

引用格式:朱富占,邹海,张馨. 改进果蝇算法优化 GRNN 在弹痕深度预测中的应用 [J]. 微电子学与计算机,2019,36(2):41-45. [ZHU F Z, ZOU H, ZHANG X. Application of improved fruit fly algorithm optimization GRNN in bullet depth prediction [J]. Microeletronics & Computer,2019,36(2): 41-45.]

改进果蝇算法优化 GRNN 在弹痕深度预测中的应用

朱富占,邹海,张馨

(安徽大学 计算机科学与技术学院,安徽 合肥 230601)

摘 要: 本文采用果蝇优化算法来优化广义回归神经网络的平滑因子,提出了基于改进果蝇算法优化广义回归神经网络的弹痕深度建模方法,将该方法与未经优化的广义回归神经网络测试函数逼近误差,结果明显优于未经优化的广义回归神经网络.最后,通过与未经优化的广义回归神经网络、原始果蝇优化算法优化的广义回归神经网络以及 BP 神经网络进行比较,其性能明显优于另外三种方法,验证了该方法在弹痕深度预测中的有效性.

关键词: 非线性问题;广义回归神经网络;果蝇优化算法;函数逼近;弹痕深度

中图分类号: TP301.6

文献标识码: A

文章编号: 1000-7180(2019)02-0041-05

Application of Improved Fruit Fly Algorithm Optimization GRNN in Bullet Depth Prediction

ZHU Fu-zhan, Zou Hai, Zhang Xin

(School of Computer Science and Technology, Anhui University, Hefei 230601, China)

Abstract: We use the fruit flies optimization algorithm to optimize smoothing factor of generalized regression neural network, and thus proposed the bullet scratch depth modeling method based on the optimization of the generalized regression neural network with improved fruit flies optimization algorithm, and the method is much better than the unoptimized generalized regression neural for function approximation. In the end, take the generalized regression neural network without optimization method, the unoptimized generalized regression neural network with original fruit flies optimization algorithm and the BP neural network into comparison, the performance of this method is superior to the other three methods, it verified the effectiveness of this method in the bullet scratch depth prediction.

Key words: nonlinear problem; GRNN; fruit fly algorithm; function approximation; bullet depth

1 引言

在涉枪的案件中,如何以快速高效的方法找到所使用的枪支是侦破刑事案件的重点突破口.由于制造、加工、保管等方面的不同,使得每支枪管的膛线也各有不同,因此弹头上的擦痕也各不相同^[1-2].其中弹头表面的擦痕深度具有不确定性,是复杂的非线性问题.群智能优化算法^[3-4]以其算法简单、容易实现、约束少、适应性强以及应用领域广等

优点被广泛应用于各个领域,也产生了许多改进的算法.文献[5]在原始粒子群优化算法的基础上构造出自适应的惯性权重,引入了“优胜劣汰”机制,即平衡了算法的全局和局部搜索能力又避免算法出现早熟收敛现象;文献[6]将直觉模糊化应用于非线性问题,根据种群个体的进化迭代的适应度大小动态自适应调整 GA 的交叉率和变异率,增强了算法的全局寻优能力和局部寻优能力;文献[7]提出一种改进的果蝇算法,对不同的变量更新采用不同的策略,并

周期性的改变移动步长指导果蝇的寻优,使其避免陷入局部最优.此类算法的缺点也不容忽视,例如:粒子群算法易发散且收敛精度低;遗传算法的编程实现较为复杂,影响参数较多且易早熟;果蝇优化算法的稳定性不高,易于陷入局部最优.

本文采用改进果蝇算法对 GRNN 的参数进行优化选取^[8],再将优化后的平滑因子代入神经网络模型对弹痕深度进行预测.

