

基于改进灰狼优化算法的支持 向量回归预测

钟世云¹, 张屹¹, 戴杰², 钱骏²

(1. 常州大学 机械与轨道交通学院, 江苏 常州 213164;

2. 常州星宇车灯股份有限公司, 江苏 常州 213022)

摘要: 为了提高支持向量回归 (SVR, support vector regression) 进行数据驱动预测的精度, 针对 SVR 存在的参数优化问题, 通过引入 Tent 混沌映射进行种群初始化、改进收敛方式、并结合模拟退火算法, 改进了传统的灰狼优化算法 (GWO, grey wolf optimization) 来优化 SVR 超参数, 并基于改进后的 GWO 算法提出了一种 IGWO-SVR 预测模型; 将提出的 IGWO-SVR 模型应用于 NASA 锂电池数据集仿真 SOH 预测以及实际生产中的车灯电流预测实验后, 实验结果表明 IGWO-SVR 预测模型在 NASA 锂电池数据集上进行预测的误差相较 GWO-SVR 模型降低了 23%, 相较粒子群算法和遗传算法优化的 SVR 模型均存在明显优势, 误差分别降低了 39% 和 51%; 在实际工作中使用 IGWO-SVR 模型进行车灯电流预测也取得良好效果, 与实测值之间的相对误差达到 2.67%, 相较 GWO-SVR 模型误差降低了近 7 个百分点, 证明了模型在实际应用中具有良好的价值。

关键词: 支持向量回归; 灰狼优化算法; 模拟退火; 参数优化; 数据驱动预测

Support Vector Regression Prediction Based on Improved Grey Wolf Optimization Algorithm

ZHONG Shiyun¹, ZHANG Yi¹, DAI Jie², QIAN Jun²

(1. School of Mechanical Engineering, Changzhou University, Changzhou 213164, China;

2. Changzhou Xingyu Automotive Lighting System Co., Ltd., Changzhou 213022, China)

Abstract: In order to improve the accuracy of data-driven prediction by Support Vector Regression (SVR), Aimed at the problem of SVR parameter optimization, the traditional Grey Wolf Optimization (GWO) algorithm is improved to optimize the SVR hyper-parameters by introducing Tent chaotic mapping for population initialization and improving the convergence method, and combining with the simulated annealing algorithm for the parameter optimization problem of SVR. And an IGWO-SVR prediction model based on the improved GWO algorithm is proposed. After the proposed IGWO-SVR model is applied on the simulated SOH prediction of NASA lithium battery dataset and the actual production lamp current prediction experiments, the experimental results show that compared with that of the GWO-SVR model, the prediction error of the IGWO-SVR prediction model on the NASA lithium battery dataset is reduced by 23%, the IGWO-SVR prediction model has a significant advantage over both the particle swarm algorithm and the genetic algorithm optimized SVR model, and the errors are reduced by 39% and 51%, respectively. In practice, the IGWO-SVR model has also achieved good results in predicting the lamp current, compared to the measured value, the relative error of the IGWO-SVR mode reaches 2.67%, which is nearly 7% lower than that of the GWO-SVR model, and it proves a good application value of the model in practical applications.

Keywords: support vector regression; grey wolf optimization algorithm; simulated annealing; parameter optimization; data-driven prediction

0 引言

目前, 基于数据驱动的预测方法在各行业的数据预测领域中得到了广泛的应用, 其主要思想是从历史的数据中得到预测模型, 将模型看作一个黑匣子, 无需过多地了解系统内部的机理, 只需考虑输入输出, 数据驱动方法主要

有统计方法和机器学习方法等。SVR 是基于支持向量机 (SVM, support vector machine) 的思想通过引入不敏感损失系数衍生出的一种机器学习回归算法。近几年, 机器学习算法中的 SVR 被广泛应用于预测领域, 其能够较好地处理小样本数据、非线性特性及高维度等问题, 且具有较强的泛化能力, 不易过拟合^[1]。

收稿日期: 2022-11-07; 修回日期: 2022-12-08。

基金项目: 国家自然科学基金项目 (51875053)。

作者简介: 钟世云 (1998-), 男, 江西赣州人, 硕士研究生, 主要从事数据预测和优化算法方向的研究。

通讯作者: 张屹 (1976-), 男, 甘肃兰州人, 博士, 教授, 博士生导师, 主要从事机电系统现代设计方法、智能计算等方向的研究。

引用格式: 钟世云, 张屹, 戴杰, 等. 基于改进灰狼优化算法的支持向量回归预测[J]. 计算机测量与控制, 2023, 31(7): 8-14.

