



# 计算机科学

COMPUTER SCIENCE

## 基于改进灰狼算法优化 SVR 的混凝土中钢筋直径检测方法

卢纯义, 于津, 余忠东, 丁双松, 张占龙, 裴科成

引用本文

卢纯义, 于津, 余忠东, 丁双松, 张占龙, 裴科成. [基于改进灰狼算法优化 SVR 的混凝土中钢筋直径检测方法](#)[J]. 计算机科学, 2022, 49(11): 228-233.

LU Chun-yi, YU Jin, YU Zhong-dong, DING Shuang-song, ZHANG Zhan-long, QIU Ke-cheng. [Detection Method of Rebar in Concrete Diameter Based on Improved Grey Wolf Optimizer-based SVR](#)[J]. Computer Science, 2022, 49(11): 228-233.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于灰狼优化算法的信用评估样本均衡化与特征选择同步处理](#)

Application of Gray Wolf Optimization Algorithm on Synchronous Processing of Sample Equalization and Feature Selection in Credit Evaluation

计算机科学, 2022, 49(4): 134-139. <https://doi.org/10.11896/jsjcx.210300075>

[改进的支持向量回归机在电力负荷预测中的应用](#)

Application of Power Load Prediction Based on Improved Support Vector Regression Machine

计算机科学, 2020, 47(6A): 58-65. <https://doi.org/10.11896/JsJkx.191000042>

[融合渐近性的灰狼优化支持向量机模型](#)

Support Vector Machine Model Based on Grey Wolf Optimization Fused Asymptotic

计算机科学, 2020, 47(2): 37-43. <https://doi.org/10.11896/jsjcx.190100092>

[基于自适应调整策略灰狼算法的 DV-Hop 定位算法](#)

DV-Hop Localization Algorithm Based on Grey Wolf Optimization Algorithm with Adaptive Adjutment Strategy

计算机科学, 2019, 46(5): 77-82. <https://doi.org/10.11896/j.issn.1002-137X.2019.05.012>

[灰狼优化算法研究综述](#)

Comprehensive Review of Grey Wolf Optimization Algorithm

计算机科学, 2019, 46(3): 30-38. <https://doi.org/10.11896/j.issn.1002-137X.2019.03.004>

# 基于改进灰狼算法优化 SVR 的混凝土中钢筋直径检测方法

卢纯义<sup>1</sup> 于津<sup>1</sup> 余忠东<sup>1</sup> 丁双松<sup>1</sup> 张占龙<sup>2</sup> 裘科成<sup>2</sup>

1 国网浙江省电力有限公司兰溪市供电公司 浙江 金华 321100

2 重庆大学输配电装备及系统安全与新技术国家重点实验室 重庆 400044

(luchunyi@sohu.com)

**摘要** 传统钢筋混凝土检测方法通过线性拟合或标准值查表法只能对钢筋直径做大致估算,无法精确测量。针对钢筋直径检测中样本数据较少、检测结果受到钢筋埋深及相邻钢筋间距的影响而非表现出非线性回归变化的情况,提出了基于改进灰狼算法(Improved Grey Wolf Optimizer, IGWO)优化的支持向量回归机(Support Vector Regression, SVR)检测方法(IGWO-SVR)。首先,通过反向学习策略优化初始化种群分布,改善了灰狼优化算法(Grey Wolf Optimizer, GWO)的全局搜索能力,通过随机差分变异策略扩大狼群动态搜索范围,避免了灰狼优化算法陷入局部最优;然后,将改进后的灰狼优化算法应用于支持向量回归机的核心参数寻优,以改良算法模型的检测性能;最后,与另外3种算法模型的实验结果进行对比分析,结果表明了所提方法在钢筋直径检测中的精度以及优化模型与实际值的拟合度都得到了有效提升。

**关键词:** 钢筋直径;灰狼优化算法;支持向量回归机;反向学习策略;随机差分变异策略

中图分类号 TP301

## Detection Method of Rebar in Concrete Diameter Based on Improved Grey Wolf Optimizer-based SVR

LU Chun-yi<sup>1</sup>, YU Jin<sup>1</sup>, YU Zhong-dong<sup>1</sup>, DING Shuang-song<sup>1</sup>, ZHANG Zhan-long<sup>2</sup> and QIU Ke-cheng<sup>2</sup>

1 Lanxi Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd, Jinhua, Zhejiang 321100, China

2 State Key Laboratory of Power Transmission Equipment & System Security and New Technology, Chongqing University, Chongqing 400044, China

**Abstract** The traditional reinforced concrete detection method uses linear fitting or standard value look-up table method, which can only roughly estimate the diameter of rebar. In view of the fact that there are few sample data of the diameter detection, and the detection result changes non-linearly due to the influences of the buried depth and the distance between adjacent rebars, a SVR detection method based on IGWO is proposed (IGWO-SVR). Firstly, the inverse learning strategy is used to optimize the initial population distribution, which improves the GWO global search ability. And the random differential mutation strategy is used to expand the search range, which can avoid the GWO algorithm from falling into the local optimum. Then, the IGWO algorithm is applied to the core parameter optimization of the SVR to improve the detection performance. Finally, the comparison and analysis of experimental results with the other three algorithm models show that the accuracy of the proposed method in the detection of rebar diameter has been effectively improved.

