

基于灰色支持向量机残差修正模型的地面沉降量预测

宁志杰¹, 袁颖^{1,2}

(1. 河北地质大学城市地质与工程学院, 河北石家庄 050031; 2. 河北省高校生态环境地质应用技术研发中心, 河北石家庄 050031)

[摘要] 沉降现象在各地区普遍发生, 地面沉降量预测越来越受到重视。本文通过结合灰色 (GM(1,1)) 预测模型和支持向量机 (SVM) 模型各自的优点, 建立灰色支持向量机 (GM(1,1) - SVM) 残差修正模型, 在突出时间序列发展趋势影响的同时降低序列中异常值的消极作用。以某高层建筑的 18 次地面沉降量数据为实例, 检验 GM(1,1) - SVM 模型的预测效果。结果表明: 相对单一的 GM(1,1) 沉降量预测模型, GM(1,1) - SVM 模型相对误差小, 预测精度高, 对地面沉降量预测有一定指导意义。

[关键词] 地面沉降 沉降量预测 GM(1,1) 模型 GM(1,1) - SVM 模型

[中图分类号] P542 **[文献标识码]** A **[文章编号]** 0495 - 5331(2021)03 - 0614 - 07

Ning Zhijie, Yuan Ying. Prediction of land subsidence based on a residual correction model of the grey support vector machine[J]. *Geology and Exploration*, 2021, 57(3): 0614 - 0620.

0 引言

随着我国经济的迅猛发展和城市化进程的加快, 人们对空间资源和矿产资源的需求量越来越大, 资源的过度开发对周围环境造成了极大的影响和破坏。其中, 以地下空间及矿产资源的开发和高层建筑的兴建等工程活动引起的地面沉降现象尤为严重。地面沉降不仅会引起周边建筑物和地下管线的变形, 而且区域性的地面沉降往往伴随着地裂缝的发生, 严重危及人民的生命财产安全。因此, 通过发现已有地面沉降数据内在的规律与本质, 预测未来沉降量与沉降趋势是一个值得探索的问题。

目前应用于地面沉降量预测的模型有很多种, 如种亚辉等(2019)基于时序 InSAR 技术对常州市重点沉降区域的沉降量进行了预测; 周爱红等(2018)采用粒子群优化的支持向量机模型对盾构施工引起的地面沉降量进行了预测; 戴文婷等(2019)通过缓冲算子优化原始序列, 对地铁施工过程中的地表沉降量进行了预测; 彭立顺等(2019)采

用优化后的神经网络对南城高速路基沉降量进行了预测。上述各类单一模型都能够对沉降量进行预测, 但是均存在预测精度较低的情况。为了提高预测结果的精度, 结合不同模型的优点建立组合模型在地面沉降量的预测中应用越来越受到重视。李慧洁等(2016)以山西省太原市阎家峰路段地面沉降数据为基础, 建立了泊松和指数模型的组合模型, 对黄土地区高填方路堤沉降量进行了预测; 杨彪等(2016)将人工神经网络与灰色 GM(1,1) 模型相结合, 建立了 GM(1,1) - ANN 预测模型对某工程沉降监测点数据进行了预测; 武光伟(2016)针对沉降量具有非平稳时序性和发展趋势确定的特点, 建立了 GM(1,1) - AR 组合模型, 对某高层建筑物的沉降量进行了预测; 王朋飞(2017)基于经验模态分解 (EMD) 和支持向量回归 (SVR) 相结合的预测方法, 建立 EMD - SVR 模型对长春自由大道地铁站地表沉降量进行了预测。上述组合模型有效地提高了沉降预测的精度, 在一定程度上表明了组合模型在沉降量预测中的优势。

[收稿日期] 2019 - 12 - 02; **[改回日期]** 2021 - 04 - 08; **[责任编辑]** 郝情情。

[基金项目] 国家自然科学基金资助项目 (编号: 41807231)、河北省自然科学基金项目 (编号: D2019403182) 和河北省教育厅青年基金项目 (编号: QN2019196) 联合资助。