SVR 在实际应用过程中, 性能依赖于学习机的超参数设定, 因此参数的选择是支持 SVR 应用中的一个难题^[2]。传统的 SVR 参数优化方法主要有交叉验证法^[3], 网格搜索法^[4]及梯度下降法^[5]等。在国外的 Olivier Chapelle 等人^[6]在 2002 年就提出运用梯度下降法来进行超参数的优化, 此方法在计算方面相对较快, 也得到了一定的推广。但是这些传统方法均存在一些弊端, 如交叉验证法计算量过大, 不适合超参数优化; 网格搜索法遍历全体组合, 非常耗时; 相较于传统参数选择方法, 群智能优化算法具有实现简单、可扩充性、通用性、鲁棒性强等特点, 在非线性参数优化问题中表现出良好的性能^[7], 群智能优化算法已经成为 SVR 参数优化的代表性方法。在国外的 Abdulhamit Subasi^[8]提出了用粒子群算法 (PSO, particle swarm optimization) 来优化支持向量机的参数并在医学方面的应用中取得较好的效果。Yuan 等人^[9]以及 Li 等人^[10]使用 PSO 算法对 SVR 超参数进行优化, 创建的人群密度和水质参数预测模型均取得了较好的效果。国内的朱霄珣等人^[11]利用遗传算法 (GA, genetic algorithm) 对 SVR 超参数同步优化, 建立 SVR 风速预测模型, 使预测精确度大大提高。陈颖等人^[12]提出一种基于灰狼优化算法的 SVR 预测模型, 相较于其他优化算法, 迭代次数更少, 拟合效果更好, 预测误差更小。在众多的群智能优化算法中, GWO 算法有着结构简单、需要调节的参数少、容易实现等特点^[13], 在参数优化领域展现出卓越的性能。然而, GWO 算法也存在着如种群多样性差, 后期收敛速度慢, 易陷入局部最优等问题。针对这些问题, 很多学者对 GWO 算法进行了改进以提升性能。胡璇等人^[14]采用了非线性的控制因子改进 GWO 算法, 改善算法的后期收敛能力。方晓玉^[15]等人使用自适应差分进化作为变异策略并引入莱维飞行改进更新位置公式改进 GWO 算法, 取得了良好的效果, 但以上两种方法都没有考虑到没有考虑到种群初始化对于种群多样性的影响。杨晓敏^[16]通过使用自适应收敛因子以及改进的位置更新公式对 GWO 算法进行改进, 应用于支持向量机的网络流量预测, 达到了较高的精度, 但在改进过程中, 没有考虑到增强算法跳出局部最优解能力。本文针对以上问题, 在种群初始化方式, 算法收敛方式及跳出局部最优解的能力 3 个方面改进了 GWO 算法, 再利用改进 GWO 算法优化 SVR 的超参数, 建立 IGWO-SVR 模型, 提升数据预测模型的性能。

1 支持向量回归

对于回归问题, 给定训练数据 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_j, y_j)\}$, $\forall x_i, y_i \in R$, 期望通过学习得到一个回归模型 $f(x) = w^T x + b$ 使得 $f(x)$ 与 y 尽可能接近, 其中 w^T 为权重矢量, b 为偏置, 均是模型的参数。

与传统回归模型不同, 支持向量回归允许 $f(x)$ 与 y 之间最多有 ϵ 的误差, 即仅当 $f(x)$ 与 y 相差值大于 ϵ 时才计算损失, ϵ 被称为不灵敏损失参数。考虑到拟合误差,

引入松弛变量 $\xi_i \geq 0$, $\hat{\xi}_i \geq 0$, 则支持向量回归的优化问题如式 (1):

$$\begin{aligned} \min & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^j (\xi_i + \hat{\xi}_i) \\ \text{s. t. } & f(x) - y_i \leq \epsilon + \xi_i \\ & y_i - f(x) \leq \epsilon - \hat{\xi}_i \\ & \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, 3, \dots, j \end{aligned} \quad (1)$$

其中: C 为正则化参数, 利用拉格朗日乘子法, 引入拉格朗日乘子 $\mu_i \geq 0$, $\hat{\mu}_i \geq 0$, $\alpha_i \geq 0$, $\hat{\alpha}_i \geq 0$, 得到拉格朗日方程:

$$\begin{aligned} L(w, b, \xi, \hat{\xi}) = & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^j (\xi_i + \hat{\xi}_i) + \\ & \sum_{i=1}^j \alpha_i (f(x) - y_i - \epsilon - \xi_i) + \sum_{i=1}^j \hat{\alpha}_i (y_i - f(x) - \epsilon - \hat{\xi}_i) - \\ & \sum_{i=1}^j \mu_i \xi_i - \sum_{i=1}^j \hat{\mu}_i \hat{\xi}_i \end{aligned} \quad (2)$$

求出参数 w , b , ξ , $\hat{\xi}$ 的偏导数并令其等于 0, 带回可得支持向量回归的对偶优化问题:

$$\begin{aligned} \max & \sum_{i=1}^j (\hat{\alpha}_i - \alpha_i) y_i - \sum_{i=1}^j \epsilon (\hat{\alpha}_i + \alpha_i) - \\ & \frac{1}{2} \sum_{i=1}^j \sum_{k=1}^j (\hat{\alpha}_i - \alpha_i) (\hat{\alpha}_k - \alpha_k) K(x_i, x_k) \\ \text{s. t. } & \sum_{i=1}^j (\hat{\alpha}_i - \alpha_i) = 0, \hat{\alpha}_i, \alpha_i \in [0, C] \end{aligned} \quad (3)$$