**Keywords** Rebar diameter, GWO, SVR, Reverse learning strategy, Random differential mutation strategy

### 1 引言

钢筋混凝土材料被广泛应用于建筑设施及电力设施的基础构架中,其结构的耐久性很大程度上取决于内部钢筋的质量<sup>[1]</sup>。但在目前钢筋混凝土相关设施的生产过程中,部分厂家使用拉伸打磨后的废旧钢筋以次充好,其实际直径小于设计尺寸,令钢筋混凝土结构的抗压、抗裂及抗冲击能力均大打折扣,导致在未达到预定的使用年限就发生结构性失效,甚至造成坍塌事故,给人民的生命安全带来了巨大的威胁并造成

了大量的经济损失<sup>[2]</sup>。因此,准确掌握混凝土内钢筋直径的实际大小,对排除各类建筑设施的安全隐患有着重大意义。

目前,由于装置自身测量精度的不足以及分析算法的选择不当,常用的检测仪对钢筋直径的测量往往高于±1个规格,容易对钢筋直径造成错误的判断,因此检测结果的参考价值不高<sup>[3]</sup>。国内外相关研究机构也对钢筋参数检测方法进行了大量的研究<sup>[4-5]</sup>,基于电磁感应原理,文献[6]通过检测钢筋在不同距离下的脉冲涡流瞬态响应衰减时间来测量钢筋参数,文献[7]利用锁相放大器得到相差90°相位的检测信号Y

到稿日期:2021-08-04 返修日期:2021-10-23

基金项目:国家自然科学基金(52077012)

This work was supported by the National Natural Science Foundation of China(52077012).

通信作者:张占龙(zhangzlc@cqu.edu.com)

与激励信号  $X$  绘制  $X$ - $Y$  图,并测量其斜率,从而测量钢筋参数,但它们均未同时考虑钢筋埋深和间距大小的影响,导致检测精度较低且适用性不足。

在钢筋直径检测过程中,钢筋埋深及相邻钢筋间距是主要影响因素,每次获取不同情况下的直径检测数据都需要改变钢筋的埋深及间距设置,操作较为复杂,样本数据较少。在分析算法上,文献[8]建立钢筋检测标准数据库并采用查表法进行钢筋参数测量,受到样本容量的限制,精度较低;文献[9]利用改进 BP 神经网络(Back Propagation Neural Network, BPNN)对检测数据进行分析,相比标准 BPNN,该方法在精度上有了提升,但同样未考虑钢筋间距的影响。

针对以上情况,本文提出了基于改进灰狼算法优化 SVR 的钢筋直径检测方法,旨在在样本数据较少且影响因素较多的情况下实现钢筋直径的有效检测。首先通过反向学习策略和随机差分变异策略改善灰狼优化算法的全局搜索能力,避免灰狼优化算法陷入局部最优;然后将改进后的灰狼优化算法应用于支持向量回归机的核心参数寻优,以改良算法模型的检测性能;最后,利用 IGWO-SVR 进行钢筋直径检测,并与 BPNN、默认参数 SVR 及标准灰狼算法优化 SVR(GWO-SVR)的检测结果进行了对比分析,验证了所提方法的可行性。

## 2 钢筋直径检测原理

基于磁化效应的基本原理,当铁磁物质处在外磁场中,其内部所含有的大量磁畴会转向与外磁场方向一致,有非常大的饱和磁化磁场强度  $B_m$ <sup>[10]</sup>,在磁化煤质区域  $V'$  内取一体积元  $dV'$ ,其闭合表面面积为  $S'$ 。根据电磁场的矢量恒等式及斯托克斯定理,空间某点磁化磁场的强度为:

$$B_m = \frac{\mu_0}{4\pi} \int_{V'} \frac{\nabla' \times M}{r^2} \vec{r} dV' + \frac{\mu_0}{4\pi} \oint_{S'} \frac{M}{r^2} \vec{r} dS' \quad (1)$$

其中,  $M$  为铁磁物质磁极化强度,  $\mu_0$  为真空磁导率,  $r$  为磁化区域到空间某点的矢径。磁化磁场极大地增强了原磁场,增强后的磁感应强度  $B'$  可以被看成原磁场  $B_0$  与  $B_m$  相叠加的结果,即:

$$B' = B_0 + B_m = \mu_0 (H + M) = \mu_0 \mu_r H \quad (2)$$

又由于钢筋为圆柱体,式(1)中的两个积分项的积分范围与钢筋直径之间的关系为:

$$\begin{cases} V' = \frac{\pi d^2}{4} \cdot h \\ S' = \frac{\pi d^2}{2} + \pi d \cdot h \end{cases} \quad (3)$$