2 广义回归神经网络

广义回归神经网络(GRNN)是由 Specht 等^[9]在 1991 年提出的一种使用径向基函数作为激活函数的人工神经网络,其网络结构相对简单,计算时间短,学习速率快,同时具有很强的非线性映射能力. GRNN 是径向基网络(RBF)的一种变形形式,建立在非参数回归的基础上,以样本数据为后验条件,执行 Parzen 非参数估计,网络计算结果具有全局收敛性. GRNN 以 RBF 为基础,因此具有良好的非线性逼近性能,与 RBF 相比,其训练更为方便,学习速率更快.一旦训练样本确定,GRNN 的网络结构和神经元之间的连接权值也变为已知,训练的目的便是为了确定其平滑因子.

GRNN 的网络结构相对简单,由四 4 层构成,分别为输入层、模式层、求和层和输出层,如图 1 所示.




图 1 广义回归神经网络结构

(1) 输入层 输入层为向量,该层神经元数目等于学习样本中输入向量维数,每个神经元对应不同的样本,输入层将神经元接收的变量直接传递给模式层.

(2) 模式层 模式层神经元数目等于样本数量 n ,设输入向量 X 为 r 维, $X = [x_1, x_2, \dots, x_r]^T$,输出变量 Y 为 k 维, $Y = [Y_1, Y_2, \dots, Y_k]^T$,则各个神经元的传递函数为

$$P_i = \exp\left[-\frac{(X - X_i)^T(X - X_i)}{2\sigma^2}\right] \quad (1)$$

$i = 1, 2, \dots, n$

式中, X_i 代表第 i 个神经元所对应的学习样本, σ 代表平滑因子.

(3) 求和层 求和层中使用两种类型的神经元求和,其中一类为每个模式层节点的输出和,求和方式

$$S_i = \sum_{i=1}^n P_i \quad (2)$$

另一类神经元为预期的结果与每个模式层节点的加权求和,其求和方式为

$$S_{wj} = \sum_{i=1}^n y_{ij} P_i \quad j = 1, 2, \dots, k \quad (3)$$

(4) 输出层 输出层的神经元个数等于学习样本中输出向量的维数 k ,输出结果为求和层中两类求和方式所得的结果相除,即:

$$y_j = \frac{S_{wj}}{S_i} \quad j = 1, 2, \dots, k \quad (4)$$

3 改进的果蝇算法优化广义回归神经网络

果蝇优化算法(Fruit Fly Optimization Algorithm, FOA)采用固定的步长值,影响了算法后期的局部搜索能力,导致算法容易陷入局部最优,因此提出改进的变步长果蝇算法(CSFOA).由于 GRNN 的性能受到平滑因子的影响,现采用改进的果蝇优化算法优化广义回归神经网络,以提高网络的预测精度.

具体步骤如下:

(1) 设定果蝇群体规模和最大迭代次数分别为 Sizepop, Maxgen, 初始化果蝇群体位置为 X_0, Y_0 .

(2) 修改果蝇飞行的随机方向和距离,变固定步长为动态递减步长的策略,并引入随机机制避免算法陷入局部最优.

$$\begin{cases} X_i = X_0 + L * randValue \\ Y_i = Y_0 + L * randValue \end{cases} \quad (5)$$

$$L = L_0 * (p)^c * w \quad (6)$$

$$w = 1 - e^{-\gamma} \quad (7)$$

$$c = \frac{t}{t_{\max}} - \cos\left(\frac{t}{t_{\max}}\right) + 1 \quad (8)$$

式中, L_0 为初始步长; p 为指数因子,本文取 0.8;过度参数 c 随着迭代次数的增加而增加,步长值则会逐渐减小,增强了算法在后期的局部搜索能力; w 为权重因子,服从指数分布,使算法能够以更大的几率

跳出局部最优; γ 为常量,本文取值为 0.5.

(3) 计算果蝇个体位置与原点的距离(D_i)和味道浓度判定值(S_i),并将(S_i)作为 GRNN 中的平滑因子 σ .

$$D_i = \sqrt{X_i^2 + Y_i^2}$$

(9)

$$S_i = \frac{1}{D_i}$$

(10)

(4) 将平滑因子 σ 代入 GRNN 模型中,载入数据并将数据分为训练和预测两类进行交叉训练,求出两者的均方根误差($RMSE_i$) 作为味道浓度判定值($Smell_i$).