其中: $K(x_i, x_k)$ 为核函数, 常见的核函数主要有线性函数、多项式核函数、Sigmoid 核函数和径向基 (radial basis function, RBF) 核函数。因为 RBF 核函数本身具有非线性逼近能力强的特点, 泛化能力比较优秀, 所以一般选取 RBF 核函数作为 SVR 的核函数, 最常用的 RBF 函数是高斯核函数, 其表达式如下:

$$K(x_i, x_k) = e^{-\|x_i - x_k\|^2 / 2g^2}$$

其中: g 为核函数的参数。

式 (1) 是一个不等式约束的优化问题, 结合其求解需满足的 KKT 条件, 支持向量回归模型可以表示为:

$$f(x) = \sum_{i=1}^j \sum_{k=1}^j (\hat{\alpha}_i - \alpha_i) K(x_i, x_k) + b \quad (4)$$

由此可见, 支持向量回归模型的参数主要包括正则化参数 C , 不灵敏损失系数 ϵ 以及核函数 $K(x_i, x)$ 的参数 g , 其中, 不灵敏损失系数 ϵ 与支持向量的数目相关, 惩罚参数 C 影响模型的复杂度和稳定性, 核函数参数 g 反映样本在特征空间分布情况, 三者之间相互影响, 共同决定 SVR 模型的复杂度和泛化性能^[7]。因此选择合适的 C , ϵ , g 能够让回归模型的性能得到提升^[17]。在实际应用中, C , ϵ , g 3 个参数之间存在着相互影响的关系, 所以在选择参数的过程中, 单独对每一个参数进行优化选择既费时费力, 又不够准确, 难以达到理想的结果, 对 3 个参数形成的超参数 (C , ϵ , g) 综合选取才是更加合理的选择。

2 灰狼优化算法

SVR 的超参数主要是依靠经验自行设定, 难以使模型

获得较佳的性能, 虽然后续也发展了网格搜索法寻优, 但没有摆脱传统算法的弊端, 需要遍历所有组合, 计算量庞大、耗费时间长且精准度不高^[18], 于是逐渐衍生出使用种群智能优化算法全局优化超参数的方法。灰狼优化算法^[19]是由 Seyedali Mirjalili 等人于 2014 年提出的一种智能群体优化算法, 优点是收敛性强, 参数较少且易于实现, 适合用于参数优化领域。首先是在搜索空间中随机产生灰狼族群, 并按照每个个体的适应度高低划分群体, 适应度从第一到第三分别为 α , β , δ , 剩下的群体则为 ω 。灰狼群体捕猎的过程包括围捕, 狩猎和攻击 3 个阶段, 最终获取最优解, 各个过程描述如下:

2.1 围捕

捕猎过程中, 灰狼群体会先包围猎物, 该行为的数学模型可以表示为:

$$\vec{D} = |\vec{C} \cdot \vec{X}_p(t) - \vec{X}(t)| \quad (5)$$

$$\vec{X}(t+1) = \vec{X}_p(t) - \vec{A} \cdot \vec{D} \quad (6)$$

其中: t 代表当前迭代的次数, \vec{A} 和 \vec{C} 为协同向量, 计算方式为 $\vec{A} = 2\vec{a} \cdot \vec{r}_1 - \vec{a}$, $\vec{C} = 2 \cdot \vec{r}_2$ (其中 \vec{a} 中的分量在迭代过程中从 2 到 0 线性递减, \vec{r}_1 和 \vec{r}_2 为 $[0, 1]$ 中的随机向量), $\vec{X}_p(t)$ 为第 t 次迭代中猎物的位置向量, $\vec{X}(t)$ 为第 t 次迭代中灰狼的位置向量。

2.2 狩猎

在群体包围猎物之后, 狩猎会在 α 狼, β 狼, δ 狼的领导下进行, 每次迭代过程, 保存 α , β , δ 的位置信息, 群体则根据他们的位置信息来更新自身的位置。狩猎的数学模型表示为:

$$\begin{cases} \vec{D}_\alpha = |\vec{C}_1 \cdot \vec{X}_\alpha - \vec{X}(t)| \\ \vec{D}_\beta = |\vec{C}_2 \cdot \vec{X}_\beta - \vec{X}(t)| \\ \vec{D}_\delta = |\vec{C}_3 \cdot \vec{X}_\delta - \vec{X}(t)| \end{cases} \quad (7)$$

$$\begin{cases} \vec{X}_1 = |\vec{X}_\alpha - \vec{A}_1 \cdot \vec{D}_\alpha \\ \vec{X}_2 = |\vec{X}_\beta - \vec{A}_2 \cdot \vec{D}_\beta \\ \vec{X}_3 = |\vec{X}_\delta - \vec{A}_3 \cdot \vec{D}_\delta \end{cases} \quad (8)$$

$$\vec{X}(t+1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (9)$$

其中: \vec{X}_α , \vec{X}_β , \vec{X}_δ 代表当前迭代中 α , β , δ 的位置向量, $\vec{X}(t)$ 为第 t 次迭代中个体的位置向量, \vec{C}_1 , \vec{C}_2 , \vec{C}_3 为随机向量, \vec{D}_α , \vec{D}_β , \vec{D}_δ 代表群体中其他个体与 α , β , δ 之间的距离, $\vec{X}(t+1)$ 为个体更新后的位置向量。

