

## 基于人工蜂群算法优化的改进高斯过程模型\*

张乐<sup>1,2</sup>, 刘忠<sup>1</sup>, 张建强<sup>1</sup>, 任雄伟<sup>1</sup>

(1. 海军工程大学 电子工程学院, 湖北 武汉 430033;

2. 武汉军械士官学校, 湖北 武汉 430075)

**摘要:**高斯过程(GP)的非线性特征导致其对大样本的训练时间复杂度过高,而且其超参数的选取是否适当直接影响高斯过程回归模型的预测精度。提出采用人工蜂群(ABC)算法优化改进GP以减小时间复杂度和提高预测精度。改进GP通过选取训练样本的子样本进行模型学习,以降低训练过程的时间复杂度。ABC通过优化改进GP的超参数,提升预测精度。选取训练样本的子样本构建改进GP回归(GPR)模型,采用ABC算法搜寻改进GPR的最优超参数,并用得到的超参数构建最优的改进GPR模型,输入测试样本进行预测并输出预测精度。将该模型应用于解决海上远程精确打击(LPSS)体系作战效能评估问题中,通过MATLAB仿真实验,与常见的多种优化方法相比较,验证了该模型的有效性。

**关键词:**改进高斯过程;人工蜂群算法;超参数;参数优化

**中图分类号:** TP39 **文献标志码:** A **文章编号:** 1001-2486(2014)01-0154-07

## Optimized improved Gaussian process model based on artificial bee colony algorithm

ZHANG Le<sup>1,2</sup>, LIU Zhong<sup>1</sup>, ZHANG Jianqiang<sup>1</sup>, REN Xiongwei<sup>1</sup>

(1. College of Electronic, Naval University of Engineering, Wuhan 430033, China;

2. Wuhan Mechanical Technology College, Wuhan 430075, China)

**Abstract:** Gaussian Process (GP) is characterized by the non-linear property, which leads to too high training time complexity for a large sample, And the hyper-parameters directly affect the prediction accuracy of Gaussian Process. The method of improved GP optimized by the artificial bee colony (ABC) algorithm is proposed to reduce the time complexity and to improve the prediction accuracy. Improved GP constructs the model by selecting a sub-sample of training samples to reduce training time. ABC optimizes the hyper-parameters of improved GP to improve prediction accuracy. Firstly, the improved GPR model is constructed by selecting a sub-sample of training samples; then it is followed by ABC algorithm searching the optimal hyper-parameters of improved GPR; finally the test sample is used to predict and output the prediction accuracy. The model is applied to solve maritime long-range precision sea strike (LPSS) system-of-systems operational effectiveness evaluation issues, and the MATLAB simulation experiments verify the validity of the model compared with other evolutionary algorithms.

**Key words:** improved gaussian process; artificial bee colony algorithm; hyper-parameters; parameters optimization

高斯过程<sup>[1]</sup>是在贝叶斯框架下对不确定问题进行合理估计的一种统计学习方法,目前已被广泛应用于分类<sup>[2]</sup>和回归<sup>[3-4]</sup>等机器学习问题中。针对高斯过程的非线性特征导致对于大样本训练数据的时间复杂度过高的问题,改进高斯过程<sup>[5]</sup>通过选择训练样本的子集进行模型学习,从而降低训练过程的时间复杂度。高斯过程的特征完全由均值函数和协方差函数决定<sup>[6]</sup>,为了公式表达的简化,一般设均值函数为零,协方差函数成为影响改进高斯过程的主要因素。因此,协方差

函数中超参数的确定成为直接影响高斯过程预测精度的关键问题。

传统高斯过程的超参数确定,采用共轭梯度法,通过最大化训练样本的对数似然函数获得。由于共轭梯度法具有迭代次数难以确定、对初值的依赖性较强和易陷入局部极小等缺点,文献[7]采用遗传算法(GA)搜索高斯过程的最优超参数,得到进化高斯过程回归模型,并应用于隧道围岩变形预测中。文献[8]采用粒子群优化算法(PSO)对高斯过程超参数优化,提出粒子群-高

\* 收稿日期:2013-08-01

基金项目:国家部委资助项目(513300303)

作者简介:张乐(1984—),男,湖北武汉人,博士研究生,E-mail:lzhang84@163.com;

