

基于PSO-DSRVM的边坡变形预测

袁于思, 冯小鹏, 李 勇, 易灿灿

Prediction of mine slope deformation based on PSO-DSRVM

YUAN Yusi, FENG Xiaopeng, LI Yong, and YI Cancan

在线阅读 View online: <https://doi.org/10.16031/j.cnki.issn.1003-8035.202112032>

您可能感兴趣的其他文章

Articles you may be interested in

基于贝叶斯-粒子群算法的溜砂坡稳定性评价

Stability evaluation of sand slopes based on the Bayesian-PSO algorithm

娄超华, 田荣燕, 旺久, 孙威宇, 罗进 中国地质灾害与防治学报. 2021, 32(2): 53-59

基于BA-LSSVM模型的黄土滑坡致灾范围预测

Prediction of the disaster area of loess landslide based on least square support vector machine optimized by bat algorithm

吴博, 赵法锁, 贺子光, 段钊, 吴韶艳 中国地质灾害与防治学报. 2020, 31(5): 1-6

建房切坡条件下边坡稳定性分析

Analysis of slope stability under the condition of cutting for house-building

杜显祥, 房浩, 曹佳文 中国地质灾害与防治学报. 2020, 31(5): 40-47

基于可靠度理论的阻滑键加固渣土边坡多目标优化设计方法

A method for reliability-based multi-objective optimization design of sliding resistant components in construction waste slope

王盈, 曾江波, 姚文敏, 李长冬 中国地质灾害与防治学报. 2020, 31(5): 88-97

基于支持向量机的膨胀土胀缩等级预测

Predicting of swelling-shrinking level of expansive soil using support vector regression

周苏华, 周帅康, 张运强, 聂志红, 雷瑜 中国地质灾害与防治学报. 2021, 32(1): 117-126

基于Mein-Larson入渗模型的凹形边坡稳定性分析

Stability analysis of concave slope based on Mein-Larson infiltration model

胡庆, 吴益平, 苗发盛, 张龙飞, 李麟玮 中国地质灾害与防治学报. 2021, 32(6): 26-35



关注微信公众号, 获得更多资讯信息

DOI: 10.16031/j.cnki.issn.1003-8035.202112032

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.

YUAN Yusi, FENG Xiaopeng, LI Yong, et al. Prediction of mine slope deformation based on PSO-DSRVM[J]. The Chinese Journal of Geological Hazard and Control, 2023, 34(1): 1-7.

基于 PSO-DSRVM 的边坡变形预测

袁于思¹, 冯小鹏¹, 李 勇¹, 易灿灿²

(1. 中铁武汉电气化局集团第一工程有限公司, 湖北 武汉 430074;

2. 武汉科技大学, 湖北 武汉 430081)

摘要: 为了建立高精度的边坡位移预测模型, 文章采用基于粒子群优化(PSO)的双稀疏相关向量机(DSRVM)建立边坡稳定性和影响因素之间的非线性关系。双稀疏相关向量机是在变分和相关向量机(RVM)框架下提出的一种多核组合优化的方法, 相比于RVM和其他多核学习方法, DSRVM不仅有更少的训练时间, 并且能够得到更高的预测精度。由于DSRVM的核参数对预测效果的影响较大, 文章采用粒子群算法实现多个核参数的优化选取并应用于边坡位移预测。最后将本文提出的基于粒子群优化的双稀疏相关向量机(PSO-DSRVM)预测结果与极限学习机(ELM)和小波神经网络(WNN)预测结果进行对比, 通过均方根误差(RMSE)、复相关系数(R^2)和平均相对预测误差(ARPE)进行评价, 验证了PSO-DSRVM模型在边坡变形预测上的可行性。

关键词: 边坡稳定; 位移预测; 粒子群优化算法; 双稀疏相关向量机

中图分类号: P642.22

文献标志码: A

文章编号: 1003-8035(2023)01-0001-07

Prediction of mine slope deformation based on PSO-DSRVM

YUAN Yusi¹, FENG Xiaopeng¹, LI Yong¹, YI Cancan²

(1. China Railway Wuhan Electrification Bureau Group Co.Ltd., Wuhan, Hubei 430074, China;

