

# 基于改进灰狼算法的 RBF 神经网络研究

郭振洲, 刘 然, 拱长青, 赵 亮

(沈阳航空航天大学 计算机学院, 辽宁 沈阳 110136)

**摘 要:** 对于 RBF 神经网络权值参数优化问题, 提出一种基于改进灰狼优化算法的 RBF 神经网络的方法. 针对灰狼算法的收敛精度低的缺点提出一种非线性收敛的灰狼算法, 将隐层到输出层的权值矩阵映射成灰狼算法里的人工狼, 利用灰狼优化算法收敛速度快, 全局搜索能力强的特点对 RBF 网络的隐层到输出层的权值进行优化. 本文采用 KDD CUP99 数据集进行实验, 实验结果表明: 本文所提出的算法具有更好的分类检测效果具有更好的检测分类效果, 并在一定程度上增强了 RBF 神经网络对非线性问题的处理能力.

**关键词:** 灰狼优化算法; 非线性; RBF 神经网络; 权值; 分类

**中图分类号:** TP399

**文献标识码:** A

**文章编号:** 1000-7180(2017)07-0007-04

## Study on RBF Neural Network Based on Gray Wolf Optimization Algorithm

GUO Zhen-zhou, LIU Ran, GONG Chang-qing, ZHAO Liang

(School of Computer, Shenyang Aerospace University, Shenyang 110136, China)

**Abstract:** For the problem of RBF parameter optimization neural network weights, and presents a method of RBF neural network optimization algorithm based on the improvement gray wolf. A nonlinear algorithm for convergence of the proposed algorithm convergence precision of gray wolf low. The hidden layer to the output layer weights matrix mapping algorithm in artificial to wolf, wolf using optimization algorithm has fast convergence speed and global search ability of the hidden layer of RBF network to the output layer weights are optimized to improve the RBF neural network. This paper uses the KDD CUP 99 data set for experiment, the experimental results show that the effect of classification results the proposed algorithm has better better detection and classification, and enhance the processing ability of the RBF neural network for nonlinear problems in a certain extent.

**Key words:** gray wolf optimization; nonlinear; radial basis function neural network; weights; classification

## 1 引言

随着人工智能的迅速发展, 我们在各个领域也能常常见到神经网络的应用. 由于 RBF(Radial Basis Function)神经网络具有自学习、自组织和自适应的特点, 并且其对非线性连续函数具有一致逼近性和较强的分类和学习能力的特性, 因此 RBF 神经网络适用于大范围的数据的融合分类<sup>[1]</sup>.

在传统的 RBF 神经网络算法中, 隐层和输出层之间的权值问题一直是研究的热点. 为了解决隐层和输出层之间权值优化问题, 文献[2]提出动态构造

PSO 优化 RBF 神经网络结构, 针对不同的动态构造方法进行分类, 文献[3]为了改进 RBF 神经网络模型结构和参数的设置方法, 通过动态调整粒子群算法中的惯性权重因子, 用改进的粒子群算法训练 RBF 神经网络, 文献[4]提出一种基于改进的 k-means 算法优化 RBF 的参数, 文献[5]将具有遗传算法中的选择、交叉、变异操作的遗传-粒子群算法(GA-PSO), 用于 RBF 神经网络的参数优化, 文献[6]为了提高 RBF 神经网络的预测精度, 使用混合递阶遗传算法(HHGA)对 RBF 神经网络进行训练, 获得了神经网络结构参数. 本文首次提出用改进

灰狼优化算法训练 RBF 的参数,然后用来训练后的 RBF 神经网络对 KDD CUP99 网络入侵数据进行分类.

## 2 相关工作

### 2.1 RBF 神经网络

RBF 神经网络一般由三层神经元构成:输入层,隐层和输出层. RBF 神经网络结构<sup>[7]</sup>如图 1 所示.