当  $d$  变大时,积分范围增加,积分式  $B_m$  增大,从而导致最终检测到的叠加磁场  $B'$  增大;反之,  $B'$  减小。从微观角度来看,钢筋直径  $d$  变大,同一长度的钢筋其内部的磁畴数量变多,而外磁场影响下产生的总磁化等效电流为单个磁畴等效磁化电流与磁畴数量的乘积,因此磁化磁场也得到了增强。因此,检测空间磁场强度值  $B'$  并分析其与钢筋直径之间的函数关系即可反演出钢筋直径。

在钢筋直径检测过程中,钢筋埋深及钢筋间距是主要影响因素,如图 1 所示。埋深  $L$  的变化影响式(1)中的矢径  $r$  进而改变检测值,而相邻钢筋的存在令磁化磁场强度  $B_m = B_{m0} + B_{m1}$ ,且其间距  $D$  越小影响越大。

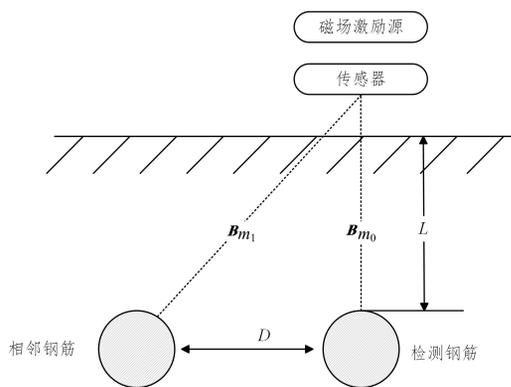


图 1 钢筋磁测量原理

Fig. 1 Principle of magnetic measurement of rebars

检测值  $y$  的函数关系为:

$$y = f(d, L, D) \quad (4)$$

除了受到埋深及间距的影响,检测结果还存在样本容量小的局限性。由于支持向量回归机对样本大小的依赖性不强,将大样本训练转化为寻找少量特征样本,在实际应用中具有较好的泛化能力,因此可以通过 SVR 构建检测结果与钢筋实际值之间的函数关系。

然而,针对不同数据结构类型,SVR 核心参数的选择不当往往会使其陷入局部最优,或者灵敏度和拟合程度大大降低。而 GWO 作为一种全局搜索能力强、结构简单、易实现的优化算法,十分适用于 SVR 的参数优化。因此,本文在已有算法研究的基础上,通过不同策略改进 GWO 算法来实现 SVR 参数寻优,使 SVR 在钢筋直径检测中提升拟合度、降低预测误差。

## 3 算法原理及改进方法

### 3.1 支持向量回归机

SVR 是将训练样本尽量拟合到一个回归模型中,利用核函数可将非线性关系映射至高维空间,得到能明确表达输入输出的非线性关系函数<sup>[11-12]</sup>。

在 SVR 的损失函数中需要定义一个允许误差值  $\epsilon > 0$ ,对于样本数据  $(x_i, y_i)$ ,假设其可通过某个非线性变换函数  $\phi$  将数据从低维映射至高维空间,当其满足  $|y_i - w \cdot \phi(x_i) - b| \leq \epsilon$  时无损失,反之则对应的损失为  $|y_i - w \cdot \phi(x_i) - b| - \epsilon$ 。如图 2 所示,在二维平面来体现  $\epsilon$  的作用,当样本数据处于虚线框内时无损失,而样本数据处于虚线框外时存在损失,大小为红色线段的长度<sup>[13-15]</sup>。

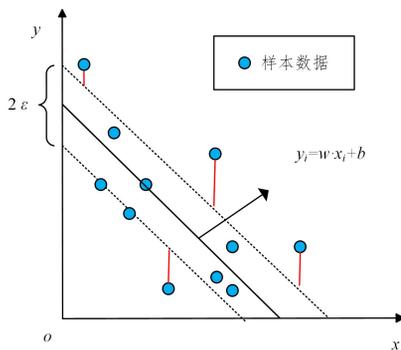


图 2 SVR 样本分布(电子版为彩图)

Fig. 2 SVR sample distribution

设  $|y_i - \omega \cdot \phi(x_i) - b|$  的值为  $s$ , 可知 SVR 损失函数为:

$$\text{err}(x_i, y_i) = \begin{cases} 0, & s \leq \epsilon \\ s - \epsilon, & s > \epsilon \end{cases} \quad (5)$$

随着  $\epsilon$  取值增大, SVR 的灵敏度会降低, 易陷入“欠学习”; 反之, 易陷入“过学习”。

SVR 模型中另一个重要参数为惩罚因子  $C$ , 用于调节优化方向中的两个指标, 即间隔大小、分类准确度, 其值的大小决定了算法模型的拟合程度。

由于钢筋直径检测 SVR 为多输入单输出的非线性关系, 径向核函数(Radial Basis Function, RBF)可以将样本映射到一个更高维的空间, 便于处理类别标签(Class Labels)和数据特征之间的关系是非线性时的情况, 同时具有适用性广、参数少、数值计算更简单的优点, 因此核函数选择 RBF。RBF 自带参数  $\gamma$  (简称  $g$ ) 决定了数据映射到新的特征空间后的分布, 进一步影响了训练和预测的速度。