2. Wuhan University of Science and Technology, Wuhan, Hubei 430081, China)

Abstract: In order to establish a high-precision prediction model of mine slope displacement, Doubly Sparse Relevance Vector Machine (DSRVM) based on Particle Swarm Optimization (PSO) was used to establish the nonlinear relationship between slope stability and influencing factors in this paper. DSRVM was a multi-core combinatorial optimization method, which was proposed under the framework of variational and Relevance Vector Machines (RVM). Compared with RVM and other multiple-kernel learning methods, DSRVM not only had less training time, but also can obtained higher prediction accuracy. Aiming at the influence of the parameter's selection of DSRVM on the final prediction effect, the optimal multiple kernel parameters was determined by PSO algorithm to be used in the mine slope displacement prediction. Compared the computational results of DSRVM with Extreme Learning Machine (ELM) and Wavelet Neural Network (WNN), the feasibility of PSO-DSRVM in slope deformation prediction was verified by the evaluation indicators such as RMSE, R^2 and ARPE.

Keywords: slope stability; displacement prediction; particle swarm optimization algorithm; doubly sparse relevance vector machine

收稿日期: 2021-12-27; 修订日期: 2022-04-18

投稿网址: <https://www.zgdzzhyfzxb.com/>

基金项目: 国家自然科学基金项目(51805382); 湖北省安全生产专项资金科技项目(KJZX202007003)

第一作者: 袁于思(1974-), 男, 湖北通山人, 本科, 主要从事结构健康监测的研究。E-mail: 1197693411@qq.com

通讯作者: 易灿灿(1989-), 男, 湖北松滋人, 博士, 主要从事结构健康监测的研究。E-mail: zhiliwangmr@163.com

0 引言

边坡变形是现今边坡普遍存在的现象,世界各地每年都会发生山体滑坡,这给整个经济和社会造成灾难性的后果。我国对于各种边坡安全高度重视,出台了一系列的规范性文件,比如《露天煤矿边坡变形监测技术规范》、《建筑边坡工程技术规范》等。2021年8月5日,湘西自治州某工地在对其公路边坡进行安全检测时,突发边坡坍塌,造成4人死亡。边坡坍塌已经危害了人民的生命财产安全,而边坡位移能够准确反映边坡形变量,是边坡失稳中最直观的体现。因此做好边坡变形预测和准确掌握边坡变形的趋势,这对降低灾害所带来的损失具有重要的意义。

近年来,随着智能计算技术的不断发展,各种机器学习方法被广泛应用于边坡位移预测。由于没有复杂的地质实体,智能计算方法如极限学习机(ELM)、线性回归模型、灰色预测模型、支持向量机、BP神经网络和相关向量机^[1-5]受到了很多学者的青睐。韩连生等^[6]利用灰色理论模型预测露天矿山边坡的位移。史笑凡等^[3]提出 SVM 并结合实测数据对边坡垂直位移方向率进行回归预测,得到了高精度的预测结果。由于 SVM 中存在着输入向量权值无差别、最优训练组合难以确定等问题,李麟玮等^[7]将灰狼优化算法(GWO)、最大信息系数(MIC)和 SVM 结合起来并用于边坡位移预测,得到了较高的预测精度。Liu 等^[8]利用长短时记忆神经网络(LSTM)、随机森林(RF)和门控递归单元(GRU)对三个不同的三峡库区边坡变化做出了预报,并自适应选取高精度的预测模型。罗亦泳等^[9]结合 RVM 与差分进化优化算法,可以较精准预测边坡安全系数。江婷等^[10]提出了支持向量机-小波神经网络预测模型并应用于岩土边坡位移预测,验证了该模型的可靠性和稳定性。然而上述方法或多或少存在着不足,比如模型能力过于依赖数据样本、泛化能力较弱等。因此,提出高精度、简单的边坡位移预测模型是很有必要的。

