

文章编号: 1000-7598 (2011) 06-1669-07

基于粒子群-高斯过程回归耦合算法的 滑坡位移时序分析预测智能模型

徐 冲, 刘保国, 刘开云, 郭佳奇

(北京交通大学 土木建筑工程学院, 北京 100044)

摘 要: 高斯过程回归(GPR)学习机有着容易实现、超参数自适应获取及预测输出具有概率意义等优点。通常采用共轭梯度法获取 GPR 超参数, 但其存在优化效果对初值依赖性太强, 迭代次数难以确定, 易陷入局部最优的缺点。改用粒子群优化(PSO)算法进行最优超参数搜索, 形成粒子群-高斯过程回归耦合算法(PSO-GPR)。将该算法引入三峡永久船闸高边坡、卧龙寺新滑坡、链子崖滑坡 3 个不同的典型滑坡变形时序分析中, 对每个滑坡分别采用稳态核及一种新式神经网络(NN)、平方指数(SE)、有理二次型(RQ) 3 种单一核函数进行外推预报测试。工程应用表明, 基于 3 种不同单一核函数的粒子群-高斯过程回归算法(PSO-GPR)均能完全适应不同滑坡时序分析, 其中以 NN 核函数外推预测效果最佳, 平均相对误差分别为 6.37%、7.62%、1.07%, 从而改善了在进行不同滑坡变形时序分析时采用单一核函数的核机器外推能力存在较大差异性的问题, 提高了单一核函数对不同数据类型的兼容性。

关 键 词: 滑坡; 粒子群优化; 高斯过程回归; 时序分析; 位移预报

中图分类号: TB 115

文献标识码: A

Intelligent analysis model of landslide displacement time series based on coupling PSO-GPR

XU Chong, LIU Bao-guo, LIU Kai-yun, GUO Jia-qi

(School of Civil Engineering, Beijing Jiaotong University, Beijing 100044, China)

Abstract: Gaussian process regression (GPR) takes advantages of programming easily; self-adaptive acquisition of hyperparameters and prediction with probability interpretation. At present the hyperparameters are got by maximizing likelihood function of training samples based on conjugate gradient algorithm. However, the algorithm embodies the disadvantages of too strong dependence of optimization effect on initial value, difficultly determination of iteration steps, easily falling into local optimum. On the basis of mentioned above, particle swarm optimization (PSO) was used to optimize the hyperparameters of the GPR then formed the PSO-GPR coupling, and the corresponding source code was programmed. So the PSO-GPR with the neural network covariance function (NN), squared exponential covariance function (SE) and rational quadratic covariance function (RQ) is respectively applied to analyze slope displacement time series in order to test generalization ability of the algorithm. The analysis results of slope displacement time series show that the proposed PSO-GPR based on different single kernel function are all suitable for all kinds of slope deformation analysis and difference of prediction accuracy is little based on different single functions. Furthermore, the problem that there is differential the regression and generalization ability of kernel machine with different functions is solved; and the kernel function compatibility with different data is boosted.

Key words: landslide; particle swarm optimization; Gaussian process regression; time series; displacement prediction

1 引 言

滑坡灾害分布广、发生频率高、移动速度快且灾害损失大。随着我国基础设施投资建设加快, 西

北、西南山区地带的工程建设规模不断加大, 滑坡灾害严重威胁和影响工程施工及生命财产安全。因此, 对滑坡这类突发性地质灾害进行定量预测一直是滑坡研究的重点内容。滑坡是受地质过程、赋

收稿日期: 2009-12-10

基金项目: 国家 863 计划资助课题 (No. 2007AA11Z109)。

第一作者简介: 徐冲, 男, 1984 年生, 博士研究生, 主要从事岩土工程中的计算智能与数值分析研究。E-mail: 05121266@bjtu.edu.cn

存介质环境及人类活动等影响因素的多尺度、高非线性动力开放系统。然而, 这些形成条件、诱发因素通常具有随机性、模糊性及离散性, 进而造成神经网络、灰色系统、支持向量回归(SVR)等传统方法在滑坡位移监测和预测中效果不佳。为此, 本文将建立一种全新的核学习机对滑坡位移监测数据进行时序分析, 建立智能高效的外推模型以体现滑坡变形规律, 进而对滑坡体结构稳定状态做出判断。

