

基于多策略结合的灰狼优化算法及应用

秦宏伍^{1,2}, 王立铮^{1*}, 傅渝¹, 隋沐翮¹, 何秉高^{1,2}

(1. 长春大学电子信息工程学院, 吉林 长春 130000; 2. 吉林省人体健康状态辨识与机能增强重点实验室(长春大学), 吉林 长春 130022)

摘要: 标准灰狼优化(grey wolf optimizer, GWO)算法存在局部探索和全局开发难以平衡等问题。针对此类问题, 提出基于多策略结合的灰狼优化算法(multi-strategy grey wolf optimization, MSGWO)。首先, 灰狼算法引入非线性收敛因子和 Tent 映射; 然后, 利用广泛学习、精英学习和协调学习三种策略, 在 GWO 优化过程中协调工作; 最后, 利用轮盘赌进行策略选择, 以获得更具多样性灰狼位置和更具全局代表性的个体。通过标准基准函数测试, 采用算法变体进行对比。结果显示, MSGWO 算法拥有较好的全局搜索、局部开发的平衡能力以及更快的收敛速度。在此基础上, 利用 MSGWO 算法优化回声状态网络(echo state networks, ESN)超参数进行回归预测。实验表明平均绝对百分比误差为 0.38%, 拟合程度达到 0.98, 验证了 MSGWO 算法的优化性能。

关键词: 灰狼优化算法; 多策略; 轮盘赌; 收敛因子; 回声状态网络

中图分类号: TP301.6 **文献标志码:** A

引用格式: 秦宏伍, 王立铮, 傅渝, 等. 基于多策略结合的灰狼优化算法及应用[J]. 山东大学学报(理学版), 2024, 59(3): 51-60.

Grey wolf optimization algorithm based on multi-strategy combination and its application

QIN Hongwu^{1,2}, WANG Lizheng^{1*}, FU Yu¹, SUI Muxuan¹, HE Binggao^{1,2}

(1. College of Electronic Information Engineering, Changchun University, Changchun 130000, Jilin, China; 2. Jilin Provincial Key Laboratory of Human Health Status Identification and Function Enhancement (Changchun University), Changchun 130022, Jilin, China)

Abstract: The standard grey wolf optimizer (GWO) algorithm has issues such as difficulty balancing local exploration and global development. A multi-strategy grey wolf optimization algorithm (MSGWO), based on the fusion of various strategies, is presented to address such problems. First, the grey wolf algorithm introduces the Tent map and a nonlinear convergence factor. Then, to coordinate attempts in the GWO optimization process, the paper applies three learning strategies: extensive learning, elite learning, and coordinated learning. Finally, the paper uses roulette wheel for strategy selection to obtain more diverse wolf positions and globally representative individuals and utilizes benchmark function testing to compare algorithm variations. The outcomes demonstrate that the MSGWO algorithm has a faster convergence speed and a good balance between local development and global search. Based on this, the echo state networks (ESN) hyperparameter for regression prediction is optimized using the MSGWO method. The experiment demonstrates that the MSGWO algorithm performs optimally with an average absolute percentage error of 0.38 percent and a fitting degree of 0.98.

Key words: grey wolf optimizer; multiple strategies; roulette; convergence factor; echo state network

0 引言

在现代研究中, 研究人员通过分析自然界中某些群体动物的捕食、迁徙等群体活动, 受到启发所提出的

收稿日期: 2023-04-29; 网络出版时间: 2023-12-08 17:00:24

网络出版地址: <https://link.cnki.net/urlid/37.1389.N.20231207.1343.008>

基金项目: 吉林省科技厅资助项目(20210402081GH); 吉林省发改委资助项目(2023C042-4); 吉林省人社厅资助项目(2023RY17)