RVM 是 Tipping ME^[11]在贝叶斯理论、极大似然估计以及先验分布等理论基础上提出的一种机器学习方法,在保持与 SVM 精度一样的条件下,RVM 核函数计算时间明显减少。而本文采用的 DSRVM 是基于 RVM 提出来的改进版本,DSRVM 通过联合样本数据中的稀疏相关核集合和稀疏相关性向量集合来建立模型^[12]。与相关向量机 RVM 相比,DSRVM 有更高的稀疏性以及更高效的 EM 算法,用于学习相关核和相关向量,所以它的训练速度更快,预测精度更高。由于

DSRVM 需要正确的核参数才能保证其预测精度,因此本文采用了粒子群优化(PSO)算法来获取最优核参数,从而进一步提升模型的泛化能力。

综上所述,针对上述传统预测方法的局限和不足,本文提出了基于粒子群优化的双稀疏相关向量机用于边坡位移预测,通过均方根误差、复相关系数和平均相对误差(ARPE)这3个评价指标验证模型的有效性。工程实测数据表明,PSO-DSRVM 模型预测样本的平均相对误差达到0.017,精度远远高于极限学习机(ELM)模型和小波神经网络(WNN)模型的预测精度,边坡位移预测的精度得到明显的提升。

1 理论描述

1.1 RVM 模型

假设训练样本为 $G = \{(x_i, t_i)\}_{i=1}^N$, 其中 $\{x_i\}_{i=1}^N$ 代表输入样本矢量, N 代表样本总数, $t = \{t_1, t_2, \dots, t_N\}^T$ 是相对应的目标值。因此 RVM 的模型输出的基本形式为:

$$y(x, w) = \sum_{i=1}^N w_i K(x, x_i) + w = \varphi(x)w \quad (1)$$

式中: w ——权值向量;

$K(x, x_i)$ ——核函数;

$\varphi(x)$ ——核矩阵。

假设 t_i 服从均值 $y(x_i, w)$, 方差为 σ^2 的正态分布, 则用概率表示为:

$$p(t_i) = N(t_i | y(x_i : w), \sigma^2) \quad (2)$$

样本的似然函数为:

$$\begin{aligned} p(t | w, \sigma^2) &= \prod_{i=1}^N N(t_i | y(x_i : w), \sigma^2) \\ &= (2\pi\sigma^2)^{-\frac{N}{2}} \exp \left\{ -\frac{\|t - \Phi w\|^2}{2\sigma^2} \right\} \end{aligned} \quad (3)$$

条件概率为:

$$\begin{aligned} P(t_* | t) &= \int P(t_* | w, \sigma^2) p(w, \sigma^2 | t) dw d\sigma^2 \\ &= P(t_* | w, \sigma^2) \frac{p(w, \sigma^2) p(w, \sigma^2)}{p(t)} dw d\sigma^2 \end{aligned} \quad (4)$$

为避免过度拟合, 相关向量机(RVM)选择将先决条件加入到权值向量 w 中, 使 w 呈现正态分布, 因此有:

$$p(w | \mu) = \prod_{i=0}^N N(w_i | 0, \mu_i^{-1}) = \prod_{i=0}^N \frac{\mu_i}{\sqrt{2\pi}} \exp \left\{ -\frac{\mu_i w_i^2}{2} \right\} \quad (5)$$

此时, 要求条件概率公式可以求解, 接下来通过贝叶斯理论可求得:

$$p(w, \mu, \sigma^2 | t) = P(w | t, \mu, \sigma^2) p(\mu, \sigma^2 | t) \quad (6)$$

由 Delta 近似函数 $P(\mu, \sigma^2 | t) \approx \delta(\mu_{MP}, \sigma_{MP}^2)$ 并积分可得:

$$\begin{aligned} p(t, |t, \mu_{MP}, \sigma_{MP}^2) &= N(t_* | y_*, \sigma_*^2) \\ y_* &= \varphi(x_*) \alpha \\ \sigma_*^2 &= \sigma_{MP}^2 + \varphi(x_*)^T T \Phi \varphi(x_*) \end{aligned} \quad (7)$$

此时, 模型的求解转化为如何求得 μ_{MP} 和 σ_{MP}^2 , 采用最大似然估计可得:

$$P(t | w, \sigma^2) P(w, \mu) dw = 2\pi^{-\frac{N}{2}} |\Omega|^{-\frac{1}{2}} \exp\left(-\frac{1}{2} t^T \Omega^{-1} t\right) \quad (8)$$