刘忠(通信作者),男,教授,博士,博士生导师,E-mail:Liuzhong@163.com

斯过程回归耦合算法(PSO - GPR),并用于解决滑坡位移时序分析预测的问题。上述方法均在不同程度上提高了高斯过程回归模型的预测精度,但没有解决对于大训练样本高斯过程时间复杂度过大的问题。为了提高高斯过程回归模型的预测精度和泛化能力,文献[9]提出以组合核函数作为高斯过程的协方差函数,用于边坡角的设计中,并用共轭梯度法优化超参数,但也没有考虑大训练样本时间复杂度过高的问题。

针对以上文献中方法的缺陷,考虑到人工蜂群算法<sup>[10]</sup>(Artificial Bee Colony, ABC)相比粒子群优化算法<sup>[11]</sup>、差分进化算法<sup>[12]</sup>等智能优化算法在全局优化方面的优势,以及具有参数少,鲁棒性强的特点,本文提出采用ABC算法优化改进高斯过程。

## 1 改进高斯过程模型

由于高斯过程的非线性特性,当训练样本大小为 $N$ 时,训练过程的时间复杂度为 $O(N^3)$ 。改进高斯过程在满足样本一致性的前提下,采用有效选取训练样本子集的方法进行学习。一般训练样本子集 $M < N$ ,训练时间复杂度降低到 $O(M^2N)$ 。

### 1.1 定义

若给定训练样本集 $D = \{(x_i, y_i)\}_{i=1}^N$ ,其中 $N$ 是训练样本的大小, $x_i \in R^d$ 是输入数据, $y_i \in R$ 是对应的目标值。可定义输入数据 $x_i$ 的函数 $f(x_i)$ ,对于不同的输入数据值构成的随机变量 $\{f(x_1), f(x_2), \dots, f(x_N)\}$ 服从联合高斯分布。高斯过程的特征完全由均值函数 $m(x)$ 和协方差函数 $k(x, x')$ 决定,可记为

$$f(x) \sim \text{GP}(m(x), k(x, x')) \quad (1)$$

考虑到存在噪声的环境下,实际输出值 $y$ 等于观测值与噪声之和,即

$$y = f(x) + \varepsilon \quad (2)$$

$\varepsilon$ 为高斯白噪声,分布如下

$$\varepsilon \sim N(0, \sigma_n^2) \quad (3)$$

### 1.2 学习过程

随机选取训练样本的子集 $\bar{D} = \{\bar{x}_j, \bar{y}_j\}_{j=1}^M$ ,并定义子集样本的输入数据集 $\bar{X} = \{\bar{x}_m\}_{m=1}^M$ ,对应的目标值的集合 $\bar{f} = \{\bar{f}_m\}_{m=1}^M$ , $M$ 为子训练样本的大小。为了表达式的简洁,一般设置均值函数为零。

由于实际问题中存在噪声,本文采用的协方差函数的形式可写为

$$K(x_p, x_q) = \sigma_f^2 \exp\left[-\frac{1}{2l^2}(x_p - x_q)^2\right] + \sigma_n^2 \delta_{pq} \quad (4)$$

式中 $l$ 称为关联性测定超参数,衡量样本输入与输出的相关性。由于不同维数样本输入输出的相关性不同, $l$ 值也不同。若样本维数为 $C$ ,则 $l$ 值为 $C$ 种,记作 $l_{1-C}$ 。 $\sigma_f$ 为协方差函数的信号标准差, $\sigma_n$ 为噪声标准差, $\delta_{pq}$ 为Kronecker符号,且当 $p = q$ 时, $\delta_{pq} = 1$ ,当 $p \neq q$ 时, $\delta_{pq} = 0$ 。一般将参数 $(l_{1-C}, \sigma_f, \sigma_n)$ 称为超参数 $\theta$ 。超参数的选择是否适当直接影响高斯过程模型的构建,进而影响模型预测的精度。

对于一个输入点含有噪声的实际观测值的似然函数,假设其服从高斯分布,则其表达式为

$$p(y|x, \bar{X}, \bar{f}) = N(y|k_x^T K_M^{-1} \bar{f}, K_{xx} - k_x^T K_M^{-1} k_x + \sigma^2) \quad (5)$$

式中子样本点间的协方差 $[K_M]_{mm'} = K(\bar{x}_m, \bar{x}_{m'})$ ,原输入 $x$ 与子样本输入 $\bar{x}$ 间的协方差 $[k_x]_m = K(\bar{x}_m, x)$ ( $m = 1, \dots, M$ )。该式可看作为标准回归模型,且含有特定形式参数化的均值函数和依据输入的噪声模型。