第一作者: 秦宏伍(1976—), 男, 教授, 博士生导师, 博士, 研究方向为信息测量与控制系统、深度学习与智能控制。

E-mail: qinhongwu@ccu.edu.cn

* 通信作者: 王立铮(1996—), 男, 硕士研究生, 研究方向为智能算法与机器学习。E-mail: wangliz0117@163.com

群体智能优化算法被广泛应用到各个领域。例如结构设计、经济调度、时序预测、最优潮流问题等,使群体智能优化算法在复杂工程技术问题^[1]上得到快速地发展。目前比较流行的群体智能算法有粒子群优化(PSO)算法^[2-3]、遗传(GA)算法^[4]、人工蜂群(ABC)算法^[5]、萤火虫(GSO)算法^[6]、蜻蜓(DA)算法^[7]、鲸鱼算法^[8]等。研究发展表明,群体智能算法在多种应用上表现出良好的收敛性和多样性,对于解决复杂工程问题具有较大的优势。

多策略结合思想应用到群体智能算法,可以有效提高算法性能。Gong 等^[9]提出一种改进的多策略自适应差分进化算法,表明该算法能够提供更高质量的解决方案、更快的收敛速度和更高的成功率。Xiong 等^[10]将生物地理学算法与多策略思想结合,提高开发和勘探方面的平衡能力和收敛性能。Wang 等^[11]利用多策略思想优化人工蜂群算法,改进人工蜂群算法在不同阶段的探索能力。Du 等^[12]采用动态优化的策略结合思想增强了粒子群算法的收敛能力,提高粒子群算法的搜索范围以及搜索能力,避免陷入局部最优的情况,同时在平衡开发能力和探索能力上可以更优秀。

研究人员将多策略思想应用到群体智能优化算法,用来提高算法性能。结合多策略思想后,群体智能算法往往具备更加优秀的精确度和稳定性。同时在平衡开发能力和探索能力上可以得到进一步优化^[13]。受上述思想启发,本文将多策略思想与灰狼优化算法结合,同时将轮盘赌的随机性应用到策略选择中,提出一种基于多策略结合的灰狼优化算法。

1 灰狼优化算法

灰狼作为顶级捕食者,拥有严密的等级关系。其强大的执行力和等级关系,使整个群体在捕猎过程中有条不紊。澳大利亚研究学者 Mirjalili 等^[14]于 2014 年从灰狼的狩猎过程中得到灵感,提出灰狼优化算法。

在标准 GWO 中,灰狼捕猎需要靠近猎物,然后进行围堵猎物,最后则是攻击猎物。灰狼会根据猎物移动自身位置靠近猎物。此时,由 α 狼、 β 狼、 δ 狼引导狼群移动,数学公式表示为

$$\begin{cases} D_{\alpha} = |C_1 \cdot X_{\alpha} - X|, \\ D_{\beta} = |C_2 \cdot X_{\beta} - X|, \\ D_{\delta} = |C_3 \cdot X_{\delta} - X|, \end{cases} \quad (1)$$

式中 D_{α} 、 D_{β} 、 D_{δ} 代表 α 狼、 β 狼、 δ 狼与 ω 狼之间的距离向量, ω 狼为当代灰狼; X 代表当代灰狼位置向量, C_1 、 C_2 、 C_3 代表随机向量,对应 α 狼、 β 狼、 δ 狼; X_{α} 、 X_{β} 、 X_{δ} 代表当代 α 狼、 β 狼、 δ 狼位置向量。

另外根据 α 狼、 β 狼、 δ 狼的当前位置与 ω 狼之间的位置向量,得到新的方向向量,数学公式表示为

$$\begin{cases} X_1 = X_{\alpha} - A_1 \cdot (D_{\alpha}), \\ X_2 = X_{\beta} - A_2 \cdot (D_{\beta}), \\ X_3 = X_{\delta} - A_3 \cdot (D_{\delta}), \end{cases} \quad (2)$$

