{N_{\mathrm{pop}}} & x_2^{N_{\mathrm{pop}}} & \cdots & x_D^{N_{\mathrm{pop}}}\end{bmatrix} \tag{5}$$

式中，N_{stream} 为种群中Stream数量；N_{sr} 为种群中Sea和River的数量之和。IWCA迭代过程根据自然界中Stream流向River和Sea，River流向Sea这一准则对不同个体的位置进行更新，迭代方程如式（6）所示：

$$\begin{cases}X_{\mathrm{strem}}^{t+1}=X_{\mathrm{strem}}^{t}+C\times\left(X_{\mathrm{river}}^{t}-X_{\mathrm{stream}}^{t}\right)\\ X_{\mathrm{strem}}^{t+1}=X_{\mathrm{strem}}^{t}+C\times\left(X_{\mathrm{sea}}^{t}-X_{\mathrm{stream}}^{t}\right)\\ X_{\mathrm{river}}^{t+1}=X_{\mathrm{river}}^{t}+C\times\left(X_{\mathrm{sea}}^{t}-X_{\mathrm{river}}^{t}\right)\end{cases} \tag{6}$$

式中，$X_{\mathrm{stream}}^{t}, X_{\mathrm{river}}^{t}$ 和 X_{sea}^{t} 分别为Stream、River和Sea的位置；右上标 t 为当前迭代次数；C 为迭代步长。WCA将 C 设置为[0,1]范围内的固定值，导致在迭代后期逼近最优解时出现振荡迭代现象。为了解决该问题，IWCA将迭代步长与迭代次数关联，提出式（7）所示指数迭代步长：

$$C_t=C_0+\left(C_{\max}-C_{\min}\right)\exp\left[-\frac{t^2}{\left(\max_it\right)^2}\right] \tag{7}$$

式中，C_0 为初始迭代步长；$C_{\max}$ 为迭代步长的最大值；$C_{\min}$ 为迭代步长的最小值；$\max_it$ 为最大迭代次数。可以看出，通过将迭代步长与迭代次数关联，使初期的迭代步长较大从而获得较快的搜索速度，而随着迭代的进行，迭代步长逐渐减小从而获得更高的搜索精度。

每次迭代后，IWCA重新计算Stream、River和Sea个体的适应度函数，若Stream的适应度函数小于

其汇入的 River 的适应度函数，则将两者的位置交换，同样，若 River 的适应度函数小于其汇入的 Sea 的适应度函数，则将两者的位置交换。迭代终止时，Sea 的位置即为 IWCA 全局最优解，对应的参数值即为 SVR 的最优核参数 δ^* 和偏移量 e^*。

2 IWCA-SVR预测模型步骤

利用所提 IWCA 优化的 SVR 预测模型(IWCA-SVR)对边坡变形趋势进行预测的流程包含以下几个步骤：

1）初始化 IWCA 算法，设置 IWCA 迭代次数，种群规模以及个体数量等参数；

2）确定 SVR 核参数和偏移量的取值区间，即 IWCA 参数优化范围；

3）确定 IWCA 适应度函数为预测样本均方根误差；

4）计算 Stream 、 River 和 Sea 个体的适应度函数值，并获得种群当前适应度极小值；

5）对 Stream 、River 和 Sea 个体的位置进行更新；

6）重复步骤 4 和步骤 5，直到满足最大迭代次数，从而获得最优的 SVR 核参数和偏移量集合；

7）将最优集合带入 SVR 预测模型，对边坡未来变形趋势进行预测。

为了定量评估 IWCA-SVR 模型的边坡位移预测性能，定义式（8）所示均方根误差（RMSE）和式（9）所示平均相对误差（ARPE）作为指标：

$$\mathrm{RMSE}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(y_i-\bar{y}_i\right)^2} \tag{8}$$

