

DOI:10.13203/j.whugis20160075



文章编号:1671-8860(2018)02-0248-07

基于高斯过程回归的变形智能预测模型及应用

王建民¹ 张 锦¹

1 太原理工大学矿业工程学院,山西 太原,030024

摘 要:岩体或建构筑物的变形通常具有复杂性和非线性等特性,一般的回归模型难以精确地进行回归预测,应用高斯过程回归理论对变形监测数据呈现出的非线性特征进行时间序列分析。考虑到监测数据的不断更新和累积,以及超参数与样本集的适应性,首先研究了“递进-截尾式”超参数自动更新模式和训练样本集的选择方法;在此基础上构建了以时间作为输入项的高斯过程回归变形智能预测模型(GPR-TIPM);将该模型应用于矿山边坡监测点非线性时间序列分析中,通过分析变形趋势,最终采用 Matérn 32 和平方指数协方差函数相加的方式进行核函数组合。实验结果表明,采用组合核函数的预测性能较单一核函数有所改善,该方法提高了模型的泛化能力,GPR-TIPM 模型在短期内的预测效果较理想。

关键词:变形监测;高斯过程回归;智能预测;时间序列;矿山边坡

中图法分类号:P258

文献标志码:A

变形分析经过多年的研究和发展,取得丰硕的成果。由于引起变形的原因十分复杂,一般来说与变形体自身的物理特性、力学性质、地质条件和外界环境等诸多因素有关,使得变形具有不确定性和错综复杂性,从而诞生了多种变形分析的理论和方法。

到目前为止,回归统计分析法仍然是变形分析的主要方法,应用多元回归分析法建立变形与变形因子之间函数关系后进行定量预报,常用于大坝变形预测^[1-2]、边坡变形分析和预测^[3-5]等。回归分析在确定影响变形的因子时有时只能推断,并且有的因子不可测,使得回归分析在有限的条件下受到限制^[6]。

由于引起变形的原因复杂,许多工程实践中的时间序列数据经常表现出较明显的非线性特征。例如边坡的变形进入加速期,其变形值时间序列多数情况下会表现出较显著的非线性特点,另外确定影响变形的因素也是一个难点。

随着机器学习等新兴学科的发展,人工智能和机器学习理论逐渐引起了测绘科学界的重视。目前,应用于监测数据分析的人工智能机器学习主要代表方法是 BP 神经网络^[7-10]和支持向量机(support vector machine, SVM)^[11-13]。这些方法具有分布存储、并行处理、自学习、自组织以及非

线性映射等优点,由这些方法与其他技术的结合形成的混合方法和混合系统也有许多研究应用案例^[14-15]。将智能机器学习方法引入到测绘科学领域进行学科交叉研究,能够较好地解决变形监测中变形机理模糊、处理非线性系统等复杂问题。

近几年,高斯过程回归(Gaussian processes regression, GPR)方法在国际上成为智能机器学习领域的研究热点^[16]。但 GPR 应用于变形数据分析和预测的研究相对较少。国内已有学者开始应用 GPR 对地下工程岩体非线性行为进行预测^[17-18]、边坡可靠度分析^[19]和边坡变形预测^[20],这些研究成果主要是利用 GPR 已有的核函数开展研究,但关于 GPR 用于变形分析时核函数的选择、全局最优超参数快速求解、超参数动态更新及训练样本集优化等问题还有待进一步研究。

本文主要利用 GPR 非线性、自适应等优点对变形监测时空序列数据进行分析,研究基于 GPR 变形智能预测模型。

1 高斯过程回归基本原理

1.1 GPR 预测

回归分析方法就是用来确定两种或两种以上变量,即因变量 y 和自变量 x 之间相互依赖的定

收稿日期:2016-05-18

项目资助:山西省自然科学基金(201701D121014);国家自然科学基金(41371373)。

第一作者:王建民,副教授,主要从事测绘数据处理及变形监测理论与方法研究。8844.4321@163.com

量关系的一种统计分析方法, 回归模型中的 x 和 y 的关系由任意假设的函数 $f(x)$ 表示, 回归问题的一般模型表示为:

$$y = f(x) + \boldsymbol{\varepsilon}, \boldsymbol{\varepsilon} \sim N(0, \boldsymbol{\sigma}_n^2 \mathbf{I}_n) \quad (1)$$