式中 A_1 、 A_2 、 A_3 为系数向量, X_1 、 X_2 、 X_3 为 α 狼、 β 狼、 δ 狼与 ω 狼之间的方向向量。

同时, α 狼、 β 狼、 δ 狼预测猎物位置,下代灰狼则随机更新在猎物周围的位置。更新 ω 狼位置,数学公式表示为

$$X(t+1) = \frac{X_1 + X_2 + X_3}{3}, \quad (3)$$

式中 $X(t+1)$ 为下一代灰狼个体位置, t 为当前迭代次数。

A 、 C 分别表示为

$$A = 2a \cdot r_1 - a, \quad (4)$$

$$C = 2 \cdot r_2, \quad (5)$$

式中 a 是一个从 2 递减至 0 的收敛因子, r_1 、 r_2 是在 $[0, 1]$ 之间的两个随机向量; C 是一个 $0 \sim 2$ 的随机向量,能够有效提高当代灰狼位置的随机性,避免局部最优, C 值越大权重越大。收敛因子表示为

$$a = 2 \left(1 - \frac{t}{T} \right), \quad (6)$$

式中 T 为最大迭代次数。

2 多策略灰狼优化算法

灰狼优化算法其结构简单,应用更加方便,在智能算法中具备一定的竞争性。然而标准 GWO 算法具有更强的局部搜索性能,会导致局部探索和全局开发难以均衡,即灰狼算法搜索机制受 $|A|$ 影响,间接受到了 a 的影响,在线性收敛因子、搜索机制以及单一位置更新方式的影响下,导致此类问题出现。针对此类问题,本文提出基于多策略结合的灰狼优化算法。

2.1 非线性收敛因子

群体智能优化算法中,早期群体分布情况对算法本身的收敛速度和精确度影响很大。标准 GWO 算法采用随机初始化方式,使得初始种群分布不均,导致寻优速度降低。针对此类问题,本文利用 Tent 映射处理初始种群^[15],不仅可以避免佳点集初始化种群的规律性问题,而且可以提高种群随机性。

另外,标准 GWO 算法所采用的线性收敛因子也会导致种群多样性降低,影响算法精度和寻优能力。本文分别从收敛速度、收敛趋势、收敛前期以及后期等多个方面分析收敛因子对算法优化的影响。最后,引用非线性收敛因子,并改进初始化方式以改善群体的多样性,加强算法精度和寻优能力。其数学公式表示为

$$a = 2 - 2 \left(\frac{t}{T} \right)^{\frac{1}{2}}, \quad (7)$$

式中 a 是一个从 2 递减至 0 的收敛因子, T 为最大迭代次数, t 为当前迭代次数。

尽管基于不同方式的改进,可能促进了局部最优的避免。若仅仅从初始化种群以及收敛因子方面改进算法,但是位置更新策略依旧单一,对于群体智能算法的探索和开发之间的平衡性问题依然不能有效的解决。

2.2 互补协调策略

本文将多策略思想与灰狼优化算法结合,采用 3 个策略在不同的情况下对灰狼位置进行更新。同时将轮盘赌的随机性应用到策略选择中,提出多策略灰狼优化算法。并引用 SP 作为判断、选择不同策略的参数,即 $SP=1$ 时,选择策略 1。多策略灰狼优化算法可以从种群多样性、收敛因子、寻优方式等多个方面动态对算法进行优化,该方法能够有效地改善全局和局部搜索的均衡性。

策略 1,即 $SP=1$ 。标准 GWO 算法进行灰狼位置更新时,采用最优解的方式。此方式局部搜索能力较强是造成算法局部最优的重要原因,从而影响算法优化精度。本文借鉴广泛学习策略的思路后,在标准 GWO 算法的基础上,随机增加一匹灰狼 η ,使其参与灰狼的位置更新,可以增强全局搜索能力。使 MSGWO 算法在初期具备良好的全局搜索能力,提高算法寻优性能。其数学公式表示为

$$X(t+1) = \frac{X_1 + X_2 + X_3 + X_4}{4}, \quad (8)$$

式中 $X(t+1)$ 表示下一代灰狼位置; X_4 表示 η 与 ω 狼之间的方向向量, X_1 、 X_2 、 X_3 表示 α 狼、 β 狼、 δ 狼与 ω 狼之间的方向向量。