2.3 攻击

攻击猎物确定猎物位置, 即得到最优解, 这一过程主要通过迭代过程中收敛因子 \vec{a} 从 2 到 0 的递减来实现, 于是群体在迭代结束后, 获取最优解。

3 改进灰狼优化算法

和大多数种群智能算法类似, GWO 算法也存在算法中后期收敛速度慢、易陷入局部最优^[20]以及局部搜索能力较差等问题。本文通过引入 Tent 混沌映射序列来增强初始种群多样性以提高算法寻优速度、改进非线性收敛因子以平衡

算法全局和局部搜索能力、并结合模拟退火算法以增强算法跳出局部最优的能力, 从而改进 GWO 算法, 提升算法的性能。

3.1 Tent 混沌映射序列

在群体优化算法领域, 通常采用伪随机数生成器对种群进行初始化, 可能导致种群分布位置不均匀, 从而降低种群的多样性以及寻优速度^[21]。相较于伪随机数生成, 混沌序列的随机性与遍历性更强, 使用混沌方法对种群进行初始化通常能取得比伪随机数更好的效果。用于群体智能优化算法领域的混沌序列主要有 Logistic 映射、Tent 映射和 Cubic 映射等。其中 Tent 混沌映射在遍历性、均匀性、规律性和迭代速度方面具有更大优势^[22]。Tent 映射又称帐篷映射, 其结构简单、分布较均匀、遍历性好, 表达式如式 (10):

$$z_{k+1}^i = \begin{cases} \frac{z_k^i}{\beta}, & 0 < z_k^i \leq \beta \\ \frac{(1-z_k^i)}{(1-\beta)}, & \beta < z_k^i < 1 \end{cases} \quad (10)$$

其中: $k=0, 1, 2, \dots, n$, 表示种群中的个体; $i=1, 2, 3, \dots, t$, 表示空间的维数, 即需优化变量的个数。

随机数生成器和 Tent 混沌映射初始化种群的分布直方图对比如图 1 所示。




图 1 随机数改进为 Tent 混沌映射生成种群的分布直方图对比

由图 1 可知 Tent 混沌映射相较随机数生成器生成的种群分布密度比较均匀, 映射效果极佳, 能达到较好的遍历性。Tent 映射用于初始化种群后, 还需要将混沌变量转化为设计变量, 该逆映射的表达式如下:

$$x_k^i = l_k^i + (u_k^i - l_k^i)z_k^i \quad (11)$$

其中: u_k^i 和 l_k^i 分别表示优化变量取值范围的最大值和最小值, x_k^i 和 z_k^i 分别为设计变量和混沌变量。

Tent 混沌映射初始化种群的主要步骤如下:

- 1) 利用随机数生成器在 $[0, 1]$ 的区间内随机产生初始序列 z_0 ($z_0^1, z_0^2, \dots, z_0^n$), $k=0, k=k+1$;
- 2) 按照式 (10) 进行迭代产生下一个序列 z_k , $k=k+1$;
- 3) 若达到最大迭代次数, 即 $k=n$ 时, 结束迭代, 产生混沌序列 z ;
- 4) 将混沌序列 z 按照式 (11) 以及各参数的上下界转化为设计变量序列, 即初始种群 x 。

3.2 非线性收敛因子

GWO 算法中, 收敛因子 α 随迭代次数增加线性递减, 无法对全局与局部搜索能力进行平衡^[23], 不利于算法的求解。本文采用一种新型非线性收敛因子对 GWO 算法进行改进, 该收敛因子函数表达式如式 (12) 所示:

$$\alpha = 2 - \frac{(2t^3)}{t_{\max}^3} \quad (12)$$

其中: t 为当前迭代次数, t_{\max} 为迭代次数。

改进后的非线性收敛因子与原线性收敛因子以及文献 [23] 中使用的三角函数收敛因子的对比如图 2 所示。三角函数收敛因子的表达式如式 (13) 所示:

$$m = 2 - 2 \left(\frac{\sin \frac{t}{t_{\max}}}{\sin 1} \right)^\mu \quad (13)$$

其中: t 为当前迭代次数, t_{\max} 为迭代次数, μ 为调节系数, 文献中取 $\mu=2.5$ 。




图 2 迭代总次数 50 次时收敛因子对比

改进的非线性收敛因子在三者中前期递减速度最慢, 有利于增强算法的全局探索能力, 能够发现较多潜在的全局最优点; 后期递减速度变快, 从而提高局部最优解的搜索能力, 这样有利于算法的收敛。因此, 采用非线性收敛因子能有效地平衡算法的全局和局部搜索能力。

3.3 模拟退火算法

模拟退火算法^[24]是由 Metropolis 等人在 1953 年提出的一种仿自然过程的算法, 其思想来源于固体退火原理, 其特点为在一定概率情况下保留劣质群体, 增加种群多样性, 在一定程度上提高了算法跳出局部最优的能力^[25]。模拟退火算法思想应用于 GWO 算法的原理是, 对 GWO 算法每次迭代的解 x 添加随机扰动, 产生新的可行解 x' , 再计算适应度, 并根据 Metropolis 准则决定是否接受新解, 若其适应度优于原解, 则直接接收新解; 若其适应度相较原解差, 则以一定概率接受新解, Metropolis 准则接受新解概率的数学公式如式 (14) 所示:

$$P = \begin{cases} 1, & f(x') < f(x) \\ e^{-(f(x')-f(x))/T}, & f(x') > f(x) \end{cases} \quad (14)$$