因此, 将上述 3 个参数作为寻优的目标参数, 如表 1 所列。

表 1 IGWO 寻优目标参数

Table 1 Optimize target parameters of IGWO

参数	描述	默认值
$\epsilon$	损失函数允许误差值	0.01
$C$	SVR 惩罚因子	45
$g$	RBF 核函数参数	2.8

### 3.2 标准灰狼优化算法

标准 GWO 算法是一种模拟灰狼等级制度及狩猎机制的群体智能优化算法, 具备精度高、收敛性强、参数少、易实现的优点<sup>[16-18]</sup>, 适用于 SVR 的参数寻优。

标准 GWO 算法有  $\alpha, \beta, \delta$  3 只头狼及  $\omega$  底层狼, 按照严格的等级制度, 按优先级大小从上至下排序, 如图 3 所示。

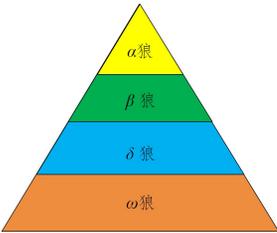


图 3 GWO 等级制度

Fig. 3 Hierarchy of GWO

为了模拟灰狼的搜索行为, 假设  $\alpha, \beta, \delta$  具有较强的识别潜在猎物(SVR 参数最优值)的能力, 在每次迭代过程中, 保留当前种群中最好的 3 只狼( $\alpha, \beta, \delta$ ), 然后根据它们的位置信息来更新其他底层  $\omega$  狼的位置, 狼群的位置更新过程即为 SVR 参数寻优的过程<sup>[19]</sup>, 如图 4 所示。图 4 中,  $A_1, A_2, A_3$  为  $\alpha, \beta, \delta$  狼的模拟搜索范围,  $a_1, a_2, a_3$  为  $\alpha, \beta, \delta$  狼的攻击范围(获得最优解),  $D_\alpha, D_\beta, D_\delta$  表示  $\omega$  狼与最优 3 条狼之间的距离。GWO 算法分为 3 个阶段。

(1) 包围阶段。在头狼带领下狼群逐渐接近猎物并包围它, 灰狼个体与猎物之间的距离  $D$  如式(6)所示, 灰狼个体的位置更新表达式如式(7)所示。

$$D = A \otimes X_p(t) - X(t) \quad (6)$$

$$X(t+1) = X_p(t) - B \otimes D \quad (7)$$

其中,  $t$  为当前迭代次数;  $\otimes$  表示哈达玛(hadamard)乘积操作;  $X_p$  表示猎物的位置向量;  $X(t)$  表示当前灰狼的位置向量;  $A$  和  $B$  是协同系数向量, 表达式如下:

$$\begin{cases} A = 2 \otimes r_2 \\ B = 2a \otimes r_1 - a \end{cases} \quad (8)$$

其中,  $a$  为收敛因子,  $r_1$  和  $r_2$  为随机向量。

(2) 狩猎阶段。 $\omega$  个体狼依靠  $\alpha, \beta, \delta$  3 只头狼的指引来靠近猎物, 该行为的数学模型可表示为:

$$\begin{cases} D_\alpha = A_1 \otimes X_\alpha - X \\ D_\beta = A_2 \otimes X_\beta - X \\ D_\delta = A_3 \otimes X_\delta - X \end{cases} \quad (9)$$

其中,  $X_\alpha, X_\beta, X_\delta$  表示当前种群中  $\alpha, \beta, \delta$  的位置向量;  $X$  表示  $\omega$  狼的位置向量;  $D_\alpha, D_\beta, D_\delta$  表示  $\omega$  狼与最优 3 条狼之间的距离;  $A_1, A_2, A_3$  为随机向量。

(3) 攻击阶段。由式(8)可知,  $a$  的变化会引起  $B$  的波动, 其中  $a$  在迭代过程中呈线性下降, 当  $B$  在  $[-1, 1]$  区间时获得 SVR 最优参数。

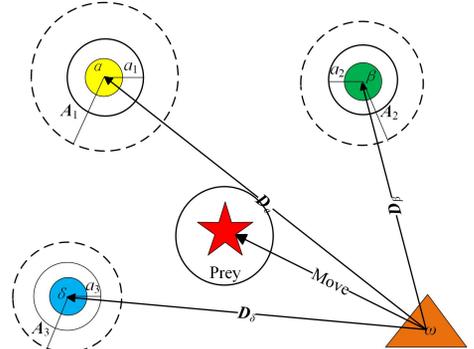


图 4 GWO 狼群位置更新过程

Fig. 4 GWO wolf pack location update process

### 3.3 GWO 改进方法

尽管标准 GWO 算法的结构简单且易实现, 但仍存在全局搜索能力不强及易陷入局部最优等不足。针对这些不足, 对标准 GWO 算法的初始化过程和搜索机制进行了优化, 形成了改进灰狼优化算法。