[第一作者] 宁志杰 (1995 年 -), 男, 2021 年毕业于河北地质大学地质工程专业, 硕士, 主要研究方向为环境和灾害地质、工程地质。E-mail: 378330572@qq.com。

[通讯作者] 袁颖 (1976 年 -), 男, 2006 年毕业于大连理工大学, 获博士学位, 防灾减灾及防护工程专业, 主要从事环境和灾害地质、工程地质的教学和科研工作。E-mail: yuanyingson@163.com。

鉴于此,本文基于 GM(1,1)模型具有处理小样本、贫信息,弱化原始序列随机性的特征和 SVM 模型泛化能力强、处理小样本、波动大、非线性样本数据等方面的优势,采用 SVM 模型对 GM(1,1)模型沉降量预测值的残差进行修正,建立 GM(1,1) - SVM 模型,并检验 GM(1,1) - SVM 模型在沉降量预测方面是否能够取得更好的效果以及该模型能否满足实际应用的需要。

1 模型理论

1.1 灰色 GM(1,1)模型

中国控制论专家邓聚龙教授于 1981 年提出灰色系统概念,并于 1982 年建立了灰色系统理论。该理论以部分信息已知、部分信息未知的灰色系统为研究对象,通过对部分已知信息的处理、开发和分析,实现对整个灰色系统的发展趋势、变化规律进行准确的反映和描述。目前,应用最广泛的是 GM(1,1)模型,它通过对原始数据累加形成有规律的时间序列数据,进而建立微分方程形式的预测模型(Dejamkhooy et al., 2017; Manjunatheshwara and Vinod, 2018; Shi et al., 2018; Gao et al., 2018)。具体的步骤为:

(1) 设建模序列 $x^{(0)}$ 有 n 个对应的观测值

$$x^{(0)} = \{x^{(0)}(1), x^{(0)}(2), \dots, x^{(0)}(n)\} \quad (1)$$

式中: n 为数据个数。

(2) 进行累加运算使其成为有规律的时间序列数据,弱化其随机性

$$x^{(1)}(t) = \sum_{i=1}^t x^{(0)}(i); t = 1, 2, \dots, n \quad (2)$$

(3) 构造变量 $x^{(1)}$ 关于时间 t 的一阶微分方程 GM(1,1) 方程

$$\frac{dx^{(1)}}{dt} + ax^{(1)} = u \quad (3)$$

式中: $ax^{(1)}$ 项中的 a 为发展系数; u 为灰色作用量;其中 a 和 u 均为未知。

(4) 由上式的离散形式,可得如下矩阵,并简化为线性模型:

$$Y = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]^T$$

$$B = \begin{cases} -\frac{1}{2}[x^{(1)}(1) + x^{(1)}(2)] & 1 \\ -\frac{1}{2}[x^{(1)}(2) + x^{(1)}(3)] & 1 \\ \vdots & \vdots \\ -\frac{1}{2}[x^{(1)}(n-1) + x^{(1)}(n)] & 1 \end{cases}$$

$$\alpha = (a \ u)^T$$

$$Y = B\alpha \quad (4)$$

式中: Y 为数据向量; B 为数据矩阵; α 为参数向量。

(5) 用最小二乘估计法求解上述简化的线性模型得

$$\alpha = \begin{pmatrix} a \\ u \end{pmatrix} = (B^T B)^{-1} B^T Y \quad (5)$$

(6) 将 α 的值代入原始微分方程,得到 GM(1,1)模型的时间响应函数形式(6),将其离散化,并利用式(7)对 $\hat{x}^{(1)}(t)$ 进行累减还原获得 $\hat{x}^{(0)}(t)$ 的预测值,即

$$\hat{x}^{(1)}(t) = \left(x(1) - \frac{u}{a}\right)e^{-a(t-1)} + \frac{u}{a} \quad (6)$$

$$\begin{aligned} \hat{x}^{(0)}(t) &= \hat{x}^{(1)}(t) - \hat{x}^{(1)}(t-1) \\ &= \left(x^{(0)}(1) - \frac{u}{a}\right)(1 - e^a)e^{-a(t-1)} \end{aligned} \quad (7)$$