其中: 函数 $f(x)$ 为适应度计算函数, $f(x)$ 越小表

示解越优; T 表示本次迭代的温度, $T_{k+1} = cT_k$, C 为冷却因子。

模拟退火思想应用于 GWO 算法的主要步骤如下:

- 1) 在 GWO 算法由上一代种群 x_{k-1} 产生下一代种群 x_k 时, 对下一代种群的每个个体添加随机扰动生成种群 x'_k ;
- 2) 对 x'_k 和 x_k 的每个个体计算适应度并依据式 (14) 进行概率替换;
- 3) 利用替换后的种群 x_k 产生下一代种群并重复步骤 2)。

3.4 改进灰狼优化算法 (IGWO) 的实现过程

改进灰狼优化算法的具体实现步骤如下:

- 1) 设置算法参数。包括灰狼种群个体数, 最大迭代次数, 优化参数的上下界, 模拟退火的初始温度以及冷却因子;
- 2) 利用 Tent 混沌映射结合优化参数的上下界初始化灰狼群位置;
- 3) 计算各个灰狼个体的适应度并排序, 选择较好的个体组成初始群体, 并将适应度最佳的 3 个个体定义为 α , β , δ , 剩下的群体则为 ω , 形成初始群体;
- 4) 根据式 (7) ~ (9) 更新灰狼位置, 其中用于更新位置的收敛因子使用式 (12) 的改进非线性收敛因子, 计算适应度并排序, 得到下一代狼群位置;
- 5) 对这一代群体添加随机扰动, 产生新解, 降低温度;
- 6) 计算新解的适应度, 并以式 (13) 的概率替换原解;
- 7) 若达到最大迭代次数, 则输出最优适应度解, 若未达到, 则返回步骤 4)。

3.5 改进灰狼优化算法性能测试

3.5.1 算法参数及基准测试函数选择

为验证 IGWO 算法在参数优化方面的有效性, 将本文改进的 IGWO 算法与 GWO 算法以及使用三角函数收敛因子的灰狼优化算法 (以下简称 IGWO-tf 算法) 进行对比, 对不同的基准函数进行寻优, 种群规模均设定为 20, 最大迭代次数为 500 次。

采用不同的算法对已有文献中选择的共 4 个基准函数进行寻优, 基准函数 f_1 和 f_2 为单峰函数, f_3 和 f_4 为多峰函数, 各基准测试函数如表 1 所示。

表 1 基准函数

函数	维数	取值范围	全局最小值
$f_1 = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$f_2 = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
$f_3 = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
$f_4 = 20 + e - 20e^{-1/5 \sqrt{1/5 \sum_{i=1}^n x_i^2}} - e^{1/n \sum_{i=1}^n \cos(2\pi x_i)}$	30	$[-32, 32]$	0

3.5.2 测试结果分析

基于上述参数设置和基准函数选择，对各个算法分别单独运行 20 次，记录最优值、平均值以及标准差。最优值和平均值反映了算法的寻优能力和收敛精度，标准差则反映了算法的稳定性。仿真实验结果如表 2，在每个函数上 IGWO 算法相较 GWO 和 IGWO-tf 算法寻优的效果均有提升，在基准函数 f_1 上，IGWO 寻优的平均值相较 GWO 以及 IGWO-tf 算法分别提升了 11 和 5 个数量级，在基准函数 f_2 上，也分别提升了 4 和 2 个数量级，而在基准函数 f_3 ， f_4 两个多峰函数上 IGWO 算法能在迭代结束前达到理论最优值。同时，IGWO 算法在基准函数寻优中不仅最优值和平均值更加接近理论最优值，而且寻优的标准差也较低，表明 IGWO 算法的寻优能力和稳定性较强。

表 2 各算法的基准函数寻优结果对比

统计量	算法	f_1	f_2
最优值	GWO	$9.763\ 853\ 43 \times 10^{-24}$	$1.142\ 001\ 95 \times 10^{-5}$
	IGWO-tf	$1.087\ 335\ 35 \times 10^{-29}$	$3.157\ 543\ 46 \times 10^{-7}$
	IGWO	$3.616\ 047\ 58 \times 10^{-35}$	$5.507\ 340\ 69 \times 10^{-9}$
平均值	GWO	$1.703\ 594\ 15 \times 10^{-23}$	$2.146\ 257\ 10 \times 10^{-4}$
	IGWO-tf	$6.426\ 006\ 74 \times 10^{-29}$	$7.131\ 484\ 69 \times 10^{-6}$
	IGWO	$1.690\ 240\ 38 \times 10^{-34}$	$5.512\ 772\ 78 \times 10^{-8}$
标准差	GWO	$1.614\ 191\ 26 \times 10^{-23}$	$3.944\ 849\ 87 \times 10^{-4}$
	IGWO-tf	$1.815\ 759\ 46 \times 10^{-28}$	$2.092\ 766\ 20 \times 10^{-5}$
	IGWO	$2.563\ 748\ 91 \times 10^{-34}$	$7.332\ 710\ 51 \times 10^{-8}$
统计量	算法	f_3	f_3
最优值	GWO	$1.776\ 356\ 84 \times 10^{-15}$	0
	IGWO-tf	0	0
	IGWO	0	0
平均值	GWO	$8.526\ 512\ 84 \times 10^{-15}$	$1.476\ 251\ 69 \times 10^{-2}$
	IGWO-tf	$5.329\ 070\ 53 \times 10^{-15}$	$2.220\ 446\ 04 \times 10^{-17}$
	IGWO	0	0
标准差	GWO	$2.466\ 514\ 81 \times 10^{-14}$	$2.900\ 235\ 15 \times 10^{-2}$
	IGWO-tf	$2.190\ 039\ 80 \times 10^{-14}$	$9.930\ 136\ 57 \times 10^{-17}$
	IGWO	0	0