其中, $\mathbf{y} = [y_1, y_2, \dots, y_n]^T$ 是受噪声污染的 $n \times 1$ 维的观测矢量, $\boldsymbol{\varepsilon}$ 是相互独立服从高斯分布的观测噪声向量, $\boldsymbol{\sigma}_n^2$ 为噪声方差, \mathbf{I}_n 是单位阵; $\mathbf{x} = [x_{i,1}, \dots, x_{i,d}]^T (i=1, 2, \dots, n), \mathbf{x} \in \mathbf{R}^d$ 是 $n \times 1$ 维的服从高斯分布的随机变量。

GPR 经过对观测数据的学习, 能间接地精确地描绘出 $f(x)$, GPR 是基于函数的, 由均值函数 $m(x)$ 和协方差函数 $k(x, x)$ 唯一确定, 因此, GPR 通常定义为:

$$f(x) \sim GP(m(x), k(x, x)) \quad (2)$$

其中,

$$\begin{cases} m(x) = E[f(x)] \\ k(\mathbf{x}, \mathbf{x}) = E[(f(x) - m(x))(f(x) - m(x))^T] \end{cases}$$

函数 $f(x)$ 是由多维高斯分布组成的, 根据多维高斯分布的性质, 由式(1)和式(2)可得观测值 \mathbf{y} 的先验分布为:

$$\mathbf{y} \sim N(0, k(\mathbf{x}, \mathbf{x}) + \boldsymbol{\sigma}_n^2 \mathbf{I}_n) \quad (3)$$

通常作数据预处理时减去均值, 使 $m(x) = 0$, 由高斯分布的性质进一步得到观测值 \mathbf{y} 与输出样本 \mathbf{y}_* (预测值) 的联合先验分布:

$$\begin{bmatrix} \mathbf{y} \\ \mathbf{y}_* \end{bmatrix} \sim N\left(0, \begin{bmatrix} k(\mathbf{x}, \mathbf{x}) + \boldsymbol{\sigma}_n^2 \mathbf{I}_n & k(\mathbf{x}, \mathbf{x}_*) \\ k(\mathbf{x}_*, \mathbf{x}) & k(\mathbf{x}_*, \mathbf{x}_*) \end{bmatrix}\right) \quad (4)$$

式中, $k(\mathbf{x}, \mathbf{x})$ 是输入样本 \mathbf{x} 的协方差矩阵, 且为 $n \times n$ 的对称正定矩阵, 各个元素 $k(x_i, x_j)$ 表示 x_i 与 x_j 的相关性; $k(\mathbf{x}, \mathbf{x}_*) = k(\mathbf{x}_*, \mathbf{x})^T$ 是输入样本 \mathbf{x} 与待预测输入值 \mathbf{x}_* 之间的 $n \times 1$ 的协方差矩阵; $k(\mathbf{x}_*, \mathbf{x}_*)$ 为待预测输入值 \mathbf{x}_* 自身的方差。

由 x 和 y 组成观测数据集 $D = \{(x_i, y_i) | i = 1, 2, \dots, n\}$, D 称为训练样本集或学习样本集, 在已获得的训练集 D 条件下, \mathbf{y}_* 的后验分布为:

$$p(\mathbf{y}_* | D, \mathbf{x}_*) \sim N(m(\mathbf{y}_*), k(\mathbf{y}_*, \mathbf{y}_*)) \quad (5)$$

其中 \mathbf{y}_* 的均值和方差分别为:

$$\begin{cases} m(\mathbf{y}_*) = k(\mathbf{x}_*, \mathbf{x}) [k(\mathbf{x}, \mathbf{x}) + \boldsymbol{\sigma}_n^2 \mathbf{I}_n]^{-1} \mathbf{y} \\ k(\mathbf{y}_*, \mathbf{y}_*) = k(\mathbf{x}_*, \mathbf{x}_*) - k(\mathbf{x}_*, \mathbf{x}) [k(\mathbf{x}, \mathbf{x}) + \boldsymbol{\sigma}_n^2 \mathbf{I}_n]^{-1} k(\mathbf{x}, \mathbf{x}_*)^T \end{cases} \quad (6)$$

式中, $m(\mathbf{y}_*)$ 即为待预测值 \mathbf{x}_* 的对应的输出值 \mathbf{y}_* 的均值; $k(\mathbf{y}_*, \mathbf{y}_*)$ 是输出预测值的后验方