图 1 RBF 神经网络

如图 1 所示的结构,假设输入层有  $n$  个节点,隐层有  $m$  个节点,输出层有  $t$  个节点. 如果输入矩阵为  $[x_1, x_2, \dots, x_n]^T \in R^n$ , 输出矩阵为  $y = [y_1, y_2, \dots, y_t]^T \in R^n$ , 输出的权值矩阵为  $W = R^{h \times m}$ , 隐节点  $i$  的激活函数为  $\Phi_i$ , 其数据中心值为  $c_i$ , 则  $k$  个输出可以表示成公式:

$$y_k = \sum_{i=1}^h w_i \Phi_i(\|x - c_i\|) \quad (1)$$

RBF 神经网络的特点是采用距离作为隐节点的基函数,同时激活函数使用高斯径向基函数,如式(2).

$$\Phi_i(x) = \exp\left(-\frac{\|x - c_i\|^2}{2\sigma_i^2}\right), i = 1, 2, \dots, h \quad (2)$$

RBF 神经网络中的隐层到输出层的权值,通常采用最小二乘法、梯度下降法等方法训练该参数,但是传统算法构建 RBF 神经网络时,无法避免由于神经元之间差异性过小造成的神经网络训练结果精度过低的缺陷,因此,本文提出用灰狼优化算法优化该权值<sup>[8-9]</sup>.

### 2.2 改进灰狼优化算法原理

灰狼算法(GWO, Grey wolf optimizer)模拟自然界中灰狼的等级制度与狩猎行为<sup>[10-11]</sup>,整个狼群按照适应度排序被分为四组: $\alpha, \beta, \delta, \omega$ . 如图 2 所示,前三组依次是适应度最好的三组,这三组指导  $\omega$  向着目标搜索前进,在优化过程中,狼群更新  $\alpha, \beta, \delta, \omega$  的位置,个体之间的距离表示如式(3)所示,式(4)表示灰狼个体的更新方式.




图 2 灰狼等级体系图

$$D = |C \cdot X_p(t) - X(t)| \quad (3)$$

$$X(t+1) = X_p(t) - A \cdot D \quad (4)$$

变量  $D$  表示个体与食物的距离,  $t$  表示当前迭代的次数,  $A = 2a \cdot r_2 - a$ ,  $C = 2r_1$ ,  $X_p$  代表猎物的位置,  $X$  表示灰狼的位置向量, 收敛因子  $a$  随着迭代次数线性从 2 线性递减到 0,  $a = 2 - 2 \times (\frac{t}{\max})$ ,  $t$  是当前的迭代次数,  $\max$  是最大迭代次数,  $r_1$  和  $r_2$  均是  $[0, 1]$  之间的随机数. 由于灰狼算法在收敛的过程中并不是线性的,线性的收敛因子并不能合适体现灰狼算法的收敛过程如图 3 所示,因此,本文提出一种基于正弦的收敛因子公式,如式(5)所示:

$$a = \sin\left(\frac{t \times \pi}{\max} + \frac{\pi}{2}\right) + 1 \quad (5)$$




图 3 收敛因子对比图

当灰狼判断出猎物的位置时,头狼  $\alpha$  带领  $\beta$  和  $\delta$  指导狼群对猎物进行包围,因为  $\alpha, \beta, \delta$  是最靠近猎物的,所以利用这三头狼的位置判断猎物大致位置,逐渐逼近猎物,数学描述如式(6)~(8)所示:

$$D_\alpha = |C_1 \cdot X_\alpha(t) - X(t)| \quad (6)$$

$$D_\beta = |C_2 \cdot X_\beta(t) - X(t)| \quad (7)$$

$$D_\delta = |C_3 \cdot X_\delta(t) - X(t)| \quad (8)$$

$X_\alpha$  表示  $\alpha$  当前位置,  $X_\beta$  表示  $\beta$  当前位置,  $X_\delta$  表示  $\delta$  当前位置.  $C_1, C_2, C_3$  表示一个随机向量,  $X(t)$  表示当前灰狼位置向量. 公式(6)~(8)分别定义了  $\omega$  狼朝向  $\alpha, \beta, \delta$  的前进的步长和方向. 公式(9)~(12)定义  $\omega$  最终的位置.  $A$  和  $C$  分别是随机向量和自适应向量.