f_1 和 f_3 基准测试函数寻优迭代收敛曲线如图 3 和图 4 所示，横坐标表示迭代的次数，纵坐标表示当前迭代次数




图 3 f_1 迭代收敛曲线




图 4 f_3 迭代收敛曲线

下适应度的 Log 值。在单峰函数 f_1 的迭代曲线上，IGWO 算法的收敛速度在前期相较 GWO 算法和 IGWO-tf 算法较慢，有利于全局寻优，后期收敛速度加快，寻优精度得到提升；在多峰函数 f_3 迭代曲线上，IGWO 算法相较其他算法的寻优能力有明显提高，能迅速达到理论最优点，而其他算法容易陷入局部最优，说明算法跳出局部最优的能力较强。

Friedman 检验是一种利用秩的非参数检验方法，常用于检验多个整体分布是否存在显著差异，为检验 IGWO 算法与 GWO 和 IGWO-tf 算法是否有着显著性差异，对算法对基准函数寻优所得的平均值做 Friedman 统计检验，所得到的结果如表 3 所示，显著性水平为 0.018，且 IGWO 算法的秩均值最小，说明可以认为 IGWO 算法对比 GWO 和 IGWO-tf 算法有明显优势。

表 3 IGWO 算法和 GWO 算法的 Friedman 检验结果

算法	IGWO	IGWO-tf	GWO
平均秩	1.00	2.00	3.00

4 IGWO-SVR 模型的实现及仿真测试表现

4.1 IGWO-SVR 模型

SVR 模型需要优化的参数有正则化参数 C ，不灵敏损失参数 ϵ 以及核函数 $K(x_i, x)$ 的参数 g ，将训练集上训练的 SVR 模型在测试集上的 R^2 作为 IGWO 算法的适应度函数来优化参数 C ， ϵ 和 g ， R^2 的计算方式如式 (15) 所示：

$$R^2 = 1 - \frac{\sum_{i=1}^j (f_i - y_i)^2}{\sum_{i=1}^j (\bar{y} - y_i)^2} \quad (15)$$

其中： f_i 表示第 i 个样本的预测值， y_i 表示第 i 个样本的真实值， \bar{y} 表示样本的平均值， j 表示样本个数。

IGWO-SVR 模型的算法流程图如图 5 所示。

4.2 锂电池 SOH 仿真预测

本文的锂电池数据集来源于 NASA 公开的锂电池数据存储库，该电池数据集通过对锂电池进行连续的充放电实验获得，充放电实验由充电、放电和阻抗测试 3 个部分组成。充电过程首先对电池进行 1.5 A 恒定电流充电，并且

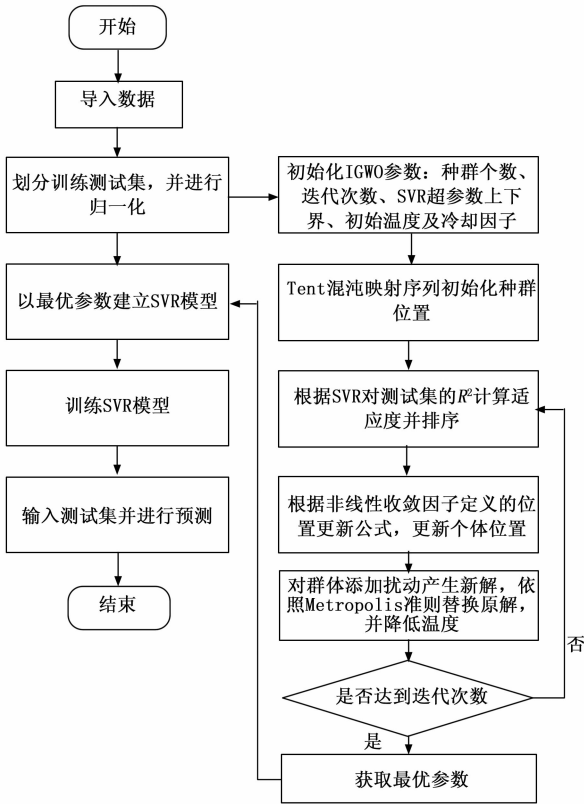


图 5 IGWO-SVR 算法流程图

充电过程中电池两端电压不断升高, 升高至 2.5 V 时, 改为恒定电压充电, 此过程中电池两端电流会开始下降, 下降至 20 mA 时结束充电过程, 在整个过程中, 以一定的时间间隔记录电池的电流、电压和温度等相关信息。放电过程则是以 2 A 的恒定电流放电至电压达到设定数值。阻抗测量过程即是使用电化学阻抗谱按设定频率扫描电池。本文将单次放电循环中的电池平均放电电压以及平均放电温度作为特征, 将电池的健康状态 (state of health, SOH) 作为预测值, SOH 的定义如式 (16):