变形预测方法都是通过建立滑坡变形时序分析外推模型来表达映射变形数据中的随机因素影响, 继而对未来滑坡变形做出预测以体现滑坡变化发展演化的动态过程。最简单的指数、双曲线函数模型是利用确定数学函数来表达变量间关系, 本质上仍属于回归分析, 无法表达滑坡变形演化过程中的突变特性; 灰色系统要求累加生成的新数据列具有灰指数规律, 同时灰色系统建模用的数据序列要求具有非负性^[1]; 人工神经网络尽管可以用来构建具有强非线性关系的围岩时程变形模型^[2-3], 但神经网络基于经验风险最小化准则, 存在大样本、过学习、推广能力较差和局部优化的缺点; SVR 具有小样本、全局优化和推广性能好的优点。董辉等^[4]基于核函数构造对 3 个典型滑坡类型进行拟合外推预测, 尽管预测精度比灰色系统较高且采用了基于 Mercer 核理论而构造了较为复杂的新核函数, 但当采用某一固定构造核函数对不同滑坡进行预测时, 彼此间的预测性能存在较大差异性。换言之, 就是该新构造核函数对不同数据类型没有兼容性, 反而增加了核机器自身参数。

高斯过程回归(Gaussian process regression, 简称 GPR)作为一种全新学习机, 苏国韶等^[5-6]已成功应用于基坑位移时序分析和岩爆的预测研究, 均取得了远优于上述传统方法的预测效果。但目前仍然采用共轭梯度法获取 GPR 最优超参数, 共轭梯度法存在优化效果过度依赖初值、迭代次数难定和局部优化的弊端, 这限制了该算法适用性^[5-7, 13]。本文引入一种仿生算法——粒子群算法(Particle swarm optimization, 简称 PSO), 形成粒子群-高斯过程回归算法(PSO-GPR), 将该算法引入三峡永久船闸高边坡、卧龙寺新滑坡、链子崖滑坡 3 个不同的滑坡位移时序分析中, 探索能适应 3 类不同滑坡类型的单一核函数, 以此改善单一核函数对不同数据类型的兼容性。

2 标准粒子群算法简介

粒子群算法最早由 Kennedy 和 Eberhart 于 1995

年提出, 其基本概念源于对鸟群觅食行为的研究^[8]。该算法受此生物种群行为特性启发并应用于求解优化问题。目前, 许多从事算法研究的学者对其进行了改进, 其中以 Shi 和 Eberhart 提出的具有惯性权重的粒子群算法最为著名, 称之为标准粒子群算法^[9]。

为不失一般性, 本文以最小化系统适应度函数 f 为优化目标, 标准粒子群算法可描述如下^[10]:

$$\left. \begin{aligned} v_i^{m+1} &= w_i^m v_i^m + c_1 r_1 (pbest_i^m - x_i^m) + c_2 r_2 (gbest^m - x_i^m) \\ x_i^{m+1} &= x_i^m + v_i^{m+1} \\ pbest_i^{m+1} &= \begin{cases} x_i^{m+1}, & f(x_i^{m+1}) < f(pbest_i^m) \\ pbest_i^m, & f(x_i^{m+1}) \geq f(pbest_i^m) \end{cases} \\ gbest^{m+1} &= \arg \min f(gbest^m), f(pbest_i^{m+1}) \end{aligned} \right\} \quad (1)$$

式中: x_i 、 v_i 、 $pbest_i$ 分别为第 i 个粒子当前位置、当前速度、个体历史最优位置; $gbest$ 为所有粒子经历的最好位置; w 为惯性权重, 取较大值有利于算法在较大范围内进行搜索, 而取较小值有利于在局部进行精细搜索; c_1 为个体进化因子; c_2 为社会进化因子, 取值均在 $[0, 2]$; r_1 、 r_2 为服从 $U(0, 1)$ 分布的相互独立随机向量。

3 高斯过程及其回归算法

高斯过程(Gaussian process, 简称 GP)又称正态随机过程, 其任意有限变量集合都有着联合高斯分布特性, 即任意一组随机变量 X 与其对应的过程状态 $f(X)$ 的联合概率分布服从 n 维高斯分布。从函数空间视角看, GP 全部统计特征可由其均值 $\mu(t)$ 及协方差 $C(t, t')$ 确定^[11-12], 定义如下:

$$f(t) \sim GP\{\mu(t), C(t, t')\} \quad (2)$$

3.1 高斯过程学习

将数据集 $D = \{(x^i, y^i), i=1, \dots, n\}$ 作为高斯模型的训练集, x^i 为 d 维输入矢量, 观测目标 $y^i \in R$ 。如果用 X 表示 $d \times n$ 维输入矩阵, y 表示输出矢量, 则训练集表示为 $D = \{X, y\}$, 同时, 带有高斯白噪声的标准线性回归模型可表示为