其中 $\Omega = \sigma^2 I + \varphi A^{-1} \varphi^T$, 在式(8)中求偏导为 0 的解可以表示为:

$$\begin{aligned} \mu_i^{\text{nevo}} &= \frac{\gamma_i}{\mu_i^2} \\ (\sigma^2)_{\text{new}} &= \frac{\|t - \Phi \mu\|^2}{N - \sum_{i=0}^N \gamma_i} \\ \gamma_i &= 1 - \alpha_i \sum_{i,i} \end{aligned} \quad (9)$$

1.2 DSRVM 模型

DSRVM^[13] 是基于 RVM 提出的新的回归预测模型, 我们给定的是关于边坡实测数据 $D = \{X_n, t_n\}_{n=1}^N$, 其中 x_n 是特征向量, 而 t_n 对应是变形量。接下来, 需要找到一个函数 y , 而它对任何 (x, t) 都是 $y(x) = t$ 的模型。

对于回归问题, DSRVM 使用 M 个基函数的加权和 $y(x) = \sum_{m=1}^M w_m \phi_m(x)$, 其中 $W = [w_1 \cdots w_M]^T$ 是加权总和基函数 $\{\phi_m\}_{m=1}^M$ 的贡献, 第 m 个基函数是通过将内核 K 以第 m 个训练数据点为中心来计算的, 其中 $\phi_m(x) = K(x, x_m)$ 且 $M = N$ 。核 K 定义为:

$$K = \sum_{k=1}^K v_k K_k \quad (10)$$

其中 $\{K_k\}_{k=1}^K$ 是一组预先定义的核, $V = [v_1 \cdots v_K]^T$ 是对应核的权值。 K_k 可以是任意核函数, 比如径向基函数 (RBF) 和直方图交叉核。 DSRVM 对于 Mercer 内核没有限制, 就像支持向量机 SVM 一样。

因此, DSRVM 将回归函数 y 定义为:

$$y(x; w, v) = \sum_{m=1}^M \sum_{k=1}^K w_m v_k K_k(x, x_m) \quad (11)$$

DSRVM 是一种双重稀疏模型, 由于学习试图识别非零权重 ω_m 和 v_k , 而其余的权值为零, 这意味着将使用

一组稀疏的基函数 ϕ_m 进行回归。由于每个 ϕ_m 未与 x_m 相关联, 因此式(11)中具有非零权重的训练数据被称为相关性向量。因此, 将具有非零权重的 K_k 称为相关核函数。

DSRVM 是基于贝叶斯框架上解决式(11)中的回归问题, 假设 ε 是服从均值为 0, 方差为 σ^2 的高斯分布误差, 比如 $t = y(x; w, v) + \varepsilon$, 其中 t 为目标输出, 由此可得到式(12):

$$p(t | W, V, \sigma^2, X) \sim N(t; y(x; w, V), \sigma^2) \quad (12)$$

其中: $N(t; y, \sigma^2)$ 表示均值 y 和方差 σ^2 在变量 t 上的高斯分布, 并且式(12)对于所有训练数据 (x_n, t_n) 对以及测试数据 $(x_{\text{new}}, t_{\text{new}})$ 都成立。进一步假设所有观察值是相互独立的, 即 $i.e. p(t | w, v, \sigma^2, X) = \prod_n p(t_n | w, v, \sigma^2, x_n)$ 其中 $t = [t_1, \cdots, t_N]^T$, $X = [x_1, \cdots, x_N]^T$ 。为了获得稀疏权值, 定义了 w 和 v 上的高斯先验分布:

$$p(w | \alpha) \sim N(w; 0, A^{-1}) \quad (13)$$

$$p(v | \beta) \sim N(v; 0, B^{-1}) \quad (14)$$

其中超参数 $A = \text{diag}(\alpha)$, $\alpha = [\alpha_1, \cdots, \alpha_M]^T$ 和 $B = \text{diag}(\beta)$, $\beta = [\beta_1, \cdots, \beta_K]^T$ 。此外, 假设所有超参数的先验分布是一致的。当积分出来时, 分层先验导致具有 $p(w_m) \sim 1/|w_m|$ (类似于 v_k) 的 w 和 v 上的不适当稀疏先验, 这类似于稀疏拉普拉斯分布^[15]。一个完整的贝叶斯处理在给定特征 x_{new} 的情况下, 该模型的预测分布将导致新目标 t_{new} 的预测分布:

$$p(t_{\text{new}} | t, X, x_{\text{new}}) = \int p(t_{\text{new}} | \Omega, x_{\text{new}}) p(\Omega | t, X) d\Omega \quad (15)$$