策略 2,即 $SP=2$ 。在加强全局搜索能力之后,策略 2 的战略重点放在 GWO 算法的局部探测上。精英学习策略具有局部搜索能力较强的特点,其精英思想可应用于此,用来提高算法性能。本文利用一个全新的精英灰狼位置 X_i ,使其与原始精英灰狼位置共同作为备选,并且将权重思想引入到算法之中。得出位置更新公式,由其计算得出下一代灰狼位置。其数学公式表示为

$$X(t+1) = \frac{(\omega_1 X_1 + \omega_2 X_2 + \omega_3 X_3 + \omega_4 X_i)}{4}, \quad (9)$$

$$X_i = \frac{X_1 + X_2 + X_3}{3}, \quad (10)$$

式中 ω_1 、 ω_2 、 ω_3 、 ω_4 数学公式表示为

$$\omega_j = \frac{|X_j|}{|X_1| + |X_2| + |X_3| + |X_i|}, \quad (11)$$

式中 $X(t+1)$ 表示下一代灰狼位置; $\omega_j (j=1, 2, 3, 4)$ 表示权重; $X_j (j=1, 2, 3, i)$ 表示方向向量, X_1 、 X_2 、 X_3 表示 α 狼、 β 狼、 δ 狼与 ω 狼之间的方向向量, X_i 表示全新精英灰狼方向向量。

策略 3,即 SP=3。全面优化算法,增强算法开发和探索的均衡配合,对上述两种策略进行补充。采用协调学习策略的方法增强并且平衡算法的局部和全局搜索能力。同时,也有效解决因为|A|值不同,产生的搜索区域不同造成的影响。首先,利用随机灰狼 η ,计算距离向量;然后,当|A|>1 时,利用公式(2)计算当代灰狼位置。当|A|<1 时,利用全新灰狼位置公式计算当代灰狼位置,增加灰狼位置随机性。最终根据位置更新公式计算下一代位置。全新灰狼位置公式、位置更新公式分别表示为

$$\begin{cases} X_a = \text{rand} \cdot (X_\alpha - A_1 \cdot (X_4)), \\ X_b = \text{rand} \cdot (X_\beta - A_2 \cdot (X_4)), \\ X_c = \text{rand} \cdot (X_\delta - A_3 \cdot (X_4)), \end{cases} \quad (12)$$

$$X(t+1) = \frac{X_a + X_b + X_c}{3}, \quad (13)$$

式中 $X(t+1)$ 为下一代灰狼位置; A_1, A_2, A_3 为系数向量; X_a, X_b, X_c 为 α 狼、 β 狼、 δ 狼与 η 狼之间的方向向量, X_4 表示 η 与 ω 狼之间的方向向量。

2.3 MSGWO 算法流程

多策略灰狼优化算法一般步骤:

- 1) 利用 Tent 映射在规定范围内进行狼群位置初始化。
- 2) 计算每一头狼的适应度值。
- 3) 将最好的三个值赋值给 α 狼、 β 狼、 δ 狼。
- 4) 更新 a, A, C 。
- 5) 利用轮盘赌的方式选择下一代灰狼位置更新方案。
- 6) 迭代次数是否大于阈值,否,则跳转到 2);是,则下一步。
- 7) 输出 $X(t+1)$ 。