#### 3.3.1 反向学习策略

标准 GWO 算法由于随机策略生成的种群对空间信息的了解和利用程度不够, 收敛速度无法预知, 因此计算消耗的时间长。基于反向学习的种群初始化策略可以扩大初始化种群的覆盖范围<sup>[20]</sup>。

假设源数  $P \in [a, b]$ , 则其反向数字为:

$$\bar{P} = a + b - P \quad (10)$$

当该反向数字处于  $N$  维空间中时, 其定义的源点  $x = (P_1, P_2, \dots, P_N)$ , 则每一维的反向数字和反向源点为:

$$\bar{P}_N = a_N + b_N - P_N \quad (11)$$

$$\bar{x} = (\bar{P}_1, \bar{P}_2, \dots, \bar{P}_N)$$

其中,  $P_N \in [a_N, b_N]$ ,  $a_N$  和  $b_N$  分别用于决定反向源点在第  $N$  维的下限与上限。

GWO 的计算时间与  $\alpha$  狼(最优狼)和其余狼之间的距离

有关,如果  $\alpha$  狼在最优值附近出生,那么这次计算中狼群的所有个体都会快速地收敛。因此,当引入反向学习策略时,同时考虑每头狼的反向个体,则其更靠近最优值的概率增加了一倍,选中更靠近的狼作为狼群的  $\alpha$  狼,则其余狼都离最优解更近了一步。

以如图 5 所示的二维空间位置向量为例,当迭代过程中  $\alpha$  狼的位置处于点  $(a, b)$ ,目标向量处于图 5 中所示位置时,两者之间的距离为  $d_1$ 。通过反向学习可得到点  $(a', b)$ ,  $(a, b')$  及  $(a', b')$ ,与目标的距离分别为  $d_2, d_3, d_4$ 。而  $d_2$  与  $d_4$  显然小于初始点与目标点之间的距离  $d_1$ ,因此以  $d_2$  与  $d_4$  为新的  $\alpha$  狼在下次迭代中可以得到更优解。

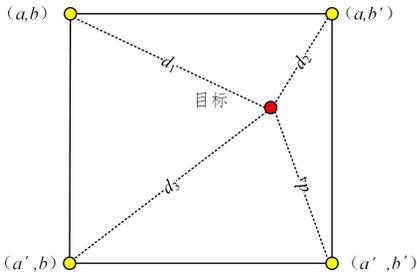


图 5 反向学习在二维坐标系中的显示

Fig. 5 Display in reverse learning 2-D coordinate system

反向学习可有效扩大种群的覆盖面积,但在算法后期接近目标函数时反而会增加计算量,降低计算速度。因此,设定线性减小的反向学习概率  $t$  和随机数  $rand1$ ,反向学习策略主要应用于 GWO 初始阶段,具体流程如算法 1 所示。

**算法 1 随机反向学习 GWO 种群初始化**

1. begin
2. if  $rand1 < t$
3.  $\overline{P_N} = a_N + b_N - P_N$
4.  $\overline{x} = (\overline{P_1}, \overline{P_2}, \dots, \overline{P_N})$
5. else
6.  $\mathbf{P} = \mathbf{P}$
7. end

**3.3.2 随机差分变异策略**

当灰狼位置在迭代过程中不断更新时,容易出现局部极值点灰狼密集的情况,此时 GWO 陷入局部最优解。为避免这种情况的发生,在原个体狼上添加随机差分变异,扩大搜索范围。随机差分扰动策略如下:

$$\mathbf{X}_i(t+1) = \mathbf{X}_{r_1}(t) + F(\mathbf{X}_{r_2}(t) - \mathbf{X}_{r_3}(t)) \quad (12)$$

其中,  $\mathbf{X}_{r_i} (i=1, 2, 3)$  分别为狼群中随机挑选 3 个个体狼的位置向量,且个体狼  $r_i \in [1, N]$ ,  $F$  为缩放因子,其值为:

$$F = 0.5 + 0.5rand \quad (13)$$

将两个个体狼的差分向量经缩放因子  $F$  缩放后与第三个个体狼位置向量结合,形成新个体狼位置向量  $\mathbf{X}_i$ ,实现了随机差分变异策略。

为了使该策略主要用于 GWO 前期的寻找猎物阶段而提高全局搜索能力,引入随机变异概率  $k$ ,其值为:

$$k = 1 - \left(\frac{t}{t_{max}}\right)^3 \quad (14)$$

其中,  $t$  为当前迭代次数,  $t_{max}$  为最大迭代次数。  $k$  值的变化如

图 6 所示,在 GWO 迭代初期取值较大,随机差分变异发生概率较大,而在迭代后期,由于灰狼个体差异小且每次迭代幅度不大,可不进行随机差分变异,因此  $k$  值衰减较快。