(5) 找出果蝇群体中的最优个体($RMSE_i$ 最小值) 及其位置并保留坐标位置:

$$[bestSmellbestindex] = \min(RMSE_i),$$

$$Smellbest = bestSmell,$$

$$X_0 = X(bestindex),$$

$$Y_0 = Y(bestindex).$$

(6) 判断是否达到最大迭代次数,若是则执行步骤 7,否则进行迭代寻优,并判断当前味道浓度值是否优于前一代,若是则执行步骤 5.

(7) 将最优味道浓度值即平滑参数 σ 代入 GRNN 模型进行预测.

4 仿真实验及结果分析

本文的实验平台是 Matlab R2014a,在内存为 4GB,CPU 速度为 3.20GHz 的 PC 机上运行.首先,选取 6 个基准测试函数验证 CSFOA 的寻优性能,并与基本 FOA 进行对比;其次,采用 Matlab 工具箱中的函数 newgrnn()对广义回归神经网络进行训练,提出了 CSFOA-GRNN 的建模方法,将 CSFOA-GRNN 用于对非线性函数的逼近,并与 GRNN、FOA-GRNN 进行对比,验证该方法的有效性;最后用 CSFOA-GRNN 的建模方法对弹痕深度进行预测.

4.1 FOA 与 COFOA 实验对比

为验证 CSFOA 算法的性能,本文选取 6 个基准函数进行仿真实验,如表 1 所示,FOA 与 CSFOA 分别对每个基准函数独立运行 20 次,并统计其最小值、最大值、平均值以及方差,测试结果如表 2 所示.

从表 2 中可以看出,对于函数 F1,CSFOA 的寻优性能较 FOA 没有那么明显;对于函数 F3,两种算法的寻优精度相当,但是 CSFOA 表现的更加稳定;除了函数 F3,对其他函数的寻优 CSFOA 算法均比 FOA 算法至少提高一个精度,且更加稳定,证明了

CSFOA 算法的有效性.

表 1 测试函数

函数	范围	最优值	维度	峰值
F1 Sphere	$[-100,100]$	0	2	unimodal
F2 Ackley	$[-32,32]$	0	2	multimodal
F3 Exponential	$[-1,1]$	-1	30	unimodal
F4 Quartic	$[-1,28,1,28]$	0	30	unimodal
F5 Schwefel	$[-10,10]$	0	30	unimodal
F6 Alpine	$[-10,10]$	0	30	multimodal

表 2 测试结果

函数	算法	最小值	最大值	平均值	方差
F1	FOA	5.06E-05	2.21E-04	1.10E-04	2.46E-09
	CSFOA	1.66E-06	1.02E-05	2.81E-06	4.46E-12
F2	FOA	1.66	1.86	1.66	6.37E-07
	CSFOA	1.65	1.65	1.65	1.73E-08
F3	FOA	-0.99	-2.36E-06	-0.48	0.18
	CSFOA	-0.99	-0.99	-0.99	0
F4	FOA	1.25	9.07E+02	1.88E+02	5.66E+04
	CSFOA	0.01	0.04	0.02	3.22E-05
F5	FOA	2.25	12.01	4.07	6.30
	CSFOA	0.24	2.37	1.05	0.46
F6	FOA	0.23	12.42	1.45	6.85
	CSFOA	0.03	0.42	0.15	1.39E-02

4.2 函数误差分析

本文尝试将改进的果蝇算法优化广义回归神经网络用以测试非线性函数的逼近误差,并与未经优化的广义回归神经网络以及原始果蝇算法优化的广义回归神经网络进行对比,以此来验证该模型的可行性.其中本文选取的非线性函数为 $y=2x^6+3x^5-3x^3+x^2+1$,果蝇的种群规模为 20,迭代次数为 30,果蝇群体位置区间为 $[0,10]$.网络训练的实验结果和误差曲线分别如表 3、图 2 所示,表 3 中数据为在选取不同平滑因子的情况下独立运行 20 次所得的实验结果,为了更加清楚的区分算法优劣,表 3 中数据均为取得绝对值后的数据.