式中: $\Omega = (w, v, \alpha, \beta, \sigma^2)$ 是所有参数的集合。因此, 模型在训练过程需要找到后验概率分布 $p(\Omega | t, X)$ 。由于这个后验结果在没有进一步假设的情况下是难以处理的, 因此采用了超参数 α, β 的类型 II 最大似然 (ML) 估计和 σ^2 的最大似然 (ML) 估计。为了提高可读性, 我们在下面省略了对 X 的条件, 接着构成 $p(\Omega | t) = p(w, v | t, \alpha_*, \beta_*, \sigma_*^2) p(\alpha_*, \beta_*, \sigma_*^2 | t)$, 其中 $\alpha_*, \beta_*, \sigma_*^2$ 是相应参数的 ML 估计。由于权重参数 (w, v) 的联合后部不能显式计算, 因此它是一个关于 w 和 v 因式分解的变分分布近似的:

$$p(w, v | t, \alpha_*, \beta_*, \sigma_*^2) \approx q(w) q(v) \quad (16)$$

其中因子 $q(w)$ 和 $q(v)$ 是任意分布的, 其显式形式导出如下。由于如果给定 w 和 v 的后部, 则 t 是不依赖于 α_* 和 β_* 的, 因此预测分布式(15)可以由下式近似:

$$p(t_{\text{new}} | t, x_{\text{new}}) \approx \int p(t_{\text{new}} | w, v, \sigma_*^2, x_{\text{new}}) q(w) q(v) dw dv \quad (17)$$

Log 似然函数 $p(t|\alpha_*, \beta_*, \sigma_*^2)$ 的变分下界为:

$$L = \int q(w)q(v) \log_2 \left(\frac{p(w, v, t | \alpha_*, \beta_*, \sigma_*^2)}{q(w)q(v)} \right) dw dv \quad (18)$$

1.3 基于 PSO 的 DSRVM 模型

PSO^[14]是通过模拟鸟群捕食行为设计的一种群智能算法,具有良好的全局优化能力。本文利用粒子群算法来确定 DSRVM 中的多个高斯核函数的最优核参数。

基于粒子群优化的 DSRVM 算法的步骤如下:

(1)设置 PSO 算法的迭代次数、种群规模以及惯性权重的参数,确定适应度评价函数。

(2)确定待优化参数 w 等参数并确定选值范围,代入 DSRVM 中进行训练,计算种群局部适应度值 p 和全局适应度极大值 g 。

(3)更新种群粒子的速率和位置,并重新计算种群局部适应度值 p 和全局适应度极大值 g 。

(4)对比适应度值大小并更新种群适应度值和全局适应度极大值。

(5)重复步骤(3)和步骤(4)直到满足最大迭代次数,获取最终的优化参数组合。

(6)将优化的参数组合代入 DSRVM 中对边坡位移预测,模型评价指标采用均方根误差(RMSE)、复相关系数(R^2)和平均相对预测误差(ARPE)对模型进行评价,其计算公式为:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (19)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (20)$$

$$APRE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (21)$$

式中: n ——样本数量;

y_i ——第 i 个样本的真实值;

$\hat{y}_i$ ——第 i 个样本的预测值。

算法总体流程图,如图 1 所示。

2 实测数据分析

本文根据已有文献^[15]中的露天矿山边坡实测数据,该矿山处于低山丘陵地段,属于剥蚀地形,整体地形为北东低、南西低,地形起伏较大,坡角一般为 $30^\circ \sim 50^\circ$,大部分为岩质边坡,上覆碎石和土层,植被发育。在矿