差, 可以用来度量预测结果的不确定性, 即可信程度。这是 GPR 区别于 BP 和 SVM 方法的一个独特优点。

1.2 GPR 训练

由式(6)可知, GPR 中的协方差函数(核函数)对 GPR 的预测性能起着决定性的影响, 协方差函数是用来衡量训练样本与预测样本之间相似的程度, 其中平方指数协方差函数(squared exponential covariance function, SE)因其无穷可微使得 GPR 非常平滑, 是最为常用协方差函数, 其形式为:

$$k(x_i, x_j) = \boldsymbol{\sigma}_f^2 \exp\left(-\frac{1}{2l^2} r^2\right) + \boldsymbol{\sigma}_n^2 \delta_{ij} \quad (7)$$

式中, $r^2 = \sum_{k=1}^d (x_{i,k} - x_{j,k})^2$; $\boldsymbol{\sigma}_f^2$ 为信号方差, 用于控制局部相关性的程度; l 是特征长度尺度参数, 表示输出输入的相关性大小, 其值越大相关性越小。 $\boldsymbol{\sigma}_f^2$ 和 l 使得协方差函数具有很好的适用性。 $\boldsymbol{\sigma}_n^2$ 为噪声方差, δ_{ij} 为克洛内克尔函数, 习惯上将参数集 $\theta = \{l, \boldsymbol{\sigma}_f^2, \boldsymbol{\sigma}_n^2\}$ 称为超参数。

通过建立训练样本条件概率的负对数作为似然函数求偏导, 再采用牛顿法、共轭梯度法等优化方法进行最小化求得超参数的最优解, 有关其他协方差函数和超参数求解在文献[21]中有详细论述。

应用训练样本集求解超参数这一过程称为训练, 当训练完成后, 即可求得相应的协方差阵, 将待预测值 \mathbf{x}_* 代入式(6)得到预测值 \mathbf{y}_* 及其预测方差。

2 高斯过程回归变形智能预测模型

GPR 用于变形分析和预测, 不是简单的照搬和套用, 需要在解决好以下两个基本问题的基础上, 再一步研究基于 GPR 的时间驱动智能预测模型。

2.1 超参数动态更新

GPR 用于长序列变形数据分析时, 理论上选定核函数后, 经初始学习获取最优超参数, 在后续的预测环节只需要用待预测的输入量更新协方差矩阵即可, 这在开始一段时间内是可行的。然而随着监测时间的推移, 新的待预测量与超参数变得越来越不相适应, 同时 GPR 的泛化性能也会降低, 如果继续使用原有的超参数进行预测, 预测误差会逐渐增大, 在适当的时候需要借助训练样本集重新更新超参数。

考虑到变形量在时间域上的相关性,用后继的观测数据加入到初始训练样本集重新求解超参数,同时更新协方差矩阵由此来预测下一个时刻的变形量。每次更新时,由更新前已存在的超参数作为本次更新的初值,这样做的目的是为减少迭代次数,加快求解速度。但这样会存在一个问题,训练样本集会越来越大,不利于超参数的快速求解,应该维持一个数量稳定的能够自动更新的训练样本集,更新模式如下:

假设有 d 个样本对组成初始训练样本集 $D = \{(x_i, y_i), i = 1, 2, \dots, d\}$, 待预测值 x_{d+1} 作为 GPR 的输入量, y_{d+1} 为 GPR 的输出量, 当实测完 y_{d+1} 后, 将 (x_{d+1}, y_{d+1}) 作为新的样本对加入到原来的训练集中, 截去距离新加入的观测值最远的历史观测值 (x_1, y_1) , 以保持样本个数的恒定, 进一步预测下一个观测时刻变形量, 以此类推。将这种更新模式称为“递进-截尾式”动态更新模式, 图 1 为“递进-截尾式”更新模式示意图。

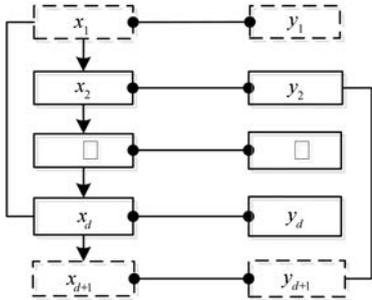


图 1 递进-截尾式示意图

Fig.1 The Schematic Diagram of Progressive-truncation

2.2 训练样本集选择

应用 GPR 进行变形预测时,如何确定训练集的数量 d 是一个关键因素,如果样本数量少达不到训练的效果,预测精度低,但也并不意味着样本数量多预测精度就高,数量太多反而会影响后续超参数的求解效率,需要综合考虑确定样本数量。

样本数量是否合理的评判依据可以从两方面考虑,一是定性分析法,即通过预测结果是否落入 GPR 置信区间以及置信区间的宽度定性的评判预测结果的好坏;二是定量分析法,定量的评判方法需要计算有关评价指标,方法如下。