$$y = f(X) + \varepsilon \quad (3)$$

式中: ε 为独立的随机变量, $\varepsilon \sim N(0, \sigma_n^2)$, 其中 σ_n 为方差。

由式 (3) 得观测目标值 y 的先验分布为

$$y \sim N(0, C + \sigma_n^2 I) \quad (4)$$

对于新测试输入 x^* , GP 根据式 (4) 中 y 的先

验知识先建立训练样本输出 y 和测试样本输出 y^* 所形成的联合高斯先验分布:

$$\begin{bmatrix} y \\ y^* \end{bmatrix} \sim N \left(0, \begin{bmatrix} C(X, X) + \sigma_n^2 I & C(X, x^*) \\ C(X, x^*) & C(x^*, x^*) \end{bmatrix} \right) \quad (5)$$

式中: $C(X, X)$ 为 $n \times n$ 阶对称正定的协方差矩阵, 其任意项 c^{ij} 度量了 x^i 和 x^j 的相关性; $C(X, x^*)$ 为测试 x^* 与训练集的所有输入点 X 的 $n \times 1$ 阶协方差矩阵; $C(x^*, x^*)$ 为测试点 x^* 自身的协方差。

3.2 高斯过程预测

在给定输入 x^* 和训练集 D 的条件下, GP 的目标是通过后验概率公式计算出与 x^* 对应的 y^* , 即

$$y^* | x^*, D \sim N(\mu_{y^*}, \sigma_{y^*}^2) \quad (6)$$

$$\mu_{y^*} = C(x^*, X)(C(X, X) + \sigma_n^2 I)^{-1} y = \sum_i \alpha_i C(x^i, x^*) \quad (7)$$

式中: μ_{y^*} 、 $\sigma_{y^*}^2$ 为 y^* 的期望和方差; $\alpha = (C + \sigma_n^2 I)^{-1} y$, I 为单位矩阵。

从式 (7) 的线性表达来看, GP 的协方差函数等价于传统机器学习的核函数。核方法是将研究数据嵌入到一个合适的被称为特征空间的向量空间, 然后通过线性、几何和统计方法, 以寻找数据的线性关系^[4]。因此, 满足积分算子理论中 Mercer 定理条件的核函数可分为稳态和非稳态 2 类, 其中, 稳态核不依赖个体输入向量, 而是取决于向量间的差异, 即 $C(x^i, x^j) = C(x^i - x^j)$; 非稳态核依赖于输入样本在特征空间的点积操作, 因而有较好的全局性质。传统的非稳态核有多项式核和线性核, 但通常多项式核由于阶数的增加会出现过拟合现象。对某一具体核函数, 其具有自动相关性判定 (automatic relevance determination, 简称 ARD) 和各项同性 (isotropic, 简称 ISO) 两类形式。区别在于前者的超参数 ℓ 的维数与输入变量 X 的维数相同, 即对输入变量 X 的任一分量 x^i , ℓ 都有一个分量 ℓ_i 与之对应; 而后者 ℓ 不随输入变量维数而改变, 即认为所有输入与输出的相关性是相同的。最后, GP 通过对训练样本的对数似然函数采用共轭梯度法获得最优超参数^[11], 故本文分别采用平方指数 (squared exponential covariance function, 简称 SE)、有理二次 (rational quadratic covariance function, 简称 RQ) 稳态核及一种新式神经网络 (neural network covariance function, 简称 NN) 非稳态核对比研究。

(1) SE 核函数

$$C_{SE}(x^i, x^j) = \sigma_f^2 \exp \left(-\frac{P(x^i - x^j)^2}{2} \right) + \sigma_n^2 \delta^{ij} \quad (8)$$

(2) RQ 核函数

$$C_{RQ} = \sigma_f^2 \left(1 + \frac{(x^i - x^j)^2 P}{2\alpha} \right)^{-\alpha} + \sigma_n^2 \delta^{ij} \quad (9)$$

(3) NN 核函数

$$C_{NN} = \sigma_f^2 \left(\sin^{-1} \left(\frac{2\tilde{x}^i P \sum \tilde{x}^j}{\sqrt{(1 + 2\tilde{x}^i P \sum \tilde{x}^i)(1 + 2\tilde{x}^j P \sum \tilde{x}^j)}} \right) \right) + \sigma_n^2 \delta^{ij} \quad (10)$$