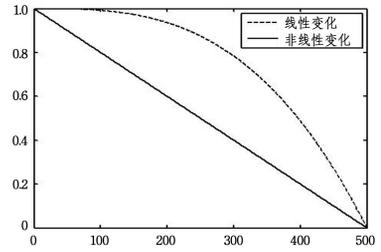


图 6  $k$  值变化趋势

Fig. 6 Trend of  $k$

随机差分变异 GWO 的过程如算法 2 所示。

**算法 2 随机差分变异与 GWO 结合**

1. begin
2. if  $rand2 < k$
3.  $\mathbf{X}_i(t+1) = \mathbf{X}_{r_1}(t) + F(\mathbf{X}_{r_2}(t) - \mathbf{X}_{r_3}(t))$
4. else
5.  $\mathbf{X}(t+1) = \mathbf{X}_p(t) - B \odot D$
6. end

经反向学习策略及随机差分变异策略优化后的 IGWO 算法较原标准算法在全局搜索能力上有了较大提升,且在迭代过程中能够有效避免陷入局部最优。将 IGWO 应用于 SVR 参数寻优,进一步结合钢筋直径检测数据样本可形成基于 IGWO-SVR 的钢筋直径检测方法。

**4 实验分析**

**4.1 数据获取及处理**

为验证基于改进灰狼优化 SVR 在钢筋直径测量方面的性能,在实验室搭建检测平台以采集数据样本,如图 7 所示。基于电磁感应原理及铁磁材料磁化效应,当钢筋直径变化时可以得到不同的检测值,将这些值作为 IGWO-SVR 的输入  $x_1$ ;钢筋埋深及间距是直径检测的主要影响因素,作为 IGWO-SVR 的输入  $x_2, x_3$ ;钢筋直径的实际大小作为 IGWO-SVR 输出  $y$ 。

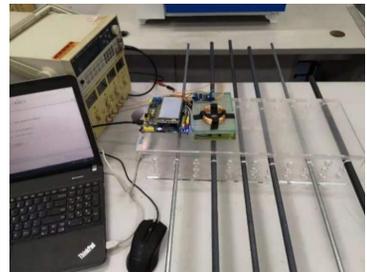


图 7 实验平台

Fig. 7 Experimental platform

将用于实验的钢筋直径范围设定为 8~16 mm,将其分为 5 组,间隔为 2 mm;将钢筋埋深测量范围设定为 15~40 mm,将其分为 6 组,间隔为 5 mm,将钢筋间距变化范围设定为 15~40 mm,将其分为 6 组,间隔为 5 mm。将不同直径的钢筋在不同埋深及间距下进行实验,共采集 300 个样本,随机划分

为 250 个训练样本用于钢筋检测模型的建立,将 50 个测试样本用于模型验证。

通过实验检测获得的数据,可以得到检测值与钢筋埋深、间距之间的关系,如图 8 所示。根据图 8 可以看出,钢筋直径检测值与钢筋埋深、间距均呈现负相关函数关系。为了避免输入数据级差别太大而引起的预测误差较大,分别将检测值、埋深及间距数据归一化处理,得到的钢筋样本数据结构如表 2 所列。

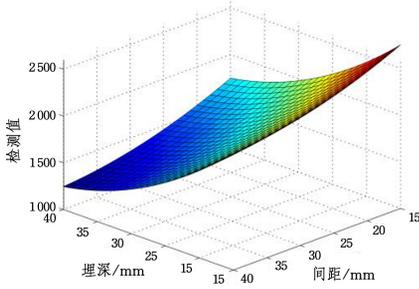


图 8 检测值与埋深及间距之间的关系

Fig. 8 Relationship between detection value and buried depth and spacing

表 2 钢筋样本数据结构(归一值)

Table 2 Rebar data structure of samples

编号	检测值 $x_1$	影响因素		实际直径 $y$
		间距 $x_2$	埋深 $x_3$	
1	0.2239	0.7653	0.8637	12
2	0.3783	0.3427	0.6343	10
3	0.5237	0.5368	0.4376	14
4	0.3576	0.5873	0.6753	12
...	...	...	...	...
250	0.8667	0.2357	0.5324	16

#### 4.2 IGWO-SVR 模型预测

首先利用 IGWO 算法对 SVR 模型参数进行优化,参数寻优区间如下:损失函数允许误差值  $\epsilon \in [0, 1]$ ,默认值为 0.1;惩罚因子  $C \in [1 \times 10^{-4}, 100]$ ,默认值为 45;RBF 参数  $g \in [1 \times 10^{-4}, 100]$ ,默认值为 2.8。IGWO 中的最大迭代次数为 500,种群规模为 30。通过对训练数据集的学习得到 SVR 参数寻优结果  $(\epsilon, C, g) = (49, 0.108, 2.3158)$ 。