(7) 同时以平均相对误差作为检验 GM(1,1)模型精度和预测效果优劣的方法,其具体计算方法为

$$\delta(t_i) = x^{(0)}(t_i) - \hat{x}^{(0)}(t_i), i = 1, 2, \dots, n \quad (8)$$

$$\Delta k = \delta_k / x_k$$

$$\overline{\Delta k} = \sum_{k=1}^n |\Delta k|, k = 1, 2, \dots, n \quad (9)$$

式中: Δk 为相对误差; $\overline{\Delta k}$ 为平均相对误差; δ_k 为 k 点的残差; x_k 为 k 点的原始沉降量的值。

1.2 SVM 模型

SVM 方法是建立在统计学理论中的 VC 理论和结构风险最小原理基础上的一种机器学习方法。当需要处理低维空间难以处理的数据集时, SVM 通常会通过一个非线性映射将这些数据映射到高维空间,在此空间构造最优超平面使各类之间的距离达到最大来解决分类问题(图 1)。它的关键在于核函数,核函数能够有效地解决空间内积的计算过程复杂繁琐、计算量庞大的问题,这就意味着,当我们确定好核函数后就能在高维空间对这些数据进行有效的学习和识别(Huang et al., 2016; Qian et al., 2016; Wei et al., 2018; Abdolrazzaghi et al., 2018)。SVM 具体的实现过程为:

(1) 将回归问题转化为求结构最小风险度问题

对于给定的样本, $[(x_i, y_i)]^T, i = 1, 2, 3, \dots, n$ 。 n 为样本总数, x_i 为训练样本的各个参评指标, y_i 为相对应的评价结果。根据 SVM 理论建立一个目标




图1 超平面划分示意图

Fig. 1 Schematic diagram of hyperplane subdivision

函数并设置约束条件,将最优化问题转化为结构风险度最小问题。

$$\max L(\alpha) = -\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j y_i y_j (x_i^T x_j) + C \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (10)$$

$$\text{s.t.} \begin{cases} y_i - (\omega \times \varphi(x) + b) < \varepsilon + \xi_i \\ (\omega \times \varphi(x) + b) - y_i < \varepsilon + \xi_i^*, i = 1, 2, 3, \dots, n \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad (11)$$

式中: α_i 和 α_j 为拉格朗日乘值; ω 为权值矢量; b 为偏置值; C 为惩罚因子; ξ_i, ξ_i^* 为松弛因子; ε 为允许误差; $\varphi(x)$ 为从输入空间到高维特征空间的非线性映射。

(2) 解决对偶问题并引入核函数

引入拉格朗日乘子 α_i 和 α_j 处理上述问题后可以得到最优解为 $\alpha^* = [\alpha_1^*, \alpha_2^*, \dots, \alpha_n^*]^T$, 进一步计算可得最优的 w^* 和 b^* 的值, 再利用核函数 $K(x - x_i)$ 得到最终的回归函数。

$$\begin{cases} \omega^* = \alpha_i^* - x_i y_i \\ b^* = -\frac{1}{2} \omega^* (x_r + x_s) \end{cases} \quad (12)$$

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \times K(x - x_i) + b \quad (13)$$

式中: x_r 和 x_s 为一对支持向量; α_i 为与每个样本对应的拉格朗日乘子; α_i^* 为最优解; $K(x_i, x)$ 为核函数。本文通过阅读大量文献选择了在时间序列预测中应用较为广泛的 *RBF* 核函数, 其公式如下:

$$K(x - x_i) = \exp(-g |x - x_i|^2) \quad (14)$$

式中: g 为参数。

1.3 GM(1,1) - SVM 残差修正模型

在 GM(1,1) 模型的精度不理想的情况下, 应当考虑建立残差修正模型。GM(1,1) - SVM 残差修正模型首先利用 SVM 模型对残差序列进行修正, 然后将 GM(1,1) 模型预测出来的沉降量与 SVM 模型修正后的残差序列相加, 最终得到 GM(1,1) - SVM 模型的预测结果。在 SVM 模型训练过程中采用 GA 算法对参数 C 和 g 寻优 (Vijayashree and Sultana, 2018; 要震等, 2018; 杨风开和程素霞, 2018; Han et al., 2019)。GM(1,1) - SVM 模型具体的实现过程如下:

(1) 在残差序列中取 $\delta(t_{i-1})$ 、 $\delta(t_{i-2})$ 、 $\delta(t_{i-3})$ 作为 SVM 模型的输入, $\delta(t_i)$ 作为模型的输出, 由此获得经 SVM 模型矫正后的残差序列 $\widehat{\delta(t_i)}$ 。

(2) GM(1,1) - SVM 模型最终的预测结果为 $\bar{x}^{(0)}(t_i) + \widehat{\delta(t_i)}$ 。

(3) 同时仍以平均相对误差检验 GM(1,1) - SVM 残差修正模型预测效果的优劣。

2 模型预测效果分析

由 GM(1,1) - SVM 残差修正模型的建模过程可知, 当 GM(1,1) 模型精度较差、预测结果难以满足实际应用时, 需要考虑建立 GM(1,1) - SVM 残差修正模型。因此本节首先采用 GM(1,1) 模型对沉降量进行预测, 并根据预测结果分析 GM(1,1) 模型存在的问题以及是否需要建立残差修正模型。若 GM(1,1) 模型精度较差则按 1.3 节中的步骤建立 GM(1,1) - SVM 残差修正模型, 将预测结果与 GM(1,1) 模型的预测结果进行对比, 分析 GM(1,1) - SVM 模型能否解决 GM(1,1) 模型存在的问题以该模型的预测结果能否满足实际需要。

2.1 数据来源

某高层建筑地面 18 层, 地下 2 层, 基础埋深 8 m, 采用天然地基, 地基土类型为低压缩性的粉土及粉质黏土。为研究高层建筑建成后对周围建筑的影响, 有关单位从 2010 年高层建筑完工到 2012 年的 2 年内对该高层建筑的沉降量进行了监测频率为 1 次/月的长期监测。记录了该高层建筑的沉降发展情况, 监测点平面布置图如图 2 所示, 本文以 2010 年 7 月 ~ 2011 年 12 月的时间段内角点 A_1 、 B_1 和 B_5 的 18 次沉降数据为例进行了后续分析。




图2 监测点平面布置图

Fig.2 Layout of monitoring points

2.2 GM(1,1)模型预测效果分析

以角点 A_1 、 B_1 和 B_5 的 18 次沉降数据的平均值 (表 1) 作为沉降量样本, 为充分利用所收集的沉降

数据, 提高沉降量的预测次数 (即预测更长时间段内的沉降发展趋势), 通过不断的调整拟合沉降数据与预测沉降数据的次数经过反复试算, 最终确定采用前 15 次地面沉降值作为建模序列建立 GM(1, 1) 模型, 预测第 16 次 ~ 第 18 次的地面沉降值。首先, 将前 15 次沉降值作为建模序列相对应的 15 次观测值 (形如式 (1) 所示), 采用式 (2) ~ (5) 对上述 15 次观测值进行累加、建立微分方程、求解线性模型获得灰参数 α , 通过式 (6) 建立离散形式的 GM(1, 1) 模型时间响应函数。由式 (7) 可知, GM(1, 1) 模型的预测过程是一个累减还原的过程, 当取式 (7) 中的 t 为 18 时, 不仅能够得到第 16 ~ 18 次沉降量的预测值, 并且通过累减还原还会得到前 15 次沉降量的预测值, 称其为拟合值。将 GM(1, 1) 模型的 18 次累减还原值划分为对前 15 次沉降量的拟合结果和第 16 ~ 18 次沉降量的预测结果见图 3, 并通过式 (8) 计算残差值见表 1。

表1 高层建筑监测点 18 次实际沉降量平均值

Table 1 Actual average values of settlement from 18 times of measurement at monitoring points of a high building