式中: 令 $\theta = (\{P\}, \sigma_f^2, \sigma_n^2)$ 为包含所有超参数的向量; $\{P\} = \ell^{-2} I$ 表示超参数 ℓ^{-2} 与 I 的乘积矩阵; σ_f^2 为核函数的信号方差, 是控制局部相关性的程度; α 为核函数的形状参数; $\tilde{x}$ 为 x 的增广矩阵, 即 $\tilde{x} = (1, x)^T$ 。




图1 PSO-GPR 算法流程图

Fig.1 Flow diagram of the PSO-GPR algorithm

4 滑坡变形时序分析智能模型

4.1 粒子群-高斯过程回归算法

PSO 最大的特点在于程序化处理方便、参数较少、算法实现简单且粒子具有记忆性, 同时 *gbest* 将信息单向传递给其他粒子, 这样的信息共享机制更有利于算法快速收敛。因此, 为了克服共轭梯度法的缺陷, 基于 MATLAB 平台, 采用 PSO 算法对样本训练过程的 GPR 进行自动最优超参数搜索, 形成粒子群——高斯过程回归算法。流程图如图 1 所示。具体实现步骤如下:

①初始化 PSO 的网络参数, 包括确定粒子群规模、迭代次数、粒子随机解—粒子初速度和粒子初始位置, 其中每个粒子向量代表了一个 GPR 网络模型, 不同模型对应不同的 GPR 网络参数。

②GPR 网络对样本进行训练和测试, 计算出每个粒子个体的适应度值 f_i 。

③把步骤②中算出的适应值 f_i 与粒子在先前

迭代历史中的最佳适应值 $f(pbest_i)$ 比较, 如果前者小于后者, 则用新的适应值取代前一轮的 $f(pbest_i)$, 用新的粒子取代前一轮的粒子。

④将每个粒子的最佳适应值 $f(pbest_i)$ 与所有粒子的最佳适应值 $f(gbest)$ 进行比较。如果 $f(pbest_i) < f(gbest)$, 则用该粒子的最佳适应值取代原有全局最佳适应值, 同时保存粒子的当前状态。

⑤当网络满足预设迭代步数时结束程序并返回当前适应值最小的粒子, 找到最优解; 如不满足, 再进行新一轮迭代, 采用式(1)更新粒子的位置和速度, 即产生新的粒子, 返回到步骤②, 直到满足最大迭代步, 算法结束。




图2 典型滑坡时序曲线

Fig.2 Typical curves of landslide time series

4.2 滑坡变形时序分析

4.2.1 典型滑坡变形时间序列曲线

由于影响边坡稳定性的地质和工程因素通常具有随机性、模糊性及离散性, 因而一次完整的滑坡破坏通常伴随着跳跃及突变性。

文献[4]将滑坡时间序列归纳为4种类型。图2为以链子崖、三峡船闸及卧龙寺为代表的3类典型滑坡变形曲线, 其分属减速-匀速型、匀速-增速型、复合型。减速-匀速型和匀速-增速型属于简单滑坡变形模式, 前者变形速率稳定、波动较小、规律性强, 故可通过简单的指数函数方法进行拟合回归; 后者往往在变形发展后期存在位移突变, 预测模型的训练学习样本包含不完整的监测信息分布和发展规律, 导致预测模型对后期变形发展外推能力差; 复合型时序曲线包含了上述两种简单曲线的信息特征, 故将匀速-增速(突变)和复合型作为本文主要研究对象。

4.2.2 滚动预测方法^[13]

滚动预测过程如下: 假设已经获得前 k 天的变形时序 $\{x_i, y_i\} (i = 1, \dots, k)$, 取前 p 天数据作为初

次网络训练的学习样本, 剩下的 $(k-p)$ 天变形数据作为初次网络训练的测试样本, 初次训练完成后, 对时间 t 天的变形进行一次预测, 然后将 t 天的实测变形时序 $\{x_i, y_i\} (i = k+1, \dots, k+t)$ 加入初次样本集并剔除原样本集的 t 变形数据, 即第2次网络训练的学习样本为 $\{x_i, y_i\} (i = t+1, \dots, p+t)$, 而将变形时序 $\{x_i, y_i\} (i = t+1, \dots, k+t)$ 中剩下的 $(k-p)$ 变形时序 $\{x_i, y_i\} (i = p+t+1, \dots, k+t)$ 作为第2次网络训练的测试样本, 即第2次网络训练时学习及测试样本的数目和第1次保持一致, 再进行一次 t 的变形预测, 待 t 的实测变形获得后, 遵循每次网络训练的学习及测试样本数不变, 而用最新采集的变形数据更新训练样本集的原则, 依此类推, 按照以上步骤组成后续网络训练的学习样本和测试样本。