图 1 边坡位移预测流程图

Fig. 1 Flow chart of slope displacement prediction

山边坡中轴线布置传感器并测量地下水位变化量 X_1 、边坡坡度高度变化量 X_2 、黏聚力 X_3 、降雨量平均值 X_4 、摩擦角 X_5 、边坡角 X_6 、应力监测数据 X_7 、矿山边坡变形量 X_8 为模型的原始样本(表 1)。其中 $X_1 \sim X_7$ 为模型的因变量, X_8 为模型的自变量。样本空间划分为训练和预测两个部分,其中 1—27 号样本作为训练集,28—32 号样本作为测试集。

根据表 1 所示的边坡变形量与影响因素监测数据统计样本,本文分别利用 ELM、小波神经网络和本文研究的基于粒子群优化的双稀疏相关向量机(PSO-DSRVM)进行统计建模分析。

ELM 算法是一种前馈神经网络,采用前向单隐层结构训练模型,不需要梯度的反向传播调整权重。选取 Sigmoid 为 ELM 的激活函数,隐含层中含有 16 个神经元,矿山边坡位移预测结果如图 2 所示。

小波神经网络(WNN)是以 BP 神经网络结构为基础,小波基函数作为隐含层的传递函数,本文采用的 WNN 模型选用 Morlet 小波,网络训练次数为 100,其预测结果如图 3 所示。针对编号为 28—32 号的 5 个测试样本,从图 2 中可以发现期望的输出值(实际值)与模型预测值存在较大的误差,尤其是在第 30 号样本上误差最大。相较于图 2,小波神经网络对矿山边坡变形数据

表 1 边坡变形量与影响因素监测数据统计样本
Table 1 Statistical sample of monitoring data of slope deformation and influencing factors

编号	X_1/mm	X_2/mm	X_3/kPa	X_4/mm	$X_5/({}^\circ)$	$X_6/({}^\circ)$	X_7/kPa	X_8/mm
1	19	2	12	0	24	33	188.45	14.4
2	12	7	20	0	10	22	115.91	11.7
3	36	4	68	0	44	51	177.86	16.5
4	16	6	30	0	20	40	190.41	18.5
5	16	3	30	0	20	40	188.73	20.3
6	36	2	68	0	38	49	109.65	41.2
7	12	4	35	10	10	22	120.35	25.6
8	30	12	50	40	39	46	159.19	51.3
9	32	1	55	0	38	42	189.07	24.1
10	27	2	46	0	38	46	180.35	11.4
11	23	6	39	12	31	40	190.45	26.8
12	25	7	40	35	35	43	192.13	27.2
13	13	11	20	30	26	30	194.88	18.5
14	16	3	25	0	20	40	182.21	10.9
15	31	1	50	0	38	47	187.79	21.4
16	26	4	49	15	36	48	190.17	22.8
17	23	5	40	0	31	42	115.28	14.4
18	33	4	55	0	39	49	102.77	32.5
19	24	4	40	0	33	41	182.83	18.5
20	15	13	25	24	43	27	194.32	22.4
21	26	8	46	28	36	45	139.18	53.1
22	18	2	30	0	23	32	182.48	11.2
23	25	0	40	0	32	43	106.49	23.7
24	24	8	40	30	33	41	190.45	23.1
25	22	2	37	0	30	39	189.03	24.5
26	21	3	35	0	24	37	113.58	36.6
27	21	2	35	0	32	36	181.89	10.6
28	32	2	55	0	41	49	184.69	21.2
29	23	6	39	0	31	40	116.69	15.1
30	33	11	55	40	44	46	193.55	29.8
31	15	3	25	0	18	35	181.89	12.5
32	18	3	32	0	23	37	191.03	21.2




图 2 极限学习机的预测结果
Fig. 2 The prediction results of ELM




图 3 小波神经网络的预测结果
Fig. 3 The prediction results of WNN

的分析结果如图 3 所示,可以发现小波神经网络的结果比极限学习机(ELM)的分析效果要好,但是回归分析的精度仍然需要提升。
最后利用本文提出的 PSO-DSRVM 模型对多变量