选定 d 个观测数据组成初始训练样本,同时设定 k 个已测的数据作为检验数据。将 k 个实测值和 d 个样本值作为待预测值输入到 GPR 预测模型中,得到 k 个实测值对应的预测值和 d 个训练样本对应的预测值。由 k 个预测值和实测值求取残差,用式(8)计算出预测中误差 σ_k 用于衡量预测精度;由 d 个样本值和预测值求取残

差,用式(9)计算出训练中误差 σ_d 用于衡量训练精度。

逐渐增加 d 的个数并计算每次 d 改变后的 σ_k 和 σ_d ,当二者趋于稳定时, d 不再增加,作为最终的学习样本数量值。

$$\sigma_k = \sqrt{\frac{1}{k} \sum_{i=d+1}^{k+d} v_i^2} \quad (8)$$

$$\sigma_d = \sqrt{\frac{1}{d} \sum_{i=1}^d v_i^2} \quad (9)$$

式中, $v_i = y_i - y_{*i}$ 为对应的残差。

2.3 GPR 变形智能预测流程

无论是传统的几何测量还是先进的 GNSS 及测量机器人系统,这些监测设备仍需人为布置一定数量的监测点,才能发挥其优势,监测点的观测数据是一个时间序列。

“递进-截尾式”动态更新模式是针对单个监测点,以一般变量 x_i 作为输入量,预测出对应的变形量。如果以观测时间 t_i 作为 GPR 的输入量,时间作为驱动因子一步步预测监测点未来的变形量,本文将命名为 GPR 时间驱动智能预测模型(GPR time-driven intelligent prediction model, GPR-TIPM),图 2 是 GPR-TIPM 的预测流程图。

GPR-TIPM 用于预测包含为两个过程,首先要确定训练样本数量 d 并固定样本数量,然后选择某一时刻作为预测的开始时间进行动态预测,假如从当前时间第 10 天开始预测未来 5 d 的变形量,则 5 d 的时间长度作为 1 个预测周期,当 1 个观测周期实测完成后,再预测下一个预测周期内的变形,以此类推,图 3 是应用该模型的预测过程图。

3 GPR-TIPM 应用实例分析

实验数据来自中煤平朔井工二矿边坡(2#边坡)测量机器人监测系统,在监测区域内沿走向方向在各个“台阶”上布设了 63 个监测棱镜(监测点)构成 5 条监测线。图 4 是边坡外貌和监测棱镜点布置图。

由于矿山边坡所处的环境复杂,监测点的沉降量并非一直表现为连续下沉,监测点有时会出现上升的现象,实验选取了编号为 C1-06 的监测点连续 60 d 的时序观测值作为实验数据。之所以选择 C1-06 点作为实验对象,是因为 C1-06 可能受局部环境的影响(如施工作业),使其产生了一个明显的加速下沉,变形较其它点更为复杂,用于实验分析说服力更强。