4.2.3 滑坡非线性变形智能预测

选取文献[4]的3个滑坡监测数据作为工程算例。实测数据如表1~3所列。在此分别取 $k = (27, 36, 8)$, $p = (26, 35, 7)$, $t = (1, 1, 1)$, GPR核函数分别采用NN、SE和RQ, PSO算法的粒子范围: $[w_{\min}, w_{\max}] = [0.3, 0.9]$, 学习因子 c_1, c_2 都取2, 种群规模取20, 最大迭代步数为100, 适应度函数为

$$f = \frac{1}{m} \sum_{i=1}^m (g(x_i) - y_i)^2 \quad (11)$$

式中: $g(x_i)$ 为网络训练时第 i 个测试样本的预测值; y_i 为第 i 个测试样本的样本值。

最后, 分别对3个滑坡变形进行了预测分析, 适应度值变化曲线如图3所示, 预测结果见表4。在历次网络训练过程中, 搜索到的GPR最优超参数见表5。

表1 三峡永久船闸高边坡 TP/BM11GP02 测点位移数据
Table 1 Measured displacements of monitoring point TP/BM11GP02 of permanent ship lock slope of Three Gorge Project

监测时间/年-月-日	变形/mm	监测时间/年-月-日	变形/mm
1996-11-15	0.00	1998-04-12	8.43
1996-12-14	0.05	1998-05-16	7.54
1997-01-14	0.79	1998-06-14	10.99
1997-02-15	0.40	1998-07-13	10.16
1997-03-12	1.13	1998-08-10	12.33
1997-04-15	1.79	1998-09-16	14.00
1997-05-16	1.46	1998-10-08	14.45
1997-06-15	1.37	1998-11-09	16.05
1997-07-14	1.94	1998-12-10	17.52
1997-08-16	2.32	1999-01-08	20.11
1997-09-15	2.53	1999-02-04	19.24
1997-10-17	3.72	1999-03-09	22.41
1997-11-18	4.18	1999-04-09	22.45
1997-12-10	5.18	1999-05-15	23.75
1998-01-14	5.71	1999-06-15	23.24
1998-02-14	6.26	1999-07-15	22.95
1998-03-16	7.73		

表2 卧龙寺新滑坡变形实测数据
Table 2 Measured displacements of Wolongsi

监测时间/年-月-日	变形/mm	监测时间/年-月-日	变形/mm
1971-03-25	7.0	1971-04-15	16.1
1971-03-26	7.3	1971-04-16	16.4
1971-03-27	7.8	1971-04-17	17.2
1971-03-28	8.2	1971-04-18	17.6
1971-03-29	8.4	1971-04-19	18.2
1971-03-30	8.7	1971-04-20	19.0
1971-03-31	9.0	1971-04-21	19.2
1971-04-01	9.2	1971-04-22	20.0
1971-04-02	9.4	1971-04-23	23.0
1971-04-03	10.0	1971-04-24	24.0
1971-04-04	10.1	1971-04-25	25.2
1971-04-05	10.3	1971-04-26	26.0
1971-04-06	10.4	1971-04-27	27.0
1971-04-07	10.5	1971-04-28	28.2
1971-04-08	10.8	1971-04-29	30.0
1971-04-09	11.1	1971-04-30	31.0
1971-04-10	12.0	1971-05-01	32.0
1971-04-11	13.0	1971-05-02	33.0
1971-04-12	13.4	1971-05-03	42.0
1971-04-13	14.0	1971-05-04	47.0
1971-04-14	15.0	1971-05-05	61.0

表3 链子崖滑坡G_A测点位移实测数据
Table 3 Measured displacement of monitoring point G_A of permanent landslide of Lianziya

监测时间/年-月	变形/mm	监测时间/年-月	变形/mm
1978-12	10.32	1984-12	47.16
1979-12	26.96	1985-12	48.38
1980-12	34.07	1986-12	49.95
1981-12	38.65	1987-12	51.75
1982-12	42.98	1988-12	52.50
1983-12	44.93		

4.3 计算结果分析

由表 4、6 的外推预测值和平均相对误差指标可见, 采用 PSO 进行网络参数优化后 GPR 外推预

测能力明显强于基于遗传算法(genetic algorithm, 简称 GA)和传统共轭梯度法的 GPR, 避免了梯度法初始参数选择盲目的问题。同时, 采用 GA-GPR 和 GPR 进行 3 类滑坡预测, 基于 3 种核函数的预测误差大于等于 10% 共计分别为 13 和 8 项, 而 PSO-GPR 仅为 7 项。