的矿山边坡变形数据进行分析。相比于 RVM, DSRVM 属于多核学习模型的一种,它通过学习得到两组稀疏解,能提高模型的泛化能力。本文采用高斯核函数,核函数的数量为 3,通过多目标参数的粒子群算法获得最

优核参数为分别为 1.7、2.6、0.9, 具体分析结果如图 4 所示。图 4(a) 所示为训练样本建模的结果, 可以发现目标值与预测值具有非常好的拟合度, 其复相关系数接近 1, 并且根据 PSO-DSRVM 的基本原理可以识别出重

要性更突出的相关向量。图 4(b) 为对 5 个预测样本进行分析的结果, 在图中预测值和目标值基本重合, 同时根据贝叶斯分布的原则, 给出了预测结果的置信区间, 这对于结果的可靠性分析更具有意义。




图 4 本文提出的 PSO-DSRVM 模型预测结果

Fig. 4 The prediction results of the PSO-DSRVM

为了进一步评价本文提出方法对矿山边坡变形数据的预测精度和模型泛化能力, 图 5 显示了预测样本实际值与预测值的回归关系, 以及 5 个预测样本的相对误差。通过对比上述模型预测样本的均方根误差 (RMSE)、复相关系数 (R^2) 和平均相对预测误差 (ARPE) 来评价模

型预测精度, 具体如表 2 所示。通过表 2 可以发现, 本文提出的基于粒子群优化的双稀疏相关向量机 PSO-DSRVM 方法更适用于分析处理边坡变形数据, 具有更好的分析精度。




图 5 PSO-DSRVM 预测的精度

Fig. 5 Accuracy of PSO-DSRVM prediction

表 2 三种不同模型预测效果的比较

Table 2 Comparison of prediction effects of different models

评价指标	PSO-DSRVM	极限学习机	小波神经网络
RMSE	0.478	1.88	1.14
R^2	0.99	0.72	0.77
ARPE	0.017	0.29	0.27

3 结论

通过 PSO-DSRVM 模型在边坡工程中的应用研究, 可得出以下结论:

(1) 影响边坡位移及稳定性有很多非线性因素, 本文选取了 7 个变量作为边坡位移的影响因素。作为一种

新的机器学习算法 DSRVM,其最终结果受到核参数的影响较大,因此本文在优化算法的启发下,提出了基于粒子群优化的双稀疏相关向量机模型即 PSO-DSRVM。

(2)在建立 PSO-DSRVM 预测模型的基础上,利用露天矿边坡变形数据,通过与极限学习机和小波神经网络相比较,结果表明 PSO-DSRVM 的预测精度远也高于其他两种模型,将其运用于露天矿边坡变形预测研究中具有较好的适用性和可靠性。

参考文献(References):