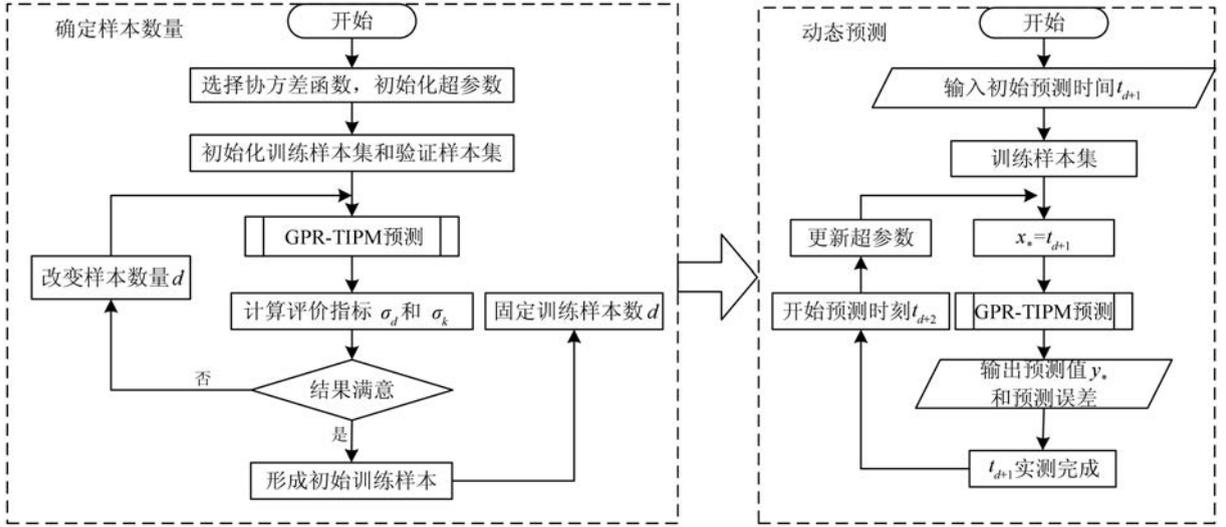


图 2 GPR-TIPM 预测流程图

Fig.2 The Prediction Procedure Diagram of GPR-TIPM

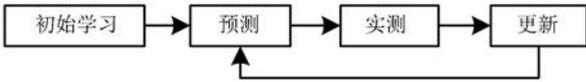


图 3 GPR-TIPM 预测过程

Fig.3 The Prediction Process of GPR-TIPM



图 4 边坡和监测棱镜点布置图

Fig.4 Monitoring Point Arrangement

3.1 协方差函数的选择

GPR 的协方差函数对预测性能有很大影响,即使是相同的数据,不同的协方差函数预测结果不完全相同。就 2# 边坡的监测数据的初步分析结果为长期的下沉趋势伴随着“波动”特征,时间与变形之间是一复杂的非线性关系。由于 GPR 的基础理论决定了 GPR 用于预测只能选择一种核函数,一种核函数难以满足变形曲线多样化的变形特征。GPR 可以将不同的协方差函数进行组合运算,本文利用组合式协方差函数模型来适应变形过程的多样化特征。

SE 无穷可微使得 GPR 非常平滑,通过设置 SE 较小的特征长度参数来适应观测数据的“波动”特征,但有时用过渡光滑的假设条件模拟许多物理过程是不现实的,可以考虑使用马特恩

(Matérn 32) 协方差函数。因此,实验最终选择 Matérn 32 + SE 作为后续监测点变形预测的核函数模型。

表 1 The Results of Different Kernel Function

Tab.1 不同核函数误差统计结果

评价 指标	协方差函数模型		
	SE	Matérn 32	Matérn 32+SE
σ_d /mm	0.50	0.34	0.3
MRE/%	9.0	5.7	5.0
耗时/s	0.62	0.52	1.9

表 1 是 Matérn 32 协方差函数和组合式 Matérn 32+SE 协方差函数计算的训练中误差和平均相对误差(MRE),同时计算了每种模型的计算耗时,显然 Matérn 32+SE 的效果更好,但计算效率下降。图 5 是输出的变形曲线,SE 输出的曲线比 Matérn 32+SE 光滑,但置信区间宽。

具体选择哪种协方差函数,需要分析观测数据自身的特点来做出选择,如果观测数据呈现出明显的线性特征,线性协方差函数无疑是理想的选择;如果观测数据表现出很强的周期性特点,显然要选用周期性核函数。

3.2 样本数量的确定

选择 d 为 7 的初始样本数量进行学习,检验数据集为第 13~17 天,即 $k=5$,根据图 2 中的 GPR-TIPM 预测流程进行计算,随着 d 的增加,置信区间宽度有所减小,另外当 d 的值增加到 12 时, σ_k 和 σ_d 的值基本趋于稳定,最终的学习样本数量取 12。图 6 是样本数 $d=7$ 和 $d=12$ 预测输出结果。

3.3 实验结果及分析

实验初始样本选用 1~12 d 的实测值进行训

练,以 Matérn 32+SE 作为核函数,选用 3 d 为 1 个预测周期,连续预测第 13~60 天的累积沉降量,图 7 是 GPR-TIPM 输出的未来 3 d 的时间-沉降曲线。