根据贝叶斯理论可得到子样本目标值的后验分布为

$$p(\bar{f}|D, \bar{X}) = N(\bar{f}|K_M Q_M^{-1} K_{MN}(\Lambda + \sigma^2 I)^{-1} y, K_M Q_M^{-1} K_M) \quad (6)$$

式中符号 $Q_M = K_M + K_{MN}(\Lambda + \sigma^2 I)^{-1} K_{NM}$ 。

### 1.3 预测过程

给定测试样本点 $(x_*, y_*)$ ,结合单个样本点的似然分布(5)和后验分布(6)可得到测试点的预测分布为

$$p(y_*|x_*, D, \bar{X}) = \int d\bar{f} p(y_*|x_*, \bar{X}, \bar{f}) p(\bar{f}|D, \bar{X}) = N(y_*|\mu_*, \sigma_*^2) \quad (7)$$

式中 $y_*$ 的期望和方差分别为:

$$\mu_* = k_*^T Q_M^{-1} K_{MN}(\Lambda + \sigma^2 I)^{-1} y \quad (8)$$

$$\sigma_*^2 = K_{**} - k_*^T (K_M^{-1} - Q_M^{-1}) k_* + \sigma^2 \quad (9)$$

由于 $\Lambda + \sigma^2 I$ 为对角阵,计算量仅取决于 $Q_M$ 矩阵乘法 $K_{MN}(\Lambda + \sigma^2 I)^{-1} K_{NM}$ ,其时间复杂度为 $O(M^2N)$ 。测试过程中,针对每一个测试点,计算均值函数的复杂度为 $O(M)$ ,方差的复杂度为 $O(M^2)$ 。

## 2 人工蜂群算法

### 2.1 蜂群采蜜行为分析

人工蜂群算法是2005年由Karaboga受到蜜蜂采蜜的行为启发,提出的用于解决函数极值优化问题<sup>[13]</sup>的智能优化算法。人工蜂群的智能模型一般由三个方面组成,分别是蜜源、雇佣蜂、非雇

佣蜂。雇佣蜂搜寻花蜜并以一定的概率在跳舞区域通过跳摇摆舞与观察蜂分享蜜源的信息。观察蜂接收到众多雇佣蜂的蜜源信息,并选择最有收益的蜜源进行开采。观察蜂在到达蜜源后,在蜜源附近进行搜索,若搜索到更好的蜜源就代替原蜜源,否则仍在原蜜源处采蜜。观察蜂变成“雇佣蜂”开采花蜜,并将花蜜放到存储区,此时蜜蜂有三种可能性,成为“侦察蜂”、成为“雇佣蜂”招募蜜蜂采蜜,继续回到原蜜源处采蜜。

## 2.2 人工蜂群算法实现

### 2.2.1 算法实现流程

在人工蜂群算法中,蜜源代表着待优化问题的可行解,蜜源的花蜜量代表着可行解的质量或适应度,雇佣蜂的数量与可行解的个数相同。随机产生初始蜜源的集合  $P = \{x_i\}_{i=1}^{SN}$ , 其中  $x_i$  为蜜源,  $SN$  为雇佣蜂的个数。每一个可行解  $x_i (i = 1, 2, \dots, SN)$  是  $D$  维向量, 其中  $D$  为需优化参数的个数。人工蜂群算法的具体步骤描述如下:

(1) 初始化蜂群的规模大小为  $CS$ , 其中雇佣蜂和观察蜂各占一半, 为  $SN$ 。一个蜜源被采集的最大次数为  $limit$ , 采蜜的最大循环次数为  $MCN$ 。

(2) 雇佣蜂随机搜寻花蜜的位置, 并在舞蹈区与观察蜂分享花蜜信息, 观察蜂依据接收到的众多信息进行筛选, 并在所选的蜜源处进行搜索, 若搜索到更好的蜜源就代替原蜜源, 否则仍保留原蜜源。其中观察蜂选择蜜源概率的计算公式如下:

$$P_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (10)$$

式中  $fitness_i$  为第  $i$  蜜源的质量值,  $SN$  为雇佣蜂的数量。蜜源质量越高被选择的概率越大。

(3) 观察蜂在被选择蜜源附近搜寻到另一新蜜源  $i + 1$ , 并比较新蜜源与原蜜源, 如果新蜜源的质量好于原蜜源, 则开采新蜜源, 否则仍保留原蜜源。一般算法中通过选定特定的参数, 并稍微做些改变以产生新蜜源。产生新蜜源的表达式如下:

$$x_{ij}^{new} = x_{ij}^{old} + \mu(x_{ij}^{old} - x_{kj}) \quad (11)$$

式中  $k \in \{1, 2, \dots, SN\}, k \neq i, j \in \{1, 2, \dots, D\}$  且均为随机值,  $\mu$  为  $[-1, 1]$  内的随机数。 $x_{ij}$  代表着第  $j$  参数为  $x_i$  可行解, 对蜜源  $x_{ij}$  作微小改变可产生新蜜源。