$$SOH = \frac{C}{C_Q} \quad (16)$$

其中: C 为此次循环的电池容量, C_Q 为电池的标称容量。

选取数据集集中的 5 号电池数据集进行 SOH 预测, 通过将 IGWO-SVR 模型与遗传算法优化 SVR (GA-SVR)、粒子群算法优化 SVR (PSO-SVR) 以及灰狼优化算法优化 SVR (GWO-SVR) 进行对比, 仿真检验 IGWO-SVR 模型的性能。选取模型在测试集上的 R^2 、平均绝对百分比误差 MAPE 及均方根误差 RMSE 作为反映模型预测性能的指标, MAPE 和 RMSE 的计算公式分别为式 (17) 和式 (18):

$$MAPE = \frac{1}{j} \sum_{i=1}^j \left| \frac{f_i - y_i}{y_i} \right| \quad (17)$$

$$RMSE = \sqrt{\frac{1}{j} \sum_{i=1}^j (f_i - y_i)^2} \quad (18)$$

其中: f_i 表示第 i 个样本的预测值, y_i 表示第 i 个样本的真实值, j 表示样本个数。

4.3 仿真结果

各模型在锂电池数据集 SOH 预测中的结果如表 4 所示, 可得, 相比其他模型, IGWO-SVR 的 R^2 最大, MAPE 和 RMSE 最小, 表示其在 NASA 锂电池数据集上锂电池 SOH 仿真预测中的性能优于其他几种模型。

表 4 各模型在锂电池数据集 SOH 预测中的性能对比

模型	R^2	MAPE	RMSE
GWO-SVR	0.976 35	0.011 54	0.013 58
PSO-SVR	0.963 63	0.016 03	0.017 03
GA-SVR	0.943 16	0.020 87	0.021 29
IGWO-SVR	0.988 10	0.010 68	0.010 28

5 IGWO-SVR 预测车灯在不同温度及电压下电流实验

5.1 车灯电流预测实验

针对车灯在高温下由内置的微控制单元以及负温度系数热敏电阻作用下降低电流散热而导致工作中温度与电压对车灯电流的影响难以估计的问题, 建立能反映各个温度和电压条件下的特定车灯电流预测模型, 对 IGWO-SVR 模型的实际应用性进行评估。本次进行分析的数据来自于由某车灯企业对某款汽车远光灯进行实验提供, 实验中, 将车灯放入高低温试验箱, 用可变恒压电源进行多级电压供电, 使用热电偶测温仪测量温度、示波器测量电流。测试的温度分布于 25~105℃, 电压在 9~16 V, 共有 227 个样本, 模型训练前, 将 227 个样本按照 4:1 的比例分为训练集和测试集, 并对特征进行归一化预处理。而后, 将训练集样本导入训练模型进行训练, 并将训练获取的最优参数导入测试模型, 对测试集样本进行预测, 以验证模型的实际应用性, 实验环境如图 6 所示。



图 6 车灯电流测试实验

5.2 实验结果及分析

进行对比试验, 对比 IGWO-SVR 模型与 GA-SVR、PSO-SVR 以及 GWO-SVR 模型的预测性能。在模型训练后, 将模型在测试集上的 MAPE、RMSE 及实验测得的 10 组数据与预测值之间的平均相对误差 δ 作为模型的评价标

准。其中, 平均相对误差 δ 的计算公式如式 (18):

$$\delta = \frac{1}{j} \sum_{i=1}^j \frac{|f_i - y_i|}{y_i} \times 100\% \quad (18)$$

其中: f_i 表示第 i 个样本的预测值, y_i 表示第 i 个样本的真实值, j 表示样本个数。

对比实验的结果如表 5 所示, 可得, IGWO-SVR 模型对比其他模型, MAPE、RMSE 和 δ 均较低, 表现出更好的预测效果, 可以较为准确地预测车灯在不同温度及电压下的电流值。

表 5 各模型在车灯电流预测中的性能对比

模型	MAPE	RMSE	实测值平均相对误差 δ
GA-SVR	0.017 06	0.076 79	12.37%
PSO-SVR	0.009 35	0.059 76	4.73%
GWO-SVR	0.008 97	0.053 18	9.65%
IGWO-SVR	0.006 87	0.042 36	2.67%

6 结束语

本文针对支持向量回归精度不足的问题, 通过引入 Tent 映射初始化种群, 增加种群的多样性从而提升寻优速度; 使用非线性收敛因子改变算法前后期的收敛速度, 平衡算法的全局和局部搜索能力; 融合模拟退火算法的思想, 增加算法跳出局部最优的概率, 从 3 个方面改进了 GWO 算法, 将其用于对 SVR 超参数进行优化, 并提出 IGWO-SVR 预测模型。NASA 锂电池数据集上的仿真测试结果表明, IGWO-SVR 模型的预测性能较优, IGWO 算法对 SVR 的优化优于 PSO、GA 及 GWO 算法。使用 IGWO-SVR 模型对某车灯的电流值进行回归预测实验, 获得了较好的效果, 表明 IGWO-SVR 模型在实际工程问题中具有良好的应用价值。