$$X_1 = X_{\alpha} - A_1 \cdot D_{\alpha} \tag{9}$$

$$X_2 = X_{\beta} - A_2 \cdot D_{\beta} \tag{10}$$

$$X_3 = X_{\delta} - A_2 \cdot D_{\delta} \tag{11}$$

$$X(t+1) = (X_1 + X_2 + X_3)/3 \tag{12}$$

3 IGWO-RBF 模型

本文将 RBF 神经网络隐层到输出层的权值矩阵  $W$  映射成为人工灰狼的位置向量  $\mathbf{W} = [\omega_{11}, \omega_{12}, \omega_{13}, \dots, \omega_{1M}, \omega_{21}, \dots, \omega_{mM}]$ , 首先将人工灰狼个体的位置在定义域内随机产生, 适应度定义为如式(13)的人工神经网络输出的均方误差, 然后利用灰狼算法的迭代计算出最优权值。

$$MSE = \sum_{i=1}^m (o_i^k - d_i^k)^2 \tag{13}$$

其中  $m$  是输出的数量,  $d_i^k$  是第  $k$  个训练样本的第  $i$  个期望输出,  $o_i^k$  是第  $k$  个训练样本的第  $i$  个实际输出。算法步骤如图 4 所示。




图 4 IGWO-RBF 流程图

- (1)首先随机选择  $H$  个训练样本作为聚类中心,通过聚类算法确定隐层中心值和宽度值。
- (2)在定义域内随机产生若干人工狼个体,适应度采用公式(13),通过改进灰狼算法计算最优狼的位置,重新映射为 RBF 隐层到输出层的权值。
- (3)将(2)计算所得权值应用到 RBF 神经网络中,输入训练样本,得到训练后的 RBF 模型。

4 实验及结果分析

4.1 实验准备

仿真实验的运行环境为 IntelCorei5 CPU,主频 3.20 GHz,内存 4 GB,windows 7 64 位操作系统,实验仿真软件采用 Matlab R2015a.使用 KDD CUP 99 数据集的抽样数据来检测所提出的 IGWO-RBF 算法的性能,同时实验采用正确率、误差率和漏报率三个指标来评判.本文除了权值优化算法不同外,其余均统一参数。

RBF 神经网络有三个参数需要学习:隐层节点中心、宽度及隐层到输出层的权值,本文统一 RBF 隐层中心、宽度均采用 K-means 算法计算所得,权值分别采用 IGWO 算法、GWO 算法、梯度下降法用作对比.同时需要指出,由于不同的实验环境、不同的参数设置对神经网络算法有影响,而目前对于神经网络参数设置方面并没有规范.因此,为了可以有效的避免过学习以及欠学习状态的发生,本实验都采用十折交叉检验法,并且每组实验五十次,取其平均值作为最终结果.表 1 列举了实验对比的方法及特点。

表 1 实验方法对比及特点

| 方法名称     | 特点                   | 迭代次数 |
|----------|----------------------|------|
| IGWO-RBF | 隐层到输出层的权值采用改进灰狼算法优化. | 300  |
| GWO-RBF  | 隐层到输出层的权值采用标准灰狼算法优化. | 300  |
| RBF      | 隐层到输出层的权值采用梯度下降法计算.  | 300  |

4.2 数据预处理

根据 Cover 定理,低维空间线性不可分的模式通过非线性映射到高维特征空间则可能实现线性可分,这也是 RBF 神经网络的理论依据.但是在高维空间进行分类或回归时,则存在确定非线性映射函数的形式和参数、特征空间维数等问题,这就需要大量的计算.维数越高,计算量越大.这也就是在高维特征空间运算时存在的“维数灾难”<sup>[12]</sup>。