图3 适应度值随迭代步变化曲线

Fig.3 The curve of evolutionary fitness value as iterative step

在核函数选择方面, 无论采用粒子群、遗传算法哪种优化方法, 相对于 SE 和 RQ 核函数, NN 核函数均表现出较好的外推预测能力, 以粒子群优化效果最佳。具体表现为, 在对卧龙寺和链子崖滑坡外推预测时均获得最小误差, 分别为 7.62% 和 1.07%, 而 RQ 核函数对三峡滑坡外推效果稍强于 NN, 为 4.89%。另一方面, 与文献[4]中基于支持向量机(SVM)的构造核函数—多项式核与高斯核的线性组合核函数(linear combination of polynomial and gaussian covariance function, 简称 LPG)相比, 后者对卧龙寺这类具有突变特性的滑坡变形外推预测较

表4 基于 PSO/GA-GPR 不同核函数的三组滑坡变形外推预测
Table 4 Extrapolation forecast of three landslides based on PSO/GA-GPR with three kernel functions

滑坡实例	日期 /年-月-日	变形 /mm	GA-GPR 外推预测变形/mm			PSO-GPR 外推预测变形/mm			GPR 外推预测变形/mm		
			NN	SE	RQ	NN	SE	RQ	NN	SE	RQ
三峡永久船闸高边坡	1999-02-04	19.24	21.08	24.64	24.51	20.74	21.15	20.57	20.80	20.76	20.76
	1999-03-09	22.41	20.58	20.51	20.51	20.30	18.80	20.96	21.54	21.42	21.41
	1999-04-09	22.45	23.87	23.47	23.45	24.21	23.57	23.55	23.43	23.35	23.35
	1999-05-15	23.75	23.95	23.87	23.84	23.86	22.88	23.16	24.50	24.34	24.32
	1999-06-15	23.24	24.52	24.43	24.43	25.04	24.92	24.83	25.62	25.98	25.31
卧龙寺新滑坡	1999-07-15	22.95	24.29	24.27	24.26	24.09	22.77	22.52	25.99	25.97	24.99
	1971-04-30	31.00	31.49	31.56	31.59	31.43	31.48	31.45	31.17	30.28	30.46
	1971-05-01	32.00	32.00	32.42	32.41	32.37	32.25	32.27	32.57	31.61	31.79
	1971-05-02	33.00	32.86	33.35	33.34	33.23	33.05	33.18	33.85	32.67	32.90
	1971-05-03	42.00	33.82	34.32	34.32	34.23	34.04	34.94	35.00	33.59	33.86
链子崖滑坡	1971-05-04	47.00	37.25	36.48	36.5	37.23	37.41	36.74	38.59	38.94	38.99
	1971-05-05	61.00	56.27	56.88	56.57	59.07	57.83	56.51	44.24	54.75	53.85
	1986-12	49.95	50.06	48.59	47.78	49.32	49.16	49.19	49.33	47.21	47.39
链子崖滑坡	1987-12	51.75	51.06	50.17	51.17	50.85	51.82	49.40	50.71	49.11	49.39
	1988-12	52.50	53.56	54.42	53.02	52.59	53.77	52.65	52.48	51.51	52.59

表 5 基于粒子群优化的高斯过程回归算法历次网络训练最优超参数
Table 5 The optimal hyperparameters obtained by PSO-GPR during the each training process

滑坡实例	训练样本 起始编号	不同核函数训练参数									
		NN			SE			RQ			
		θ_1	θ_2	θ_3	θ_1	θ_2	θ_3	θ_1	θ_2	θ_3	θ_4
三峡永久 船闸高边坡	1~27	88.668	638.422	0.433	20.471	617.204	0.371	94.340	1571.4	36.281	0.373
	2~28	14.912	14.984	0.425	4.491	3.550	0.564	4.539	3.077	2.465	0.518
	3~29	147.983	2567.02	0.370	107.308	2077.7	0.373	92.851	1092.4	54.435	0.371
	4~30	45.227	48.477	0.892	7.257	8.008	0.502	10.624	5.751	4.032	0.548
	5~31	32.655	35.005	0.689	20.213	13.076	0.981	19.165	7.382	8.150	0.542
	6~32	11.898	11.147	0.666	5.966	4.881	0.518	5.414	4.2892	3.538	0.397
卧龙寺 新滑坡	1~36	340.665	31682	0.371	18.848	79.599	0.384	136.620	2057.6	9.194	0.369
	2~37	41.368	41.368	0.483	8.541	18.001	0.409	22.493	20.053	12.255	0.379
	3~38	31.655	53.474	0.424	14.150	16.387	0.780	21.411	12.640	8.137	0.463
	4~39	30.435	36.086	0.417	20.154	17.988	0.925	17.397	13.902	5.892	0.764
	5~40	316.809	10649	0.372	108.386	606.497	0.373	101.038	405.694	267.629	0.372
	6~41	15.975	6.777	0.388	3.695	10.796	0.531	4.851	8.968	3.021	0.379
链子崖滑坡	1~8	3.339	3.132	0.435	10.372	8.394	0.487	9.067	6.023	5.377	1.593
	2~9	4.197	3.097	0.690	12.386	13.656	0.841	10.453	9.867	5.511	1.132
	3~10	5.206	5.492	1.243	11.694	7.140	0.9230	12.572	8.809	5.402	2.298