参考文献:

- [1] 倪裕隆. 基于 SVR 的锂离子电池剩余有效寿命预测方法 [D]. 吉林: 东北电力大学, 2020.
- [2] CHERKASSKY V, MA Y. Practical selection of SVM parameters and noise estimation for SVM regression [J]. *Neural Networks*, 2004, 17 (1): 113-26.
- [3] MAO W, XU J, WANG C, et al. A fast and robust model selection algorithm for multi-input multi-output support vector machine [J]. *Neurocomputing*, 2014, 130 (apr. 23): 10-9.
- [4] BAO Y, LIU Z. A fast grid search method in support vector regression forecasting time series [C] // Berlin, Heidelberg: Springer, 2006: 504-511.
- [5] ZOU Y, HUANG Z, HU X, et al. Application of support vector regression algorithm optimized by gradient descent method for analysing efficiency of boiler [C] // Jinan, China: IEEE, 2017: 530-534.
- [6] CHAPELLE O, VAPNIK V, BOUSQUET O. Choosing Multiple Parameters for Support Vector Machines [J]. *Machine*

- learning*, 2002, 46 (1/3): 131-59.
- [7] 张琳, 汪廷华, 周慧颖. 基于群智能算法的 SVR 参数优化研究进展 [J]. *计算机工程与应用*, 2021, 57 (16): 50-64.
- [8] SUBASI A. Classification of EMG signals using PSO optimized SVM for diagnosis of neuromuscular disorders [J]. *Computers in Biology and Medicine*, 2013, 43: 576-86.
- [9] YUAN J, LOU H, BAO H, et al. A method for people counting using feature fusion based on SVR with PSO optimization [C] // Guangzhou, China: IEEE, 2017: 1443-1446.
- [10] LI Y, HE L, PENG B, et al. Remote sensing inversion of water quality parameters in longquan lake based on PSO-SVR algorithm [C] // Valencia, Spain: IEEE, 2018: 9268-9271.
- [11] 朱霄珣, 徐博超, 焦宏超, 等. 遗传算法对 SVR 风速预测模型的多参数优化 [J]. *电机与控制学报*, 2017, 21 (2): 70-5.
- [12] 陈颖, 张灿, 肖春艳, 等. 基于 GWO-SVR 的土壤镉元素含量含水率校正预测模型研究 [J]. *光学学报*, 2020, 40 (10): 180-7.
- [13] 张晓凤, 王秀英. 灰狼优化算法研究综述 [J]. *计算机科学*, 2019, 46 (3): 30-8.
- [14] 胡璇, 李春, 叶柯华, 等. 改进灰狼算法优化支持向量机在风力机齿轮箱故障诊断中的应用 [J]. *机械强度*, 2021, 43 (6): 1289-96.
- [15] 方晓玉, 李晓斌, 郭震. 一种改进的混合灰狼优化支持向量机预测算法及应用 [J]. *激光与光电子学进展*, 2020, 57 (12): 341-7.
- [16] 杨晓敏. 改进灰狼算法优化支持向量机的网络流量预测 [J]. *电子测量与仪器学报*, 2021, 35 (3): 211-7.
- [17] 宋彦坡, 彭小奇, 胡志坤. 支持向量回归机元参数优化方法 [J]. *系统工程与电子技术*, 2010 (10): 2238-42.
- [18] 张轩瑞. 基于 CEEMD 和 GWO-SVR 的铣削振动信号前瞻预测分析 [D]. 哈尔滨: 哈尔滨理工大学, 2021.
- [19] MIRJALILI S, MIRJALILI S M, LEWIS A. Grey Wolf Optimizer [J]. *Advances in Engineering Software*, 2014, 69 (3): 46-61.
- [20] 赵超, 王延峰, 林立. 基于改进灰狼算法优化核极限学习机的锂电池动力电池荷电状态估计 [J]. *信息与控制*, 2021, 50 (6): 731-9.
- [21] 王娟, 秦江涛. 混沌映射与 t -分布变异策略改进的海鸥优化算法 [J]. *计算机应用研究*, 2022, 39 (1): 170-6, 82.
- [22] 岳龙飞, 杨任农, 张一杰, 等. Tent 混沌和模拟退火改进的飞蛾扑火优化算法 [J]. *哈尔滨工业大学学报*, 2019, 51 (5): 146-54.
- [23] 张英芝, 朱继微, 刘津彤, 等. 改进灰狼算法优化灰色预测模型在数控机床中的应用 [J]. *制造技术与机床*, 2022 (3): 127-31.
- [24] DUPANLOUP I, SCHNEIDER S, EXCOFFIER L. A simulated annealing approach to define the genetic structure of populations [J]. *Molecular Ecology*, 2002, 11 (12): 2571-81.
- [25] 周鹏, 董朝轶, 陈晓艳, 等. 基于阶梯式 Tent 混沌和模拟退火的樽海鞘群算法 [J]. *电子学报*, 2021, 49 (9): 1724-35.