(4) 若蜜源开采的次数达到最大次数  $limit$ , 蜜源的质量变低, 则会放弃该蜜源。此时, 雇佣蜂变成侦察蜂, 侦察蜂在蜜源集合中随机产生新蜜源。若达到设置的循环次数, 蜜源质量仍未提高,

则也放弃该蜜源, 并由侦察蜂随机选取新的蜜源进行开采。假设被放弃的蜜源为  $x_i$ , 侦察蜂搜寻产生新蜜源的表达式如下:

$$x_i^{j(new)} = \min(x_i^j) + \text{rand}[0, 1](\max(x_i^j) - \min(x_i^j)) \quad (12)$$

上式是针对  $j$  参数的取值调整。若未到达设置次数或未满足终止条件, 重复执行以上步骤。

### 2.2.2 适应度函数选取

观察蜂确定某一蜜源后, 再对该蜜源附近的蜜源进行搜索, 以选取最好的蜜源。其中判断蜜源的好坏采用适应度函数计算, 适应度函数设为

$$f_i = \sum_{j=1}^{SN} \|(g_j - t_j)\| \quad (13)$$

式中  $f_i$  为可行解  $i$  的适应度值,  $SN$  为可行解的个数,  $g_j$  为实际输出值,  $t_j$  为第  $j$  个可行解的函数值。

## 3 人工蜂群优化改进高斯过程模型

本文的改进高斯过程选取高斯核函数, 在含有噪声的实际问题中, 其形式如式(4)所示, 式中超参数为  $\theta = (l_{1-c}, \sigma_f, \sigma_n)$ 。

### 3.1 目标函数

改进高斯过程是为了得到与给定训练样本集匹配程度较高的回归模型, 而所得模型优劣则由测试样本集进行检验。本文选取的评估标准为绝对平均误差 (MAPE) 和均方误差 (MSE), 其定义如下:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - y'_i}{y_i} \right| \quad (14)$$

$$MSE = \frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2 \quad (15)$$

式中  $N$  为测试样本的大小,  $y_i$  为实际目标值,  $y'_i$  为预测的目标值。

### 3.2 算法流程

基于人工蜂群算法优化的改进高斯过程模型流程如下:

步骤一: 参数初始化。随机产生蜜源集  $P = \{x_i\}_{i=1}^{SN}$ , 其中  $SN$  为蜜源的个数, 每一个蜜源  $x_i = (l_{1-c}, \sigma_f, \sigma_n)$ 。初始化最大迭代次数  $MCN$ , 并设置初始代数为  $cycle = 1$ 。花蜜开采次数为  $n = 0$ , 蜜源最大开采次数为  $limit$ 。

步骤二: 评估过程。从蜜源集中随机选取一个蜜源  $x_i = (l_{1-c}, \sigma_f, \sigma_n)$ , 用该组参数构造改进高斯过程模型, 并用测试集根据式(13)评估解的质量。

步骤三:雇佣蜂搜寻蜜源。若步骤二不满足需求解,再随机选取一蜜源,雇佣蜂根据式(11)在该蜜源的基础上产生一新蜜源,并由式(13)评估该新蜜源的适应度。

步骤四:雇佣蜂招募观察蜂采蜜。在舞蹈区雇佣蜂通过跳摆尾舞分享蜜源的信息。

步骤五:观察蜂选择蜜源。由于有  $SN/2$  只雇佣蜂与观察蜂分享不同蜜源的信息,观察蜂通过不同蜜源的适应度来选取最大适应度的蜜源。

步骤六:观察蜂产生新蜜源。在选择好蜜源后,观察蜂根据选择后的蜜源,由式(10)产生新蜜源,并与原蜜源的适应度进行比较,选取适应度较大者进行采蜜。每开采一次,开采次数  $n = n + 1$ ,迭代次数  $cycle = cycle + 1$ 。

步骤七:判断终止条件。若蜜源开采次数  $n \leq limit$ ,判断迭代次数:若  $cycle \leq MCN$ ,转到步骤三,若  $cycle > MCN$ ,算法终止,输出最优解。