由表 3 可知,当平滑因子取 0.6 时,训练误差最大,函数逼近能力最弱;由 FOA-GRNN 训练结果和当平滑因子为 0.09 时的误差结果相当,但是 FOA-GRNN 稳定性能较差;CSFOA-GRNN 的函数逼近能力明显优于 GRNN 和 FOA-GRNN,且更加稳定.从图 2 可以更加清晰的看

出由 CSFOA-GRNN 训练得出的平滑因子在处理函数逼近问题时提高了函数精度,减小了函数误差,证明了改进的果蝇算法优化广义回归神经网络的有效性.

表 3 函数逼近误差

平滑因子	最小值	最大值	平均值	方差
0.6	5.373	5.373	5.373	0
0.09	1.585	1.585	1.585	0
FOA-GRNN	1.167	5.384	2.714	1.867
CSFOA-GRNN	1.509E-05	0.669	0.191	4.186E-02




图 2 误差曲线

4.3 CSFOA-GRNN 预测弹痕深度

4.3.1 数据采集与预处理

枪弹痕迹鉴定的基础是采集到弹头、弹壳的完整信息,本文采用基于结构光及多步相移解析获取弹痕纹理图与对应的深度数据.

4.3.2 弹痕深度预测结果分析

采用改进的果蝇算法优化的广义回归神经网络对采集和预处理后的 10 组数据进行交叉训练,并与 BPNN、未经优化的 GRNN 以及原始果蝇算法优化的 GRNN 进行对比,其中果蝇的种群规模为 20,迭代次数为 50;BPNN 的学习速率和动量因子分别为 0.05、0.8;未经优化的 GRNN 的平滑因子 σ 的取值范围为 $[0.001,1]$,每次训练平滑因子 σ 增加 0.01. 实验结果如表 4 所示.

通过分析表 4 可知,四中预测模型对弹痕深度的预测值的平均误差分别为 $8.2551\text{E-}04$ 、 $6.1168\text{E-}04$ 、 $6.1157\text{E-}04$ 、 $5.4566\text{E-}04$,其中 BPNN 较其他三种模型预测能力较弱,但是 BPNN 对第一组数据的预测精度却高于其他三种模型,主要是因为裁剪后的数据中仍存在异常点,影响了训练的结果;GRNN 和 FOA-GRNN 有着类似的预测能力,原因在于 GRNN 所选取的平滑因子较小,使得训练结果较为理想,而 FOA-GRNN 在迭代搜索平滑因子时容易

陷入局部最优,影响了算法的搜索精度,且 GRNN 和 FOA-GRNN 的稳定性较差;CSFOA-GRNN 模型对弹痕深度的预测的精度更高,且具有较强的稳定性,与其他三种预测模型相比具有明显的优势,证明了 CSFOA-GRNN 的有效性.

表 4 四种模型对训练样本的预测误差(10^{-4})

数据		BPNN	GRNN	FOA-GRNN	CSFOA-GRNN
1	Min	9.084 5	12	13	12
	Max	16	23	23	16
2	Min	9.926 2	2.200 3	2.077 3	2.049 8
	Max	9.998 4	5.380 1	5.362 4	4.228 3
3	Min	5.607 8	4.620 3	4.776 5	4.561 4
	Max	9.9971	14	14	14
4	Min	9.386 1	8.858 2	9.088 7	8.845 8
	Max	18	20	19	11
5	Min	7.412 8	7.056 6	7.062 3	7.054 0
	Max	13	16	15	7.520 8
6	Min	8.164 0	5.850 7	5.964 7	5.848 4
	Max	16	21	19	6.604 4
7	Max	8.307 5	7.947 1	8.836 1	7.893 8
	Max	15	14	14	11
8	Min	9.851 7	3.693 4	4.122 1	3.693 4
	Max	15	13	12	7.494 0
9	Min	8.023 6	1.586 7	1.883 4	1.273 2
	Max	9.998 5	5.192 1	5.149 9	2.452 7
10	Min	6.031 0	7.360 5	4.345 9	4.345 9
	Max	9.998 3	15	14	7.680 9