- [1] 王鹏飞. 基于GM-RBF组合模型的高路堑边坡稳定性预测研究[J]. *建筑结构*, 2021, 51(20): 140–145. [WANG Pengfei. Study on stability prediction of high cutting slope based on GM-RBF combination model[J]. *Building Structure*, 2021, 51(20): 140–145. (in Chinese with English abstract)]
- [2] 方然可, 刘艳辉, 苏永超, 等. 基于逻辑回归的四川青川县区域滑坡灾害预警模型[J]. *水文地质工程地质*, 2021, 48(1): 181–187. [FANG Ranke, LIU Yanhui, SU Yongchao, et al. A early warning model of regional landslide in Qingchuan County, Sichuan Province based on logistic regression[J]. *Hydrogeology & Engineering Geology*, 2021, 48(1): 181–187. (in Chinese with English abstract)]
- [3] 史笑凡, 杨春风. 基于支持向量机的边坡垂直位移方向率预测及边坡稳定性研究[J]. *河北工业大学学报*, 2021, 50(1): 92–98. [SHI Xiaofan, YANG Chunfeng. Support vector machine for vertical displacement direction rate of slope estimate and slope stability research[J]. *Journal of Hebei University of Technology*, 2021, 50(1): 92–98. (in Chinese with English abstract)]
- [4] 晏红波, 杨庆, 任超, 等. 基于EEMD的BP神经网络边坡预测研究[J]. *水力发电*, 2017, 43(7): 37–40. [YAN Hongbo, YANG Qing, REN Chao, et al. Research on side slope prediction using BP neural network based on EEMD[J]. *Water Power*, 2017, 43(7): 37–40. (in Chinese with English abstract)]
- [5] 邓超, 胡焕校, 张天乐, 等. 基于改进极限学习机模型的岩质边坡稳定性评价与参数反演[J]. *中国地质灾害与防治学报*, 2020, 31(3): 1–10. [DENG Chao, HU Huanxiao, ZHANG Tianle, et al. Stability evaluation and parameter inversion of rock slope using modified extreme learning machine model[J]. *The Chinese Journal of Geological Hazard and Control*, 2020, 31(3): 1–10. (in Chinese with English abstract)]
- [6] 韩连生, 宋光仁. 基于灰色理论的露天矿边坡位移预测预警研究[J]. *化工矿物与加工*, 2018, 47(5): 48–52. [HAN Liansheng, SONG Guangren. Research of prediction and early warning of slope displacement in open-pit mines based on Gray Theory[J]. *Industrial Minerals & Processing*, 2018, 47(5): 48–52. (in Chinese with English abstract)]
- [7] 李麟玮, 吴益平, 苗发盛, 等. 基于变分模态分解与GWO-MIC-SVR模型的滑坡位移预测研究[J]. *岩石力学与工程学报*, 2018, 37(6): 1395–1406. [LI Linwei, WU Yiping, MIAO Fasheng, et al. Displacement prediction of landslides based on variational mode decomposition and GWO-MIC-SVR model[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2018, 37(6): 1395–1406. (in Chinese with English abstract)]
- [8] LIU Z Q, GUO D, LACASSE S, et al. Algorithms for intelligent prediction of landslide displacements[J]. *Journal of Zhejiang University-SCIENCE A*, 2020, 21(6): 412–429.
- [9] 罗亦泳, 张豪, 张立亭. 基于进化相关向量机的边坡安全系数估算[J]. *人民黄河*, 2016, 38(2): 103–107. [LUO Yiyong, ZHANG Hao, ZHANG Liting. Estimation of slope safety factor based on evolutionary relevance vector machine[J]. *Yellow River*, 2016, 38(2): 103–107. (in Chinese with English abstract)]
- [10] 江婷, 沈振中, 徐力群, 等. 基于支持向量机-小波神经网络的边坡位移时序预测模型[J]. *武汉大学学报(工学版)*, 2017, 50(2): 174–181. [JIANG Ting, SHEN Zhenzhong, XU Liqun, et al. Time series prediction model of slope displacement based on support vector machines-wavelet neural network[J]. *Engineering Journal of Wuhan University*, 2017, 50(2): 174–181. (in Chinese with English abstract)]
- [11] TIPPING M E. Escaping the convex hull with extrapolated vector machines[M]//*Advances in Neural Information Processing Systems 14*. MIT: The MIT Press, 2002: .
- [12] 沈力华, 陈吉红, 曾志刚, 等. 多稀疏回声状态网络预测模型[J]. *控制理论与应用*, 2018, 35(4): 421–428. [SHEN Lihua, CHEN Jihong, ZENG Zhigang, et al. Prediction model with multiple sparse echo state network[J]. *Control Theory & Applications*, 2018, 35(4): 421–428. (in Chinese with English abstract)]
- [13] KALTWANG S, TODOROVIC S, PANTIC M. Doubly sparse relevance vector machine for continuous facial behavior estimation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(9): 1748–1761.
- [14] LUO Z Y, BUI X N, NGUYEN H, et al. A novel artificial intelligence technique for analyzing slope stability using PSO-CA model[J]. *Engineering with Computers*, 2021, 37(1): 533–544.
- [15] 李胜, 韩永亮. 基于MFOA-SVR露天矿边坡变形量预测研究[J]. *中国安全生产科学技术*, 2015, 11(1): 11–16. [LI Sheng, HAN Yongliang. Research on forecasting of slope deformation in open-pit mine based on MFOA-SVR[J]. *Journal of Safety Science and Technology*, 2015, 11(1): 11–16. (in Chinese with English abstract)]