当网络安全数据规模大及维度高时,对数据的处理往往变得困难,这直接导致真正的攻击隐藏在数据深处,难以发现.因此,对数据进行的特征降维是避免“维数灾难”的首要工作.我们通过对一组原始特征进行筛选,构建特征子集,从而达到降低数据维度的目的。

不同评价指标往往具有不同的量纲和量纲单位,这样的情况会影响到数据分析的结果,为了消除

指标之间的量纲影响,需要进行数据标准化处理,以解决数据指标之间的可比性.原始数据经过数据标准化处理后,各指标处于同一数量级,适合进行综合对比评价<sup>[13]</sup>.

本文对于实验数据采用 min-max 标准化,是对原始数据的线性变换,转换函数如公式(14)所示:

$$x^* = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{14}$$

5 结果分析

十折交叉检验的十次结果的正确率、误报率和漏报率分别如图 5、图 6 和图 7 所示.




图 5 算法的正确率比较




图 6 算法的误报率比较

由图 5 可以看出,IGWO-RBF 所预测的正确率明显高于 GWO-RBF 及传统学习方法构建的 RBF,同时,从图中的十次趋势可以看出:IGWO-RBF 的正确率在走势上比其他两种方法构建的 RBF 都要稳定.说明 IGWO-RBF 检测的正确率的稳定性要高于所对比的两种对比算法.

同时图 6 和图 7 结果表明 IGWO-RBF 算法所测误差率和漏报率也略低于后者.说明采用 IGWO 优化的 RBF 神经网络在 KDD CUP99 数据集的分类效果上比起 GWO-RBF 和 RBF 是有所提升的.

对十次数据的平均值统计结果如表 2 所示,采用 IGWO 优化的 RBF 在平均正确率上能达到 94.




图 7 算法的漏报率比较

8%,高出 GWO-RBF 两个百分点,且更远远高于原生 RBF,而误报率和漏报率均是最低的.实验表明:优化后的 IGWO-RBF 算法在正确率上高于 GWO-RBF 及 RBF,同时在误报率和漏报率略有下降.说明 IGWO-RBF 在分类效果上有提升且更加稳定.

表 2 平均实验结果 %

| 方法名称     | 正确率   | 误报率  | 漏报率  |
|----------|-------|------|------|
| IGWO-RBF | 94.80 | 5.49 | 4.93 |
| GWO-RBF  | 92.13 | 6.16 | 5.55 |
| RBF      | 80.86 | 7.64 | 6.82 |

6 结束语

本文首次将灰狼优化算法用于解决 RBF 神经网络的权值优化问题,并介绍了该算法具体的优化过程,同时为了验证 IGWO-RBF 的可行性,将该算法应用于基于 KDD CUP 99 数据集样本进行分类<sup>[14]</sup>,将其结果与 GWO-RBF 和 RBF 进行比较<sup>[14]</sup>.实验结果表明,本文提出的 IGWO-RBF 算法具有很好的分类效果,增强了 RBF 神经网络的泛化能力,使检测的效果有较大的提升.

参考文献:

[1] 徐秉铮.神经网络理论与应用[M].广州:华南理工大学出版社,1999:304-322.  
[2] 张健,刘定一.一种应用 PSO 优化 RBF 神经网络的方法[J].计算机仿真,2014,31(11):269-272.  
[3] 夏轩,许伟明.改进的粒子群算法对 RBF 神经网络的优化[J].计算机工程与应用,2012,48(5):37-40.  
[4] 庞振,徐蔚鸿.一种基于改进 k-means 的 RBF 神经网络学习方法[J].计算机工程与应用,2012,48(11):161-163.  
[5] 钱玉良,张浩,彭道刚,等. PCA 和 GA-PSO-RBF 集成的发电机组远程故障诊断[J].电子测量与仪器学报,2012,27(7):597-604.