$$\mathrm{APRE}=\frac{1}{N}\sum_{i=1}^{N}\left|y_i-\bar{y}_i\right| \tag{9}$$

式中，N 为预测样本数量；y_i 和 $\bar{y}_i$ 分别为边坡位移第 i 个样本的真实值和预测值。

3 结果与讨论

3.1 实验数据

采用某铁路在山西省内路段边坡位移数据开展实验，该路段线路出露地层主要由砂质黄土和二叠系长石石英砂岩夹泥岩组成，黄土厚度为 5~20 m，黄土层和基岩形成了坡体的土石分层面，在坡体中基岩裂隙水和入渗雨水的作用下，该土石分层面易形成软弱夹层，降低坡体的稳定性，在水分、震动等长期作用下易失稳产生溜坍、滑坡等现象。实验数据来自于高精度北斗 GNSS 接收机获得的表面位移监测数据，边坡表面共布设 8 个监测点，分别位于上行 K+208 左侧坡顶及一级台阶上，上行 K+348 左侧坡顶及一级台阶上，上行 K+468 左侧坡顶上，上行 K+483 一级台阶上，上行 K+553 一级台阶上，上行 K+568 左侧坡顶上，上行 K+618 左侧坡顶上以及上行 K+623 一级台阶上。选用上行 K+384 左坡坡顶及一级台阶上监测点 2020 年 1 月至 2020 年 12 月的 36 期变形监测，发现实际变形曲线表现出了明显的非线性和非平稳特征，给变形预测带来了挑战。

实验中，将 1~24 期数据作为训练样本集用于 IWCA-SVR 模型参数寻优，25~36 期数据作为测试样本集对 IWCA-SVR 模型的预测性能进行评估验证。

采用 MATLAB R2018a 作为仿真平台进行算法实现与数据处理，硬件平台主要指标为：处理器 I7-7200 u，主频 2.4 GHz，内存 16 GHz，操作系统 Windows10。

3.2 实验结果

图 1 给出了利用 IWCA 对 SVR 核参数和惩罚因子进行全局优化过程中适应度函数值的变化曲线，同时为了对比，图 1 中一并给出了在相同条件下分别采用传统 WCA 和 PSO2 种优化算法得到的适应度函数值变化曲线。可以看出，IWCA 只需要 7 次迭代就达到了收敛状态，而传统 WCA 由于采用固定步长，在接近最优解时出现了明显的振荡现象，经过 17 次迭代才完成收敛，PSO 算法经过 9 次迭代到达收敛状态，但是从图 1 可以看出，PSO 最终收敛于局部最优解。

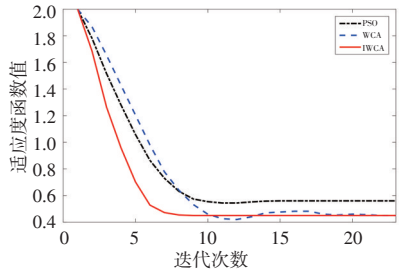


图 1 适应度函数值变化曲线

图 2 给出了利用所提 IWCA-SVR 对 25~36 期数据进行预测得到的结果，同时为了对比，图 2 中一并给出了在相同条件下分别采用 PSO-SVR 和 ELM2 种方法得到的预测结果。对图 2 所示结果进行统计得到 3 种方法的 RMSE 和 ARPE 两项指标如表 1 所示。从图 3 可以看出，对于每一个测试样本，所提 IWCA-SVR 获得的预测结果与实际变形量最为接近，预测精度最高。ELM 次之，而 PSO-SVR 由于收敛于局部最优解，其预测精度最低。从表 1 给出的计算结果可知，所提 IWCA-SVR 的 RMSE 指标相对于 PSO-SVR 和 ELM 分别提升 69.6% 和 54.9%，ARPE 指标相对于 PSO-SVR 和 ELM 分别提升 68.5% 和 55.8%，优势较为明显。