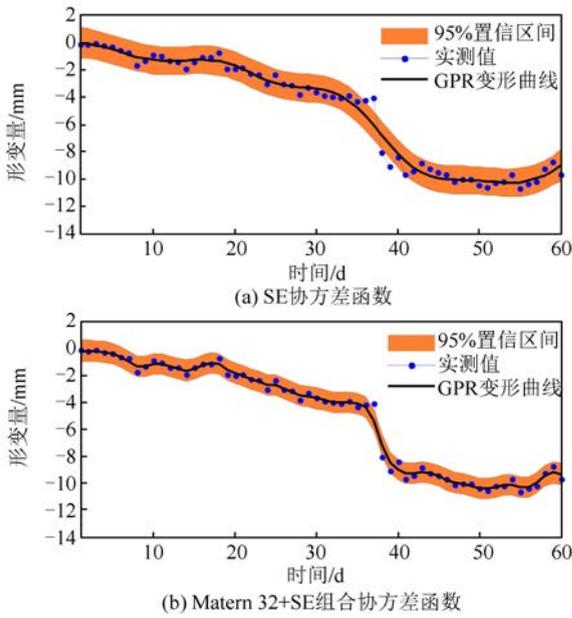


图 5 不同核函数输出的变形曲线

Fig.5 The Deformation Curve of the Different Kernel Function

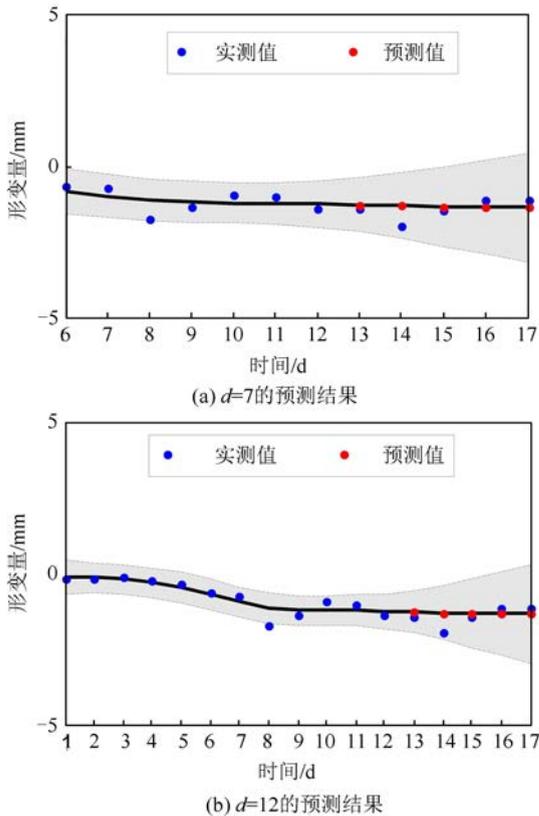


图 6 不同样本数量的预测曲线

Fig.6 The Prediction Curves of Different Sample Size

从图可以看出,距离学习样本集最近的未来第 1 天的预测值与实测值的偏差最小,第 3 天最大。未来第 1 天的预测时间是从第 13~58 天,有 91% 的预测值位于置信区间内;未来第 2 天的预测时间是从第 14~59 天,有 85% 的预测值落入置信区间内;未来第 3 天的预测时间是从第 15~60 天,有 78% 的预测值落入置信区间内。

为了客观定量地评价 GPR-TIPM 的预测性能,实验计算了预测中误差 σ_k 和平均相对误差 MRE 来衡量预测精度,计算结果见表 2。

表 2 预测精度对比

Tab.2 The Comparison of Prediction Accuracy

指标	第 1 天	第 2 天	第 3 天
MRE/%	13	16	20
σ_k /mm	0.9	1.1	1.4

实验结果表明距离学习样本越远,其预测精度越低,如果没有新的实测值更新学习样本,预测误差会越来越大。与其相对的一面,距离学习样本越近,其预测误差总体上越小,但有个别预测周期的第 1 天的预测预测误差会大一些。预测误差较大的是发生“抖动”较大的位置,如第 38 天的相对误差为 48%。理论上,GPR-TIPM 模型可以预测的更远,但预测结果的可靠性程度会降低。

4 结 语

本文首先研究了 GPR 用于变形预测时“递进-截尾式”超参数动态更新模式,进一步给出了训练样本集的选择方法,在此基础上提出 GPR-TIPM 非线性智能预测模型。GPR 是在函数空间内进行贝叶斯推理的,使得 GPR-TIPM 能够输出光滑预测中心线和置信区间。GPR-TIPM 对建模的样本数据要求不苛刻,能够适应于非平稳数据。理论上 GPR-TIPM 能够进行长远预测,由于输入量与超参数不适应,使得其预测精度会降低。

应用 GPR-TIPM 对 2# 边坡的短期内的变形进行预测,并用实测值分析其预测精度,结果表明 GPR-TIPM 用于变形预测是可行的。GPR-TIPM 预测模型仅以时间作为驱动因子,是一维预测模型,GPR-TIPM 没有顾及监测数据的自相关性,这是其不足的一面。