	观测次数																	
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
沉降量 (mm)	0	1.13	2.34	3.35	4.67	5.43	6.64	6.89	7.8	8.32	8.64	9.5	9.91	10.4	10.92	11.59	12.07	12.35
GM(1,1) 拟合值 (mm)	0	3.52	3.33	4.27	4.71	5.19	5.71	6.29	6.93	7.64	8.41	9.26	10.2	11.24	12.38	13.64	15.02	16.05
残差值 (mm)	0	-2.39	-1.54	-0.92	-0.04	0.23	0.92	0.59	0.86	0.67	0.22	0.23	-0.29	-0.84	-1.46	-2.05	-2.95	-4.2




图3 高层建筑沉降量拟合结果与预测结果对比图

Fig.3 Comparison of fitted and predicted settlement of a high building

由图 3 从整体上对 18 次实际沉降值与 GM(1, 1) 模型的 18 次沉降量累减还原值进行对比分析可知, 实际沉降量以第 7 次观测数据为分界点, 可以近似的看为是斜率不同的两段直线, 分界点前沉降量增长较快, 分界点后沉降量增长缓慢。表明该高层建筑竣工后的一段时间内地面沉降量增长迅速, 随

着时间的推移沉降量增长缓慢乃至停止, 这符合我们对地面沉降现象的认知。而由图 3 中沉降量累减还原值不难看出, 在不考虑第一次的沉降量累减还原值时, 沉降量累减还原值的增长类似于一条增长率逐渐增大的曲线, 这不符合沉降量后期缓慢增长的实际情况, 将会导致第 16 次 ~ 第 18 次的沉降量预测值偏高。为排除建模序列长度对 GM(1, 1) 模型预测效果的影响, 采用 1 次 ~ 第 5 次的沉降量值作为建模序列建立 GM(1, 1) 模型, 预测第 6 次 ~ 第 7 次的沉降量时, 发现沉降量的累减还原值仍近似于一条增长率逐渐增大的曲线。该结果表明模型累减还原值的这种曲线形式的增长规律并不是由建模序列过长引起的。因此, 认为 GM(1, 1) 模型沉降量累减还原值呈曲线形式增长是模型本身的问题。

在实际地面沉降量预测过程中, 由于预测沉降量所对应的沉降实际值是未知的, 不可能通过第 16 次 ~ 第 18 次地面沉降量的预测值与实际值进行对比分析预测效果的好坏, 只能通过对比前 15 次沉降量拟合值与实际值判断 GM(1, 1) 模型第 16 次 ~ 第

18 次的预测值是否符合实际情况。由表 1 中残差值计算得出 GM(1,1)模型的前 15 次拟合值与实际值的平均相对误差为 27.6% 可知,模型的精度并不理想;而由图 3 中拟合结果部分可知,拟合值与实际沉降值的第 4 次~第 12 次拟合程度较高,第 1 次~第 4 次和第 12 次~第 15 次的拟合效果较差,并且由图 3 中第 12 次~第 15 次残差值逐渐增大的趋势可知,沉降量预测值增长量要比实际沉降值增长快,综上所述,推测 GM(1,1)模型的第 16 次~第 18 次的预测值较实际值是偏高的,而由图 3 中预测结果部分可知沉降量预测值的确比实际值高。由于这种预测值偏高的情况是模型本身导致的,难以通过调整 GM(1,1)模型的相关参数提高模型沉降预测的效果,只能通过预判第 16 次~第 18 次的残差值,将其与 GM(1,1)模型第 16 次~第 18 次的预测值相加来降低模型预测值的误差,因此考虑利用泛化

能力强、处理突变问题效果较好的 SVM 模型对残差进行修正。

2.3 GM(1,1) - SVM 模型预测效果分析

为了克服模型本身的缺陷,提高预测结果的准确性,以表 1 残差序列中的 18 个残差值作为原始数据建立 SVM 模型。SVM 模型建模的具体步骤为:以残差序列的第 1 次~第 3 次数据作为输入 x_i ,第 4 次作为输出 y_i ;再以第 2 次~第 4 次数据作为输入 x_i ,第 5 次作为输出 y_i ;以此类推,基于式(10)~(12)对上述 12 组数据处理得到式(13)中的回归函数建立 SVM 模型,预测第 16 次~第 18 次残差值,接着将残差修正值与 GM(1,1)模型的预测值对应相加作为 GM(1,1) - SVM 模型的预测值。最后将两种模型的第 16 次~第 18 次地面沉降预测值同实际值进行对比,并根据式(9)计算出预测结果的平均相对误差来检验预测结果的精度,如表 2 所示。