步骤八:侦查蜂产生新蜜源。若蜜源开采次数达到  $limit$ ,解的质量仍未提高,则由侦查蜂在解空间中根据式(11)随机产生一个新蜜源代替当前蜜源,并设置新蜜源的开采次数  $n = 0$ ,转到步骤二。

步骤九:改进高斯过程模型构建。根据输出的最优超参数确定核函数,并通过训练样本学习改进高斯过程模型。

步骤十:预测过程。将测试样本输入到改进高斯过程模型中,并使输出结果达到预测精度。

大致流程如图 1 所示。

### 4 实验结果及分析

为验证本文提出的 ABC 优化算法改进 GP 回归模型的有效性,以海上远程精确打击(LPSS)体系作战效能评估为例,分别在 Matlab 模拟仿真环境下,对多种常见的优化算法(密母算法(MA)、遗传算法(GA)、粒子群算法(PSO)、差分进化算法(DE)、人工蜂群算法(ABC))优化 GP 的效果进行比较。

#### 4.1 公共参数设置

为了比较不同的优化方法结合改进 GP 回归模型的优化效果,实验中不同方法涉及的公共参数设置相同,仅针对本身的特有参数进行不同的设置。实验中各优化方法的公共参数设置如表 1 所示。

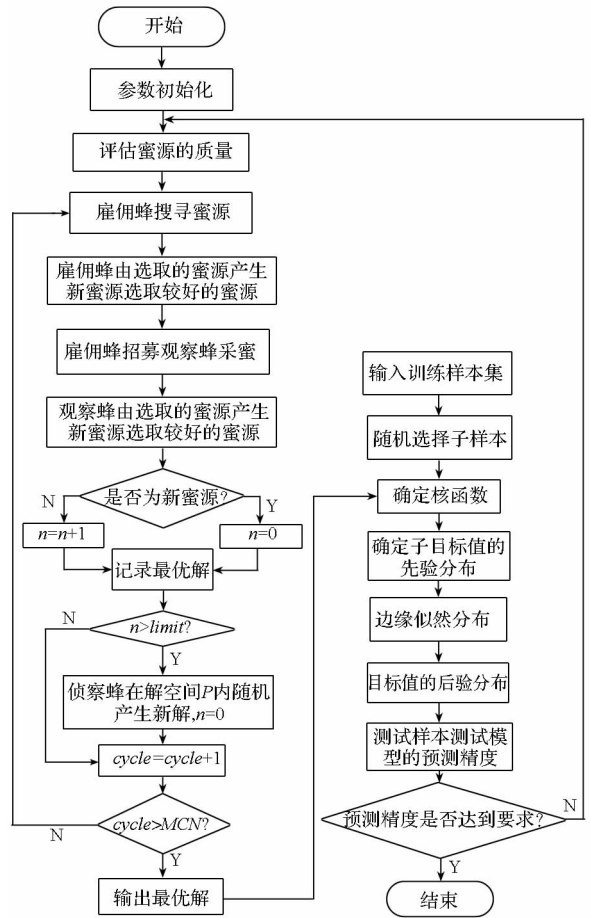


图 1 人工蜂群算法优化改进高斯过程流程图  
Fig. 1 Flowchart of improved GP optimized by ABC

表 1 各种优化算法的公共参数设置

Tab. 1 Public parameters of various optimization algorithms

参数名	参数值	备注说明
SN	50	种群大小
D	53	优化参数个数
MCN	6000	最大目标函数评估次数
runTime	20	重复实验次数
upperBounds	$10_{1-52}$ 和 $1_{53}$	个体取值的上限值
lowerBounds	0.0000001	个体取值的下限值
Objectivefunction	改进高斯函数	优化算法的目标函数

#### 4.2 不同优化算法参数设置

由于优化算法间存在的差异性,不同的优化算法除了公共参数外,各有本身特定的控制参数,且参数名、参数个数均不相同。在 Matlab 实验程序实现中,不同优化算法的控制参数设置如下所示。

##### (1) MA、GA 算法

由于 MA 是在 GA 的基础上发展来的,MA 的参数几乎与 GA 相同。不同的是 MA 在 GA 的基础上

增加了局部搜索策略。MA 的控制参数为 6 个,而 GA 的控制参数为 5 个。其参数设置如表 2 所示。

表 2 MA 与 GA 的参数设置  
Tab.2 Parameters of MA and GA

参数名	MA	GA
选择策略	轮盘赌	轮盘赌
交叉策略	单点交叉	单点交叉
交叉概率	0.8	0.8
变异策略	随机变异	随机变异
变异概率	0.01	0.01
局部搜索次数	50	-