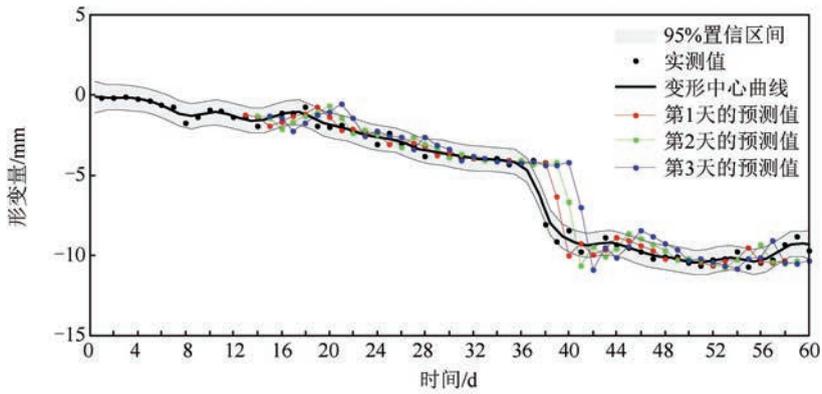


图 7 GPR-TIPM 时间-沉降曲线

Fig.7 The Time-Displacement Curve Based on GPR-TIPM

参 考 文 献

- [1] Stojanovic B, Milivojevic M, Ivanovic M. Adaptive System for Dam Behavior Modeling Based on linear Regression and Genetic Algorithms[J]. *Advances in Engineering Software*, 2013, 65: 182-190
- [2] Lu Jun, Dai Wujiao, Zhang Zhetao. Modeling Dam Deformatin Using Varying Goefficient Regression [J]. *Geomatics and Information Science of Wuhan University*, 2015, 40 (1): 139-142 (卢骏, 戴吾蛟, 章浙涛. 大坝变形变系数回归建模[J]. 武汉大学学报·信息科学版, 2015, 40(1): 139-142)
- [3] Grelle G, Guadagno I F M. Regression Analysis for Seismic Slope Instability Based on a Double Phase Viscoplastic Sliding Model of the Rigid Block[J]. *Landslides*, 2013, 10(5): 583-597
- [4] Chen Xiaopeng, Zhang Qiangyoun, Liu Dawen. Deformation Statistical Regression Analysis Model of Slope and Its Application[J]. *Chinese Journal of Rock Mechanics and Engineering*, 2008, 27(S2): 3 673-3 678 (陈晓鹏, 张强勇, 刘大文. 边坡变形统计回归分析模型及应用[J]. 岩石力学与工程学报, 2008, 27(S2): 3673-3678)
- [5] Wang Q, Wang C, Xie R. An Improved SCGM(1, m) Model for Multi-point Deformation Analysis[J]. *Geosciences Journal*, 2014, 18(4): 477-484
- [6] Huang Shengxiang, Yin Hui, Jiang Zheng. Deformation Monitoring Data Processing[M]. Wuhan: Wuhan University Press, 2010 (黄声享, 尹晖, 蒋征. 变形监测数据处理[M]. 武汉: 武汉大学出版社, 2012)
- [7] Wu Xueling, Ren Fu, Niu Ruiqing. Spatial Intelligent Prediction of Landslide Hazard Based on Multi-source Data in Three Corges Reservoir Area[J]. *Geomatics and Information Science of Wuhan University*, 2013, 38(8): 963-968 (武雪玲, 任福, 牛瑞卿. 多源数据支持下的三峡库区滑坡灾害空间智能预测[J]. 武汉大学学报·信息科学版, 2013, 38(8): 963-968)
- [8] Li L, Huang G. Procedia Engineering Prediction of Goaf Settlement with Time Sequence of Wavelet Neural Network[J]. *Procedia Engineering*, 2011, 15: 4723-4727
- [9] Suwansawat S, Einstein H H. Artificial Neural Networks for Predicting the Maximum Surface Settlement Caused by EPB Shield Tunneling[J]. *Tunnelling and Underground Space Technology*, 2006, 21: 133-150
- [10] Zhang Zhenglv, Huang Quanyi, Wen Hongyan. Deformation Monitoring Analysis and Prediction for Engineering Constructions[M]. Beijing: Surveying and Mapping Press, 2007 (张正禄, 黄全义, 文鸿雁. 工程的变形监测分析与预报[M]. 北京: 测绘出版社, 2007)
- [11] Li P, Tan Z, Yan L, et al. Time Series Prediction of Mining Subsidence Based on a SVM[J]. *Mining Science and Technology, China University of Mining & Technology*, 2011, 21(4): 557-562
- [12] Li Dejiang, Hua Xianghong, Li Tao. Researchon Predictive Modeling of Bulding Settlement Based on Support Vector Mechine[J]. *Engineering of Surveying and Mapping*, 2009, 18(3): 29-31 (李德江, 花向红, 李涛. 基于支持向量机的建筑物沉降预测模型研究[J]. 测绘工程, 2009, 18(3): 29-31)
- [13] Zhang H, Wang Y, Li Y. SVM Model for Estimating the Parameters of the Probability-integral Method of Predicting Mining Subsidence[J]. *Mining Science and Technology (China), China University of Mining and Technology*, 2009, 19(3): 385-388
- [14] Li S, Zhao H, Ru Z. Deformation Prediction of Tunnel Surrounding Rock Mass Using CPSO-SVM Model[J]. *Journal of Central South University*,