表 2 GM(1,1)模型和 GM(1,1) - SVM 模型预测结果对比
Table 2 Comparison of prediction results by GM(1,1) model and GM(1,1) - SVM model

	观测次数			平均相对误差
	16	17	18	
实际沉降量/mm	11.59	12.07	12.35	
GM(1,1) 预测值/mm	13.64	15.02	16.55	24%
GM(1,1) - SVM 预测值/mm	11.78	12.43	12.64	2.2%

由于 SVM 模型预测效果受参数 C 和 g 影响较大,为了获得最优的参数值本文利用 MATLAB 语言编写 GA 算法进行参数寻优,遗传算法的初始参数为:种群的最大数量设置为 20,进化终止代数数为 100,参数 C 的取值范围为 $(0, 100]$,参数 g 的取值范围为 $[0, 1000]$,SVM 交叉验证参数为默认值 5,GA 算法的寻优过程如图 4 所示。经过不断地迭代计算最终确定 SVM 模型最优参数值为 $C = 3.06$, $g = 0.2$ 。利用 GA 算法所确定的参数值作为 SVM 模型的最优参数值对上述残差序列进行预测。

由图 4 可知,采用 GA 算法对 SVM 模型参数进行优化,在遗传进化至 54 代后,SVM 模型能够对训练样本数据进行有效的识别,取得了很好的优化效果,GA 算法有效地避免了依赖经验数据进行参数优化,同时缩短了寻找 SVM 模型最优参数的时间,提高了预测结果的准确率。

由表 2 可知,GM(1,1)模型和 GM(1,1) - SVM 模型的平均相对误差分别为 24% 和 2.2%,表明 GM(1,1) - SVM 模型的沉降预测值更逼近真实值,预测精度更高,能够在实际工程中取得更好的应用。




图 4 GA 算法寻优过程图

Fig. 4 Optimization process of GA algorithm

并且通过表 2 可以计算出 GM(1,1)模型和 GM(1,1) - SVM 模型的预测结果与实测沉降数据的相对误差,GM(1,1)模型第 16 次~第 18 次地面沉降预测值的相对误差为 17.7%,24.4%,30%;GM(1,1) - SVM 模型第 16 次~第 18 次地面沉降预测值的相对误差为 1.6%,2.8%,2.3%。由此可知,经过残差修正后建立的 GM(1,1) - SVM 模型第 16~18 次地面沉降预测值的相对误差相对于 GM(1,1)模型均有显著降低,表明采用 SVM 模型修正残差对提

高预测结果准确性是十分有效的。

此外,由表2不难看出,无论是GM(1,1)模型还是GM(1,1)-SVM模型,它们预测的沉降量值均高于实际沉降量的值。因此,利用SVM模型对残差序列进行预测,并与GM(1,1)模型的预测结果相结合,并不能从根本上解决GM(1,1)模型对沉降数据预测时出现的问题,但是通过这种方法能够减小预测结果的误差,增强预测模型在解决实际问题中的实用性。

3 结论

地面沉降是在多种因素共同作用下产生的一种地质灾害现象,难以用单一的预测模型准确有效地预测出未来一段时间内地面沉降量的发展趋势。当沉降序列展现出增长率逐渐增大的曲线形式变化规律时,GM(1,1)模型的预测效果会更加精确,而大多数实际沉降是一个前期沉降量增长迅速、后期沉降量增长缓慢的过程,沉降发展趋势并不符合曲线增长的变化规律。因此本文将GM(1,1)模型与SVM模型相结合建立GM(1,1)-SVM模型,充分发挥了GM(1,1)模型和SVM模型的优势,虽然不能从根本上解决GM(1,1)模型预测值偏大的问题,但是该模型做出了更符合工程实际的预测,为地面沉降数据的处理提供了一种新方法。