表 6 误差统计表
Table 6 Error based different kernel functions

滑坡实例	核函数	不同算法外推预测误差/%											
		PSO-GPR				GA-GPR				GPR			
		最大误差	最小误差	平均误差	误差 ≥10	最大误差	最小误差	平均误差	误差 ≥10	最大误差	最小误差	平均误差	误差 ≥10
三峡永久船 闸高边坡	NN	9.42	0.46	6.37	0	9.56	0.84	6.04	0	13.25	3.16	7.17	2
	SE	16.11	0.78	7.12	1	28.07	0.51	8.74	1	11.79	2.48	7.29	2
	RQ	6.84	2.48	4.89	0	27.39	0.38	8.59	1	8.91	2.40	6.09	0
卧龙寺 新滑坡	NN	20.79	0.70	7.62	2	20.74	0.00	8.33	2	27.48	0.55	11.16	3
	SE	20.40	0.15	7.88	2	22.38	1.06	8.60	2	17.15	1.00	8.66	3
	RQ	21.83	0.55	8.14	2	22.34	1.03	8.68	2	19.38	0.30	8.47	3
链子崖滑坡	NN	1.74	0.17	1.07	0	2.02	0.22	1.19	0	2.01	0.04	1.10	0
	SE	2.42	0.14	1.38	0	3.66	2.72	3.14	0	5.49	1.89	4.16	0
	RQ	4.54	0.29	2.17	0	4.34	0.99	2.15	0	5.13	0.17	3.29	0
统计				5.18	7			6.16	8			6.38	13

好, 为 6.51%, 对链子崖滑坡这类传统指数回归型数据外推预测反而很差, 为 2.39%。而 NN 分别为 7.62%和 1.07%。但 NN 核函数自身参数少, 操作简易, 而 LPG 具有 3 个核参数且用于构造 LPG 的单一核函数之间的权重参数人为指定。故本文提出的 NN 核函数对 3 类滑坡时序分析具有一致的适用性, 改善了单一核函数对不同数据类型的兼容性且对三峡滑坡这种复合型时序数据预测与 RQ 差异性仅在 1.5%以内。

从本文提出的 PSO-GPR 算法简易性、有效性角度来看, 图 3 中最复杂的复合型时序数据的适应度值变化特征曲线反映了 PSO-GPR 具有较强的外推收敛能力, 其中, 适应度值的震荡减弱正是 PSO 对 GPR 网络参数的寻优过程, 期间外推误差随迭代步逐渐减小, 在经历 100 迭代步后就能获得较为满意的工程应用需求, 其参数寻优效果如表 4 所列, 表 5 的预测结果也进一步说明采用 PSO 优化能够较

好地提升 GPR 的泛化性能。

总体而言, NN 核函数构造简单, 改善了单一核函数对不同数据类型的适应兼容性, 能更加有效应用于核机器学习的核函数选择设计, 并较好地预测了变形时序的发展趋势。

5 结 论

(1) PSO 算法具有编程操作简单、网络参数少的特点, 采用粒子群算法代替共轭梯度法搜寻高斯过程最优超参数有效避免了共轭梯度法的缺陷, 能更有效地运用于 GPR 参数优化设计, 从而提高高斯过程回归的泛化性能。

(2) 不同核函数影响着核机器的学习和外推能力, 但总体而言本文采用的不同单一核函数分析效果差异性较小, 3 种单一核函数外推预测精度最大仅相差 2.23%。

(3) 本文提出的 PSO-GPR 算法经 3 种典型的

滑坡算例验证, 解决了在不同类型时序分析时采用单一核函数的核机器学习及外推能力存在较大差异性的问题, 提高了核函数对不同数据类型的兼容性, 尤其对三峡永久船闸高滑坡这类复合型和卧龙寺具有突变特性的时序变形分析, NN 神经元核函数预测误差分别仅为 6.37%、7.62%。