为了体现 IGWO-SVR 算法模型相比其他传统智能算法模型在钢筋直径检测中的优势,将其检测结果与 BPNN 模型检测结果进行对比,其中 BPNN 为 3 层结构,输入层有 3 个节点,输出层有 1 个节点,隐含层有 5 个节点,激励函数为  $f(x) = 1/(1 + e^{-x})$ ,训练次数为 500;同时,为了验证 IGWO-SVR 在标准模型上的改进优势,将其检测结果与默认参数 SVR(c:1, g:2.8, p:0.1)模型及标准灰狼算法优化支持向量回归机(GWO-SVR)的检测结果进行对比。预测结果如图 9、图 10 所示。

根据图 8 可以看出,IGWO-SVR 的钢筋直径预测结果绝对误差相比其他几种算法波动最小,最大值不超过 0.5, GWO-SVR 与默认参数 SVR 的绝对误差相近,说明未改进 GWO 对 SVR 参数的优化效果并不明显,BPNN 绝对误差最大值为 3.2 mm,大于一个钢筋规格,实际检测结果不具有参考价值。

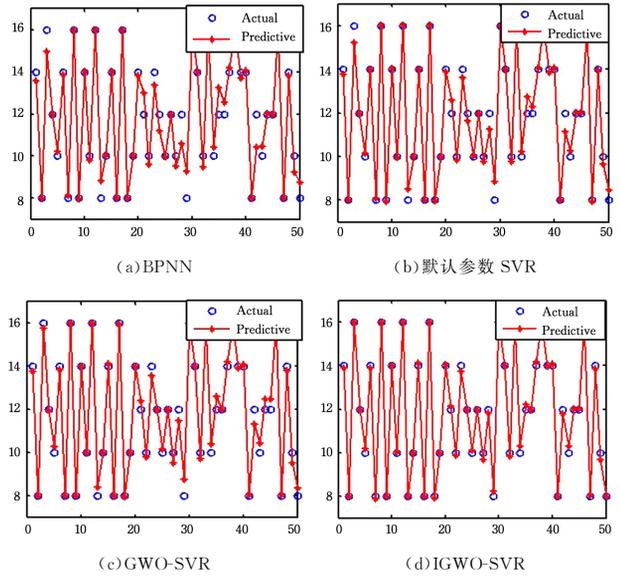


图 9 各算法的预测值与实际值

Fig. 9 Predicted and actual values of each algorithm

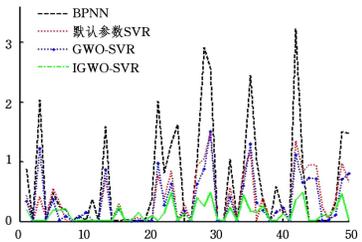


图 10 各算法的绝对误差曲线图

Fig. 10 Absolute error curve of each algorithm

为了更加直观地体现 4 种算法得到的实验结果的精确性并对其进行对比分析,本文通过计算其均方根误差(Root Mean Square Error, RMSE)、平均绝对误差(Mean Absolute Error, MAE)及拟合系数  $R^2$  来反映各算法的实际情况。RMSE 和 MAE 均反映了算法模型的精确度,其值越小,精确度越高; $R^2$  表示算法模型对于实际值的拟合度,其值越大,拟合度越高。对应的计算式如(15)式(17)所示:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - y_i')^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - y_i'| \quad (16)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - y_i')^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (17)$$

其中,  $y_i$  和  $y_i'$  为第  $i$  个钢筋直径的实际大小和模型预估大小; $\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i$  为  $n$  个钢筋直径预估值的平均值。

根据式(15)式(17),4 种算法得到的钢筋直径检测精度如表 3 所列。

表 3 实验结果对比

Table 3 Comparison of experimental results

Algorithm	RMSE	MAE	$R^2$
BPNN	0.5400	0.7298	0.9211
默认参数 SVR	0.2805	0.3679	0.9495
GWO-SVR	0.3818	0.4675	0.9406
IGWO-SVR	0.1312	0.1675	0.9877

根据表 3 可以看出,传统 BPNN 在钢筋直径检测上的拟合度较低,均方根误差及平均误差是 4 种算法中最大的,原因可能是钢筋直径数样本较少且输入量较多。IGWO-SVR 与钢筋直径实际值拟合度达到了 98.77%,均方根误差为 0.1312,直径检测值平均绝对误差为 0.1675 mm,在钢筋直径测量上的精度高于另外 3 种算法,验证了改进灰狼优化参数的可行性。

**结束语** (1)SVR 将非线性关系通过核函数映射至高维空间,可得到能明确表达输入输出的非线性关系的函数,针对钢筋直径检测中的埋深、间距及检测值多输入与实际直径输出之间的非线性关系有较好的映射能力。

(2)以 RBF 为核函数的 SVR 中,  $(\epsilon, C, g)$  3 个参数的优化对钢筋直径检测的精确度有较大的影响,构建基于 IGWO-SVR 的钢筋直径检测模型对数据进行分析,结果表明改进后的算法的输出结果与实际值之间有较高的拟合度,其均方根误差和绝对平均误差相比未改进算法有了较大的提高。

(3)与传统神经网络算法不同,SVR 在小样本学习中仍具有较高的精确度,对于钢筋直径检测数据集较少的情况具有良好的适应性。根据检测结果,验证了在 IGWO 参数优化下的 SVR 具有良好的检测性能,为混凝土钢筋检测提供了一种可行方法。

## 参 考 文 献

[1] YE H, ZHANG Z, DAN Y, et al. Novel Method for Measurement of Rebar State of Cement Tower[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-8.