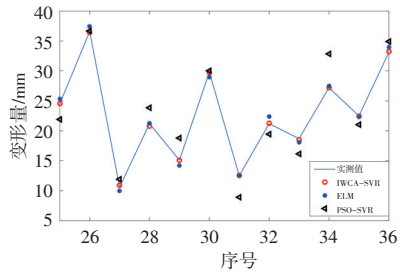


图2　不同方法预测结果

表1　不同方法预测结果

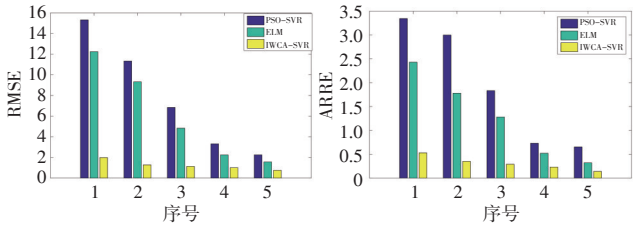
指标	PSO-SVR	ELM	IWCA-SVR
RMSE	3.32	2.24	1.01
ARPE	0.73	0.52	0.23

在实际生产生活中，由于测量设备，测量条件等的限制，很多边坡在运维过程中只有少量历史变形监测数据。这种情况下，要求变形预测模型具备小样本情况下的泛化能力，即在训练样本较少时仍能获得较高的预测精度。为了进一步验证所提IWCA-SVR模型的泛化能力，按表2构建5种不同训练和测试样本划分实验，图3给出了不同划分下所提IWCA-SVR模型和两种对比方法（PSO-SVR和ELM）的预测结果。

从图3可以看出，ELM和PSO-SVR两种方法的预测性能随训练样本数的减少而出现了较为明显的下降，当训练样本数减少至18时（序号3），2种方法预测结果的RMSE和ARPE指标相对于训练样本数为24时（序号4）下降超过100%，而所提IWCA-SVR模型在训练样本减少至12时（序号2）获得预测结果的RMSE和ARPE指标相对于训练样本数为24时（序号4）仅仅下降了不足30%，表现出了较强的泛化能力，更适合实际工程应用。

表2　不同数据集划分方式

序号	训练数据集	测试数据集
1	前6期	剩余30期
2	前12期	剩余24期
3	前18期	剩余18期
4	期24期	剩余12期
5	前30期	剩余6期



a ELM方法　　b PSO-SVR方法

图3　不同训练样本集条件下的预测结果

4　结　语

边坡变形受多种因素影响，是一种典型的非线性，非平稳随机过程。提出IWCA-SVR预测模型实现对铁路边坡变形趋势预测。得到以下结论：

1）提出的IWCA算法采用指数步长替代传统WCA的固定步长，相对于PSO算法能够获得更快的收敛速度和更高的收敛精度；

2）IWCA-SVR模型相对于PSO-SVR和ELM模型具备更高的预测精度和更强的泛化能力，更能适应边坡变形预测实际工程应用环境。

参考文献

[1] 晏晓红,宋丽,荣延祥. PSO-SVR优化模型在基坑变形监测预测中的应用[J]. 地理空间信息,2022,20(12):53-57

[2] 冯杭华. 基于SRIMA-TGM组合模型的边坡变形预测[J]. 地理空间信息,2022,20(10):98-102

[3] Wei B,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): 232-234

[4] 侯太平,杨牵动,卢雪峰,等. 基于IVDF-SVR耦合模型的边坡变形预测[J]. 人民珠江,2022,45(5):68-74

[5] 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,2019,53(4): 163-167

[6] 袁于思,冯小鹏,李勇,等. 基于PSO-DSRVM的边坡变形预测[J]. 中国地质灾害与防治学报,2023,34(1):1-7

[7] 任超,梁月吉,庞光锋,等. 经验模态分解和遗传小波神经网络法用于边坡变形预测[J]. 测绘科学技术学报,2014, 31(6):551-555

[8] 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

[9] 刘小生,秦志强. 基于相空间重构的GA-SVR组合模型边坡位移预测研究[J]. 大地测量与地球动力学,2017,37(10): 1 024-1 028

[10] 李宏俊,赵雪琼,孙瑜. 基于GPRS和SVR的滑坡灾害远程监测系统设计[J]. 微型电脑应用,2021,37(6):27-30

[11] 牛景太. 基于奇异谱分析与PSO优化SVM的大坝变形监控模型[J]. 水利水电科技进展,2020,40(6):60-65

[12] 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

[13] 陶苹睿. 基于ER-WCA算法的微电网经济运行优化研究[D]. 南昌:南昌大学,2022