参 考 文 献

- [1] 谢峰, 朱陆明, 王立忠. 滑坡监控信息分析中的修正灰色系统预测模型及应用[J]. 岩石力学与工程学报, 2005, 24(22): 4100—4155.
XIE Feng, ZHU Lu-ming, WANG Li-zhong. Modified grey system forecasting model and its application for analyzing information of landside monitory[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2005, 24(22): 4100—4155.
- [2] 张孟喜, 李钢, 冯建龙, 等. 双连拱隧道围岩变形有限元与 BP 神经网络耦合分析[J]. 岩土力学, 2008, 29(5): 1243—1248.
ZHANG Meng-xi, LI Gang, FENG Jian-long, et al. Coupling analysis of surrounding rocks in double-arch tunnel by FE and BP neural networks[J]. **Rock and Soil Mechanics**, 2008, 29(5): 1243—1248.
- [3] 李长冬, 唐辉明, 胡斌, 等. 小波分析和 RBF 神经网络在地基沉降预测中的应用研究[J]. 岩土力学, 2008, 29(7): 1917—1922.
LI Chang-dong, TANG Hui-ming, HU Bin, et al. Research on application of wavelet analysis and RBF neural network to prediction of foundation settlement[J]. **Rock and Soil Mechanics**, 2008, 29(7): 1917—1922.
- [4] 董辉, 傅鹤林, 冷伍明. 滑坡位移时序预测的核函数构造[J]. 岩土力学, 2008, 29(4): 1087—1092.
DONG Hui, FU He-lin, LENG Wu-ming. Kernel design for displacement time series of landslide[J]. **Rock and Soil Mechanics**, 2008, 29(4): 1087—1092.
- [5] 苏国韶, 燕柳斌, 张小飞, 等. 基坑位移时间序列预测的高斯过程方法[J]. 广西大学学报, 2007, 32(2): 223—226.
SU Guo-shao, YAN Liu-bin, ZHANG Xiao-fei, et al. Time series prediction of foundation pit displacement using Gaussian process method[J]. **Journal of Guangxi University**, 2007, 32(2): 223—226.
- [6] 苏国韶, 宋咏春, 燕柳斌. 岩体爆破效应预测的一种新方法[J]. 岩石力学与工程学报, 2007, 26(增刊 1): 3509—3513.
SU Guo-shao, SONG Yong-chun, YAN Liu-bin. A new method for forecasting of blasting effect in rock mass[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2007, 26(Supp.1): 3509—3513.
- [7] 熊志化, 黄国宏, 邵惠鹤. 基于高斯过程和支持向量机的软测量建模比较及应用研究[J]. 信息与控制, 2004, 33(6): 754—757.
XIONG Zhi-hua, HUANG Guo-hong, SHAO Hui-he. Comparison and application research on soft sensor modeling based on Gaussian process and support vector machines[J]. **Information and Control**, 2004, 33(6): 754—757.
- [8] KENNEDY J, EBERHART R. Particle swarm optimization[C]//Proceedings of IEEE International Conference on Neural Networks. NJ: IEEE Service Center, Piscataway, 1995: 1942—1948.
- [9] SHI Y, EBERHART R. Empirical study of particle swarm optimization[C]//Proceedings of International Conference on Evolutionary Computation. Washington USA: IEEE, 1999: 1945—1950.
- [10] 曾建潮, 介婧, 崔志华. 微粒群算法[M]. 北京: 科学出版社, 2004.
- [11] RASMUSSEN C E, WILLIAMS C K I. Gaussian processes for machine learning[M]. Massachusetts: The MIT Press, 2006.
- [12] WILLIAMS C K I. Prediction with gaussian processes: From linear regression to linear prediction and beyond[R]. Birmingham: Aston University, 1997.
- [13] 刘开云, 刘保国, 徐冲. 基于遗传-组合核函数高斯过程回归算法的边坡非线性变形时序分析智能模型[J]. 岩石力学与工程学报, 2009, 28(10): 2128—2134.
LIU Kai-yun, LIU Bao-guo, XU Chong. Intelligent analysis model of slope nonlinear displacement time series based on genetic-Gaussian process regression algorithm of combined kernel function[J]. **Chinese Journal of Rock Mechanics and Engineering**, 2009, 28(10): 2128—2134.