[2] XU C, ZHOU N, XIE J, et al. Investigation on Eddy Current Pulsed Thermography to Detect Hidden Cracks On Corroded Metal Surface[J]. NDT&E International, 2016, 84(12): 27-35.

[3] KAUR P, DANA K J, ROMERO F A, et al. Automated GPR Rebar Analysis for Robotic Bridge Deck Evaluation[J]. IEEE Transactions on Cybernetics, 2016, 46(10): 2265-2276.

[4] LIAO Y, XIONG B, LI Q, et al. Study on Imaging Algorithm by Using Ultrasonic Array Probes for Concrete Structures[J]. Piezoelectrics and Acousto-optics, 2012, 34(6): 932-935.

[5] SUN Y, LI Q, HUANG L, et al. Application of Simulated Annealing Genetic Algorithm to CT Imaging of Concrete Structure [J]. Piezoelectrics and Acousto-optics, 2013, 35(4): 487-490.

[6] EDDY I C, UNDERHILL P R, MORELLI J, et al. Pulsed Eddy Current Response to Liff-off in Different Sizes of Concrete Embedded Rebar[C]//2019 IEEE SENSORS. Montreal, QC, Canada, 2019: 1-4.

[7] HE D F, TAUTSUMI N, TSUTSUMI N, et al. Corrosion Evaluation of Steel Reinforcing Bar Using Electromagnetic Method [C]//2019 Photonics & Electromagnetics Research Symposium-Spring (PIERS-Spring). Rome, Italy, 2019: 690-693.

[8] LU J J. Development of Rebar Detector Based on Magnetic Measurement[D]. Harbin Institute of Technology, 2017.

[9] LI T B, YIN Y H, LI C C, et al. Analysis of the detection algorithm for internal reinforcement of reinforced concrete based on soft sensing [J]. Construction Technology, 2019, 48(6): 88-92.

[10] NI G Z. Engineering electromagnetic field[M]. Beijing: Higher Education Press, 2009.

[11] LEI J S, CHEN J F. The regression prediction analysis of grouting concrete stone's strength based on SVR [J]. Advanced-Materials Research, 2013, 859(10): 171-176.

[12] LI S, FANG H, LIU X. Parameter optimization of support vector regression based on sine cosine algorithm [J]. Expert System, 2018, 91(2): 63-77.

[13] CAO Q K, ZHAO F. Forecast of water inrush quantity from coal floor based on genetic algorithm-support vector regression[J]. Journal of China Coal Society, 2011, 36(12): 2097-2101.

[14] LIU D W, XU Q, TANG Y, et al. Prediction of Water Inrush in Long-Lasting Shutdown Karst Tunnels Based on the HGWO-SVR Model [J] IEEE Access, 2021, 9: 6368-6378.

[15] ZHOU P, GUO D W, WANG H, et al. Data-Driven Robust M-LS-SVR-Based NARX Modeling for Estimation and Control of Molten Iron Quality Indices in Blast Furnace Ironmaking[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(9): 4007-4021.

[16] HATTA N M, ZAIN A M, SALLEHUDDIN R, et al. Recent studies on optimization method of Grey Wolf Optimizer(GWO): a review(2014-2017) [J]. Artificial Intelligence Review, 2018, 18(2): 1-33.

[17] MISHRA A K, DAS S R, RAY P K, et al. PSO-GWO Optimized Fractional Order PID Based Hybrid Shunt Active Power Filter for Power Quality Improvements [J]. IEEE Access, 2020, 8: 74497-74512.

[18] LI K, CHENG G Y, SUN X D, et al. A Nonlinear Flux Linkage Model for Bearingless Induction Motor Based on GWO-LSSVM [J] IEEE Access, 2019, 7: 36558-36567.

[19] XU L W, WANG H, LIN W, et al. GWO-BP Neural Network Based OP Performance Prediction for Mobile Multiuser Communication Networks[J]. IEEE Access, 2019, 7: 152690-152700.

[20] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C]//International Conference on Computational Intelligence for Modelling, Control & Automation, IEEE, 2005: 695-701.



**LU Chun-yi**, born in 1978, master, senior engineer. His main research interests include electromagnetic measurement, electrical engineering and automation.



**ZHANG Zhan-long**, born in 1971, professor, Ph.D supervisor. His main research interests include electromagnetic measurement and numerical analysis.