(2) PSO 算法

粒子群优化算法的控制参数为 4 个,实验程序实现中的参数设置如表 3 所示。

表 3 PSO 的参数设置  
Tab.3 Parameters of PSO

参数名	数值	备注说明
ac	2.1	到达最优个体之间速度限制常数
Iwt	0.9 <sub>1</sub> , 0.6 <sub>2</sub>	个体速度的 2 个惯性因子
wt_end	1500	当评估次数超过此值时,使用第 2 个惯性因子
mvden	2	个体的最大速度,取值为最大上下限区间的 1/2

(3) DE 算法

差分进化算法的控制参数仅为 2 个,分别为交叉常数因子和查分变异权重,实验中的具体取值分别为 0.85、0.85。

(4) ABC 算法

人工蜂群算法的控制参数仅为 1 个,最大不更新次数为 limit,即经过 limit 次开采次数后,蜜源或解的质量仍未改善,则放弃该蜜源并产生新蜜源。在定义 limit 值时,limit = SN × D 可作为参考,其中 SN 为种群大小,D 为优化参数个数。本实验程序实现中,取 40 代则更新 2000 次,即 limit = 2000。ABC 算法的控制参数仅为一个,体现出其容易实现的优点。

4.3 ABC 算法与其他优化算法实验比较

为了评估 ABC 优化算法的性能,实验将 ABC 与其他优化算法 MA、GA、PSO、DE 分别对改进 GP 的超参数寻优效果进行比较,并用不同算法优化后的模型进行预测,得出反映预测效果的预测误差 MAPE、MSE 指标。每一次实验,优化算法评估次数均为 6000 次,重复 20 次实验,得到不同算法优化改进 GP 的预测结果。




图 2 不同优化算法的预测结果 MAPE 曲线比较图  
Fig.2 MAPE curve comparison chart of predictions of different optimization algorithms




图 3 不同优化算法的预测结果 MSE 曲线比较图  
Fig.3 MSE curve comparison chart of predictions of different optimization algorithms

图 2、图 3 分别为不同优化算法在 6000 次评估次数过程中,通过搜寻改进 GP 的最优超参数,最终得到的预测精度 MAPE、MSE 曲线图。可以看出,针对 LPSS 体系作战效能评估问题,MA - 改进 GP 的预测效果最差,ABC - 改进 GP 的预测效果最好。预测效果从好到差的优化模型依次为 ABC - 改进 GP、DE-改进 GP、PSO - 改进 GP、GA - 改进 GP、MA - 改进 GP。由于不同的优化算法都是搜索改进 GP 的最优超参数,所以从优化模型的预测精度上,也反映了优化算法的优缺点。MA 算法是一种全局和局部搜索策略结合的优化方法,实验中评估次数为 6000 次,而 MA 算法的局部搜索次数占据了实验中的部分评估次数,评估次数相对于 MA 算法较少,导致 MA 算法在 6000 次评估后,搜索改进 GP 超参数的能力没能完全表现,相对最弱。针对本文应用的问题,ABC 的搜索能力较强,蜂群搜索蜜源再对每个蜜源作出临域搜索,其中搜索强度由贪婪选择策略控制,搜索的多样化由随机选择控制,尤其蜂群间同时存在着动态分配,使得 ABC 算法具有较强的全局搜索能力。

为了更充分体现 ABC - 改进 GP 预测效果,实验针对不同优化算法 MAPE 的最大值、最小值、平均值和方差进行比较,实验结果如表 4 所示。更直观的比较结果如图 4 所示。

表 4 不同优化方法 MAPE 最大值、最小值和均值取值表

Tab.4 MAX, MIN, average values of MAPE of different optimization methods

	最小值	最大值	平均值	方差
ABC - 改进 GP	0.038154	0.046804	0.043148	4.73797E-06
DE - 改进 GP	0.038813	0.044036	0.041744	1.56564E-06
PSO - 改进 GP	0.0451	0.048274	0.047462	6.72776E-07
MA - 改进 GP	0.049457	0.049593	0.049550	1.25957E-09
GA - 改进 GP	0.049372	0.049593	0.049543	2.59496E-09