5 结束语

本文采用改进的果蝇算法优化广义回归神经网络对弹痕深度进行预测,改变果蝇算法中的定步长为递减步长,使得算法随着迭代的进行搜索步长逐渐减小,提高了算法后期的搜索精度;同时,在随机机制的协同下,增加了解得多样性,避免算法陷入局部最优. 由于广义回归神经网络的函数逼近能力和网络预测能力受到平滑参数的影响,因此本文将改进的果蝇算法用于优化广义回归神经网络,提高其映射能力和预测性能. 实验结果表明,本文方法在非线性函数逼近方面与 GRNN 和 FOA-GRNN 相比具有更好的逼近能力,且在与 BPNN、GRNN 以及 FOA-GRNN 对弹痕深度进行预测时表现出了更好的预测能力和稳定性. 接下来的重点研究工作是将本文算法应用于其他研究领域,解决生活中存在的实际问题.

参考文献:

[1]

高野. 对射击弹壳上几种痕迹特征变化的分析[J]. 辽宁警专学报,2003,22(6):36-38.

[2]

韩毅,张双喜,谢昊原. 一种枪弹痕迹自动对比算法[J]. 计算机仿真,2013,30(3):30-33.

[3]

Gupta Y, Gupta M, Kumar A, et al. A genetic algorithm-based approach to cell composition and layout design problems [J]. Transportation Research, 1996, 34(2):447-482.

[4]

Yun X F,Dai X S,Zhao J Y,et al. On a novel multi-swarm fruit fly optimization algorithm and its application[J]. Applied Mathematics and Computation,2014, 233:260-271.

[5]

赵佳鑫,高岳林,陈群林. 一种求解非线性规划问题的粒子群算法[J]. 宁夏大学学报(自然科学版),2017, 38(2):15-22.

[6]

梅海涛,华继学,王毅. 求解非线性规划问题的改进直觉模糊遗传算法[J]. 计算机科学,2016,43(9): 250-254.

[7]

朱志同,赵阳,李炜,等. 基于改进果蝇算法求解混合整数非线性规划问题[J]. 计算机应用与软件,2017, 34(6):262-308.

[8]

曹岩枫,徐诚. 基于果蝇算法优化广义回归神经网络的机枪枪管初速衰减建模与预测[J]. 兵工学报, 2017,38(1):1-8.

[9]

Specht D F. A general regression neural network [J]. IEEE Transactions on Neural Networks,1991,2(6): 568-576.

作者简介:

朱富占 男,(1992-),硕士研究生. 研究方向为智能计算. E-mail:2860603443@qq.com.

邹海 男,(1969-),博士,副教授. 研究方向为智能计算和数据挖掘.

张馨 女,(1994-),硕士研究生. 研究方向为智能计算与计算机视觉.

(上接第 40 页)

[9]

李建坡,董子奇. 基于能量迭代的无线传感器网络非均匀分簇路由算法[J]. 计算机应用研究,2017,34(3):824-827.

[10]

徐晶晶,张欣慧,许必宵,等. 无线传感器网络分簇算法综述[J]. 计算机科学,2017,44(2):31-37.

作者简介:

刘小涛 男,(1989-),硕士研究生. 研究方向为无线传感器网络路由协议. E-mail:1044951087@qq.com.

陈珍萍 女,(1981-),博士,副教授,研究生导师. 研究方向为物联网技术和时间同步.

黄友锐 男,(1971-),博士,教授,博士生导师. 研究方向为智能控制、矿山物联网、复杂网络、无线传感器网络等.