- 2012, 19(11): 3311-3319
- [15] Pan Ping. Slope Displacement Forecase Based On-wavelet Neural Network[J]. *Journal of Chengdu University of Technology: Sci & Technology*, 2006, 33(2): 176-180(潘平. 基于小波神经网络理论的边坡位移预测[J]. 成都理工大学学报(自然科学版), 2006, 33(2): 176-180)
- [16] He Zhikun, Liu Guangbin, Zhao Xijing. Overview of Gaussian Process Regression[J]. *Control and Decision*, 2013, 28(8): 1 121-1 129(何志昆, 刘光斌, 赵曦晶. 高斯过程回归方法综述[J]. 控制与决策, 2013, 28(8): 1 121-1 129)
- [17] Su G S. Gaussian Process-based Dynamic Response Surface Method for Estimating Slope Failure Probability[J]. *Yantu Lixue/Rock and Soil Mechanics*, 2014, 35(12): 3 592-3 601
- [18] Zhang Yan. Gaussina Process Model for Forecasting Andidentifying Nonlinear Behaviorofunderground Engineering Rockmass Anddynamic Intelligent Feedback Analysis[D]. Nanning: Guangxi University, 2013(张研. 地下工程岩体非线性行为预测识别的高斯过程模型与动态智能反馈分析[D]. 南宁: 广西大学, 2013)
- [19] Su Guoshao, Xiao Yilong. Gaussian Process Method for Slope Reliability Analysis[J]. *Chinese Journal of Geotechnical Engineering*, 2011, 33(6): 916-920(苏国韶, 肖义龙. 边坡可靠度分析的高斯过程方法[J]. 岩土工程学报, 2011, 33(6): 916-920)
- [20] Xia Zineng. Forecasting Method of Nonlinear Time Series of Slopedeormat Using Gaussian Process [D]. Nanning: Guangxi University, 2013(夏自能. 边坡位移非线性时间序列的高斯过程预测方法[D]. 南宁: 广西大学, 2012)
- [21] Rasmussen C E, Williams C K. Gaussian Processes for Machine Learning[M]. Cambridge, MA: MIT Press, 2006

Deformation Intelligent Prediction Model Based on Gaussian Process Regression and Application

WANG Jianmin¹ ZHANG Jin¹

¹ College of Mining Engineering, Taiyuan University of Technology, Taiyuan 030024, China

Abstract: The deformation of building structures or rock mass usually has the features of complexity and nonlinearity that the general regression model cannot accurately predict. In this paper, gaussian process regression(GPR) theory is applied in time series analysis of nonlinear deformation monitoring data. Considering the unceasing updates and massive accumulation of monitoring data, the hyper-parameter and the adaptability of sample set, a “progressive~truncation type” hyper-parameter automatic update mode and selection method for training sample set was developed. On this basis, a GPR time-driven deformation intelligent prediction model(GPR-TIPM) was constructed. This model was applied to the nonlinear time series analysis of monitoring points on a mine slope. By analyzing the deformation trend, a composite kernel optimization method including the “Matérn32” and square exponential covariance kernel function is proposed. The experimental results showed that the prediction performance of the combined kernel function is better than that of the single kernel function, and improved the generalization ability of the model The prediction effect of GPR-TIPM model is better in the short term.

Key words: deformation monitoring; gaussian process regression; intelligent predict; time series; mine slope

First author: WANG Jianmin, associate professor, specializes in deformation monitoring. E-mail: 8844.4321@163.com

Foundation support: The Natural Science Foundation of Shanxi Province, No. 201701D121014; the National Natural Science Foundation of China, No. 41371373.