图 4 不同优化方法 MAPE 最大值、最小值和平均值比较图  
Fig.4 MAX, MIN, average comparison chart of MAPE of different optimization methods

表 4 给出了不同优化模型预测精度 MAPE 的最大值、最小值、平均值、方差的比较结果。MAPE 越小说明预测结果越好,越接近真实值。最小值表明 6000 次评估次数中,预测值为最优值。从表 4 和图 4 中可以看出,ABC - 改进 GP 预测结果最好的一次好于其他优化模型。最大值表明 6000 次评估次数中预测结果最差的一次。DE - 改进 GP 的预测结果中最差的一次,预测精度最好。ABC - 改进 GP 仅次于 DE - 改进 GP。平均值说明 6000 次评估次数中平均的预测水平。从平均值的角度看,ABC - 改进 GP 仅次于 DE-改进 GP。方差反映了 6000 次评估次数中预测结果的离散程度,说明了不同优化算法寻优超参数的遍历范围。从方差的角度看,ABC - 改进 GP 的预测结果离散程度最大,体现了 ABC 较强的全局搜索能力,且在搜索空间中不易陷入局部极小。从以上不同的角度可以看出,ABC - 改进 GP 与 DE - 改进 GP 预测效果几乎相当,但 ABC 的全局搜索能力更强。经过 6000 次评估后,ABC 搜索到改进 GP 的最优超参数。

在不同优化算法搜寻改进 GP 的最优超参数的 6000 次评估次数中,选取一次实验对不同优化模型的时间复杂度作出比较,反映出不同优化模型的预测效率,如图 5 所示。

从图 5 中可以看出,ABC - 改进 GP 所用的时




图 5 不同优化模型时间复杂度的比较图

Fig.5 Comparison chart of time complexity of different optimization model

间少于 DE - 改进 GP、GA - 改进 GP、MA - 改进 GP,且后面三种模型所用的时间几乎相等。PSO - 改进 GP 所用的时间最少,但预测精度不是很好。从预测精度和效率方面综合考虑,ABC - 改进 GP 相对较好。

#### 4.4 无资源限制的 ABC - 改进 GP 预测结果

为了验证 ABC 优化改进 GP 的预测效果,该实验针对 ABC 改进高斯过程的 53 个超参数评估 50000 次,根据不同评估次数下得到的超参数,构建改进 GPR 模型,并输入相同的测试样本得到不同评估次数下的预测效果。在计算资源完全充分的条件下,得到反映预测精度的曲线 MAPE 与 MSE。




图 6 ABC 优化改进 GP 预测精度 MAPE 曲线图

Fig.6 MAPE curve chart of improved GP optimized by ABC




图 7 ABC 优化改进 GP 预测精度 MSE 曲线图

Fig.7 MSE curve chart of improved GP optimized by ABC

图 6、图 7 分别是 ABC 在 50000 次评估过程中,根据不同的评估次数下搜寻改进高斯过程的超参数,得到的预测精度 MAPE、MSE 曲线图。MAPE 与 MSE 均反映了预测的效果,其值越小,

测试样本与构建的回归曲线越匹配,拟合程度越高。图 6 与图 7 几乎反映了相同的 ABC 优化效果的趋势,MAPE、MSE 与评估次数成反比关系。然而,当评估次数到达一定的值后,预测精度没有得到太大的改善,对于 LPSS 体系作战效能评估问题,可取 35000 次或大于 35000 次评估次数寻优超参数。而 MAPE 与 MSE 曲线图中,在达到 50000 次后,并没有趋于恒定值,精度仍有较小的改善,体现了 ABC 较强的全局搜索能力。ABC 评估 50000 次改进 GP 后,得到 53 个参数即最优超参数。

实验中,选取 87 次打击仿真实验结果作为样本数据,其中随机选取 67 次仿真结果作为训练数据,余下的 20 次作为测试数据。针对 ABC 评估 50000 次后得到的最优超参数,输入训练数据学习改进 GP,构建改进 GP 回归模型。输入 20 个测试样本点,得到预测的效能值,并将输出预测的效能值和真实的效能值的差异用 MAPE、MSE 表示,即预测的精度,如表 5 所示。