采取GA算法优化的SVM模型具有良好的自适应性以及预测结果准确率高的特点,实现了对残差的有效预测,但是在利用残差序列建立SVM模型的过程中,训练样本输入数据个数与输出数据个数的确定,仍有待进一步的研究和分析。

[References]

- Abdolrazzagh M, Hashemy S, Abdolali A. 2018. Fast - forward solver for inhomogeneous media using machine learning methods: Artificial neural network, support vector machine and fuzzy logic[J]. *Neural Computing and Applications*, 29(12): 1583 - 1591.
- Dai Wenting, Wang Zhen, Wang Yufang, Wang Qi. 2019. Improvement of GM(1,1) model for prediction of subway excavation settlement[J]. *Journal of Shenyang University of Technology*, 41(5): 571 - 577 (in Chinese with English abstract).
- Dejamkhooy A, Dastfan A, Ahmadyfard A. 2017. Modeling and forecasting non - stationary voltage fluctuation based on grey system theory[J]. *IEEE Transactions on Power Delivery*, 32(3): 1212 - 1219.
- Gao C, Li S, Wang J. 2018. The risk assessment of tunnels based on grey correlation and entropy weight method[J]. *Geotechnical and Geological Engineering*, 36(3): 1621 - 1631.
- Han D, Zhao N, Shi P. 2019. Gear fault feature extraction and diagnosis method under different load excitation based on EMD, PSO - SVM and fractal box dimension[J]. *Journal of Mechanical Science and Technology*, 33(2): 487 - 494.
- Huang S, Chang J, Qiang H. 2016. Quantifying the relative contribution of climate and human impacts on runoff change based on the Budyko hypothesis and SVM model[J]. *Water Resources Management*, 30(7): 2377 - 2390.
- Li Huijie, Ju Yuwen, Wang Wenzheng, Zheng Xuemei. 2016. Comparative study on settlement prediction models for several loess high fill embankments[J]. *China Sciencepaper*, 11(1): 82 - 86 (in Chinese with English abstract).
- Manjunatheshwara K J, Vinodh S. 2018. Grey - based decision - making method for sustainable material selection of tablet device enclosure[J]. *Clean Technologies and Environmental Policy*, 20(10): 2345 - 2356.
- Peng Lishun, Cai Run, Liu Jinbo, Guo Anning, Guo Zhiyu. 2019. Prediction of settlement of highway subgrade based on genetic optimization neural network[J]. *China Earthquake Engineering Journal*, 41(1): 124 - 130, 207 (in Chinese with English abstract).
- Qian X, Chen J, Xiang L. 2016. A novel hybrid KPCA and SVM with PSO model for identifying debris flow hazard degree: A case study in southwest china[J]. *Environmental Earth Sciences*, 75(11): 991 - 1002.
- Shi M, Jiang L, Fu Y. 2018. Study on prediction methods for the fault state of rotating machinery based on dynamic grey model and metabolism grey model[J]. *Wireless Personal Communications*, 102(4): 3615 - 3627.
- Vijayashree J, Sultana H P. 2018. A machine learning framework for feature selection in heart disease classification using improved particle swarm optimization with support vector machine classifier[J]. *Programming and Computer Software*, 44(6): 388 - 397.
- Wang Pengfei. 2017. Study on time series prediction of surface subsidence based on EMD - SVR[D]. Beijing: Beijing University of Technology: 53 - 60 (in Chinese with English abstract).
- Wei C, Pourghasemi H R, Naghibi S A. 2018. A comparative study of landslide susceptibility maps produced using support vector machine with different kernel functions and entropy data mining models in China[J]. *Bulletin of Engineering Geology & the Environment*, 77(2): 1 - 18.
- Wu Guangwei. 2016. Study on the application of grey time series combination model in the settlement prediction of high - rise buildings[D]. Xi'an: Xi'an University of Science and Technology: 40 - 61 (in Chinese with English abstract).
- Yang Biao, Li Huimin, Meng Hai, Pei Xingwang. 2016. Prediction method of building settlement variation trend based on GM - ANN model[J]. *Journal of Safety Science and Technology*, 12(10): 149 - 153 (in Chinese with English abstract).
- Yang Fengkai, Cheng Suxia. 2018. Visual adjustment method of two camera pose based on GA - BP neural network[J]. *Computer Science*, 45(S2): 185 - 188 (in Chinese with English abstract).
- Yao Zhen, Xu Jiping, Kong Jianlei, Liu Songbo. 2018. Study on river water level prediction method based on GA Elman[J]. *Journal of Yangtze River Scientific Research Institute*, 35(9): 34 - 37 (in Chinese with English abstract).
- Zhong Yahui, Dong Shaochun, Hu Huan. 2019. Land subsidence monito-