- (12):4831-4845.
- [2] Hofmann E E, Haskell A G E, Klinck J M, et al. Lagrangian modeling studies of antarctic krill (*Euphausia superba*) swarm formation[J]. ICES J Mar Sci, 2004 (61):617-31.
- [3] Wang G G, Guo L H, Wang H Q, et al. Incorporating mutation scheme into krill herd algorithm for global numerical optimization[J]. Neural Computing and Applications, 2014, 24 (3/5):853-871.
- [4] Mandal B, Roy P K, Mandal S. Economic load dispatch using krill herd algorithm [J]. International Journal of Electrical Power & Energy Systems, 2014, 57(5):1-10.
- [5] Saremi S, Mirjalili S M, Mirjalili S. Chaotic krill herd optimization algorithm [J]. Procedia Technology, 2014, 12(1):180-185.
- [6] 王磊, 张汉鹏. 基于混沌搜索与精英交叉算子的磷虾觅食算法[J]. 计算机工程, 2015, 41(3):156-161.
- [7] 王维博. 粒子群优化算法研究及其应用[D]. 成都: 西南交通大学, 2012.
- [8] Li J P, Tang Y G, Hua C C, et al. An improved krill herd algorithm: Krill herd with linear decreasing step [J]. Applied mathematics and computation, 2014, 234(10):356-367.
- [9] Kennedy J, Eberhart R C. Particle swarm optimization [C]// Proc. IEEE Int. Conf. Neural Netw. Perth, Australia, 1995(4):1942-1948.

### 作者简介:

**刘楷女**, (1991-), 硕士研究生. 研究方向为应用统计、智能计算等.

**沈菊红女**, (1970-), 副教授, 硕士生导师. 研究方向为支持向量机、应用统计、最优化理论等.

**万仁霞(通讯作者)男**, (1975-), 博士, 副教授, 硕士生导师. 研究方向为智能计算、数据挖掘、模式识别等.

Email: wanrx1022@126.com.

**李延延男**, (1990-), 硕士研究生. 研究方向为数据挖掘与模式识别.

(上接第 10 页)

- [6] 孟锦, 马驰, 何加浪, 等. 基于 HHGA-RBF 神经网络的网络安全态势预测模型[J]. 计算机科学, 2011, 37(7):70-72.
- [7] 孙健, 申瑞民, 韩鹏. 一种新颖的径向基函数(RBF)网络学习算法[J]. 计算机学报, 2003, 25(11):1562-1567.
- [8] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3):46-61.
- [9] Mirjalili S, Mirjalili S M, Lewis A. How effective is the grey wolf optimizer in training multi-layer perceptrons[J]. Appl Intell, 2015, 43(3):150-161.
- [10] 龙文, 赵东泉, 徐松金. 求解约束优化问题的改进灰狼优化算法[J]. 计算机应用, 2015, 34(9):2590-2595.
- [11] 陈昌帅. 二进制灰狼优化算法的研究与分析[J]. 信息系统工程, 2016, 28(7):136-138.
- [12] 殷勇, 邱明. 一种基于高斯核的 RBF 神经网络学习算法[J]. 计算机工程与应用, 2002, 38(21):118-119.
- [13] 肖汉光, 蔡从中. 特征向量的归一化比较性研究[J]. 计算机工程与应用, 2009, 45(22):117-119.
- [14] 刘金生. 网络入侵检测的建模与仿真研究[J]. 计算机仿真, 2012, 28(12):103-106.

### 作者简介:

**郭振洲男**, (1976-), 博士, 讲师. 研究方向为密码学与信息安全、数据挖掘与分析.

**刘然(通讯作者)男**, (1993-), 硕士研究生. 研究方向为数据挖掘与分析. E-mail: 824267051@qq.com.

**拱长青男**, (1965-), 博士, 教授. 研究方向为云计算.

**赵亮男**, (1983-), 博士. 研究方向为无线网络路由、智能交通.