表 5 ABC - 改进 GP 的预测结果

Tab. 5 Prediction results of ABC-improved GP

样本点	真实值	预测值	样本点	真实值	预测值
1	0.662755	0.6652	11	0.643064	0.6433
2	0.63957	0.6549	12	0.647269	0.6469
3	0.757609	0.7155	13	0.648552	0.6575
4	0.782346	0.7454	14	0.655652	0.6556
5	0.727537	0.7149	15	0.651232	0.6628
6	0.678983	0.6782	16	0.684925	0.6851
7	0.659776	0.6509	17	0.700233	0.7106
8	0.707675	0.7074	18	0.675069	0.6742
9	0.64999	0.6417	19	0.670899	0.6718
10	0.649273	0.6548	20	0.632169	0.6663
MAPE	0.014414		MSE	0.00026	

## 5 结论

本文采用人工蜂群算法搜寻改进高斯过程的超参数,提出 ABC - 改进 GP 方法。通过训练样本学习构建回归模型,解决 LPSS 体系作战效能评估问题。本文将基于机器学习的智能评估方法引入到作战效能评估中,与常用的矩阵计算方法相比,降低了权重赋值的主观性,并能通过自适应学习自动获得权值,为效能评估问题提供了新思路。

该方法在降低高斯过程训练时间复杂度的基

础上,对超参数进行优化,构建更优的回归模型。改进高斯过程,解决了原高斯过程对于大样本数据评估效率较低的问题。人工蜂群算法优化改进了高斯过程的超参数,建立的回归模型提高了预测的精度。实验中,ABC 算法与其他优化算法 MA、GA、PSO、DE 搜寻改进 GP 的方法进行比较,仿真实验结果表明了本文所提方法的有效性,且适用于 LPSS 体系作战效能评估问题。

## 参考文献 (References)

- [1] Seeger M. Gaussian processes for machine learning [J]. International Journal of Neural Systems, 2004, 14 (2): 69 - 106.
- [2] Chen K M, Zhou Z X, Huo C L, et al. A semisupervised context-sensitive change detection technique via gaussian process[J]. Geoscience and Remote Sensing Letters, IEEE, 2013, 10(2): 1 - 5.
- [3] Gu D B, Hu H S. Spatial gaussian process regression with mobile sensor networks [J]. Neural Networks and Learning Systems, IEEE Transactions on, 2012, 23(8): 1279 - 1290.
- [4] Wang S W, Gu H L. Multiuser detection with sparse spectrum gaussian process regression [J]. Communications Letters, IEEE, 2012, 16(2): 164 - 167.
- [5] Snelson E, Ghahramani Z B. Sparse gaussian processes using pseudo-inputs [C]//Proceedings of NIPS, 2006: 1257 - 1264.
- [6] Rasmussen C E, Christopher K I W. Gaussian processes for machine learning [M]. MA: MIT Press, 2006: 19 - 56.
- [7] 刘开云,方昱,刘报国,等. 隧道围岩变形预测的进化高斯过程回归模型[J]. 铁道学报, 2011, 33 (12): 101 - 106. LIU Kaiyun, FANG Yu, LIU Baoguo, et al. Genetic gaussian process regression model for prediction of tunnel surrounding rock deformation [J]. Journal of the China Railway Society, 2011, 33 (12): 101 - 106. (in Chinese)
- [8] 徐冲,刘保国,刘开云,等. 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[J]. 岩土力学, 2011, 32(6): 1669 - 1675. XU Chong, LIU Baoguo, LIU Kaiyun, et al. Intelligent model for analysis & prediction of landslide displacement time series based on particle swarm-gaussian process regression coupling algorithm [J]. Rock & Soil Mechanics, 2011, 32(6): 1669 - 1675. (in Chinese)
- [9] 徐冲,刘保国,刘开云,等. 基于组合核函数的高斯过程边坡角智能设计[J]. 岩土力学, 2010, 31 (3): 821 - 826. XU Chong, LIU Baoguo, LIU Kaiyun, et al. Intelligent design of gaussian process slope angle based on compound kernel function [J]. Rock & Soil Mechanics, 2010, 31 (3): 821 - 826. (in Chinese)
- [10] Karaboga D. Artificial bee colony algorithm [J]. scholarpedia, 2010, 5(3): 6915.
- [11] Kennedy J, Russell E. Particle swarm optimization [C]// Proceedings of IEEE International Conference on Neural Networks, 1995: 1942 - 1948.
- [12] Qin A K, Huang V L, Suganthan P N. Differential evolution algorithm with strategy adaptation for global numerical optimization [J]. Evolutionary Computation, IEEE Transactions on, 2009, 13(2): 398 - 417.
- [13] Karaboga D. An idea based on honey bee swarm for numerical optimization [R]. Techn. Rep. TR06, Erciyes Univ. Press, Erciyes, 2005.