ring and analysis in Changzhou City Based on time series InSAR technology[J]. Geological Journal of China Universities, 25 (1): 131-143 (in Chinese with English abstract).

Zhou Aihong, Ni Yingying, Yin Chao, Sun Wu. 2018. A prediction method of land subsidence caused by shield construction[J]. Science of Surveying and Mapping, 43(3): 167-172 (in Chinese with English abstract).

[附中文参考文献]

戴文亭, 王振, 王宇放, 王琦. 2019. 改进 GM(1,1) 模型对地铁开挖沉降的预测[J]. 沈阳工业大学学报, 41(5): 571-577.

周爱红, 倪莹莹, 尹超, 孙武. 2018. 一种盾构施工引起的地面沉降预测方法[J]. 测绘科学, 43(3): 167-172.

彭立顺, 蔡润, 刘进波, 郭安宁, 郭志宇. 2010. 基于遗传优化神经网络的高速公路路基沉降量预测[J]. 地震工程学报, 41(1): 124-130, 207.

种亚辉, 董少春, 胡欢. 2019. 基于时序 InSAR 技术的常州市地面沉降监测与分析[J]. 高校地质学报, 25(1): 131-143.

李慧洁, 巨玉文, 王文正, 郑雪梅. 2016. 几种黄土高填方路堤沉降预测模型的对比研究[J]. 中国科技论文, 11(1): 82-86.

杨彪, 李慧民, 孟海, 裴兴旺. 2016. 基于 GM-ANN 模型的建筑物沉降量变化趋势预测方法[J]. 中国安全生产科学技术, 12(10): 149-153.

武光伟. 2016. 灰色时序组合模型在高层建筑物沉降预测中的应用研究[D]. 西安: 西安科技大学: 40-61.

王朋飞. 2017. 基于 EMD-SVR 的地表沉降量时间序列预测研究[D]. 北京: 北京工业大学: 53-60.

杨风开, 程素霞. 2018. 基于 GA-BP 神经网络的双摄像机位姿视觉调节方法[J]. 计算机科学, 45(S2): 185-188.

要震, 许继平, 孔建磊, 刘松波. 2018. 基于 GA-Elman 的河流水位预测方法研究[J]. 长江科学院院报, 35(9): 34-37.

Prediction of Land Subsidence Based on A Residual Correction Model of the Grey Support Vector Machine

NING Zhijie¹, YUAN Ying^{1,2}

(1. School of Urban Geology and Engineering, Hebei GEO University, Shijiazhuang, Hebei 050031; 2. Hebei Center for Ecological and Environmental Geology Research, Hebei GEO University, Shijiazhuang, Hebei 050031)

Abstract: Land subsidence is a common geologic hazard in many regions. The prediction of the amount of this surface process has received increasing attention. In this work, a residual correction model of the gray support vector machine (GM(1,1)-SVM) is established by combining the advantages of the gray prediction (GM(1,1)) model and support vector machine (SVM) model. It highlights the influence of time series development trend and lowers the negative effect of outliers in the sequence. Taken the data of 18 times of land subsidence of a high building as an example, the prediction effect of the GM(1,1)-SVM model is tested. The results show that the GM(1,1)-SVM model has a relatively small error and high prediction accuracy compared with the single GM(1,1) model, which has certain guiding significance for the prediction of land subsidence.

Key words: land subsidence, land subsidence prediction, GM(1,1) model, GM(1,1)-SVM model