多策略灰狼优化算法流程图 1。

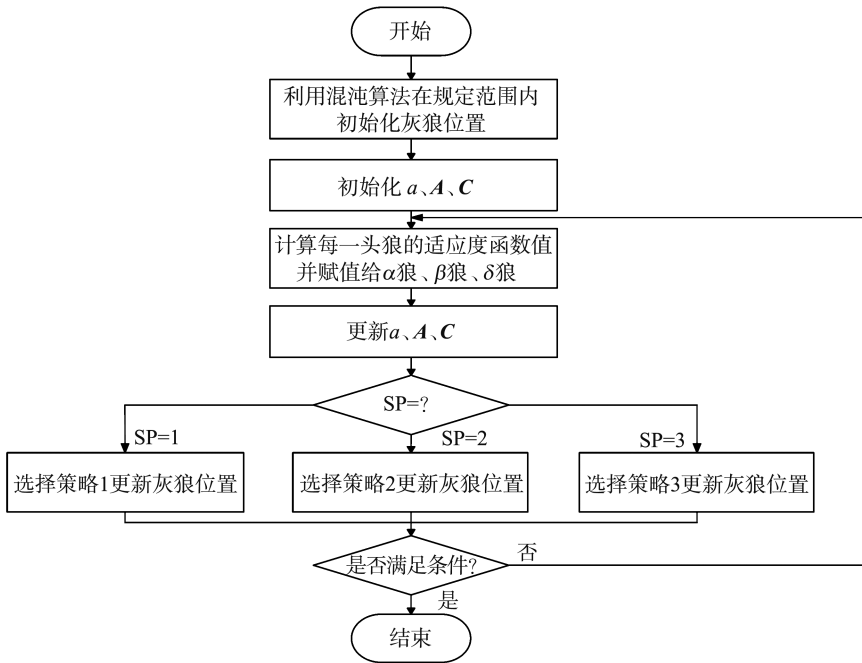


图 1 MSGWO 算法流程图
Fig.1 MSGWO algorithm flowchart

3 结果验证分析

灰狼优化算法结构简单、调节参数少,但是其优化理论仍然缺乏完善,改进空间巨大,可以从多方面进行算法改进^[16]。目前主要的改进方式包括:种群初始化、收敛因子、位置更新策略以及搜索策略。本文将多策

略思想与灰狼算法结合,提出 MSGWO 算法;为了检验 MSGWO 算法的提升效果,利用标准基准函数对多策略灰狼优化算法进行全面寻优测试。标准基准函数如表 1、2 所示,包括常用的 12 个标准基准函数。表 1 中 f_1 — f_7 是单峰标准基准函数,表 2 中 f_8 — f_{12} 属于多模态标准基准函数。利用标准函数从收敛速度、收敛精度等方面全面测试多策略灰狼优化算法的优化性能,为 MSGWO 算法的实际应用提供一定的指导作用。

表 1 单峰标准基准函数
Table 1 Unimodal standard reference function

表达式	维度	搜索区间	最优值
$f_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
$f_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
$f_4(x) = \max_i \{ x_i , 1 \leq i \leq n \}$	30	$[-100, 100]$	0
$f_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]$	0
$f_6(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30	$[-100, 100]$	0
$f_7(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1]$	30	$[-1.28, 1.28]$	0

表 2 多峰标准基准函数
Table 2 Multimodal standard reference function

表达式	维度	搜索区间	最优值
$f_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	-2 094.9
$f_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
$f_{10}(x) = -20 \exp\left(-0.2 \sqrt{1/n \sum_{i=1}^n x_i^2} - \exp\left(1/n \sum_{i=1}^n \cos(2\pi x_i)\right)\right) + 20 + e$	30	$[-32, 32]$	0
$f_{11}(x) = 1/4\ 000 \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(x_i / \sqrt{i}) + 1$	30	$[-600, 600]$	0
$f_{12}(x) = \pi/n \{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + \sin(\pi y_{i+1})] + (y_n - 1)^2 \}$ $+ \sum_{i=1}^n u(x_i, 10, 100, 4), y_i = 1 + \frac{x_i + 1}{4}$	30	$[-50, 50]$	0

此外,本文还对 MSGWO 算法进行了竞争力测试。利用标准灰狼优化算法、粒子群优化算法以及两种灰狼优化算法的变体与 MSGWO 算法进行对比实验,其中灰狼优化算法变体包括 MIGWO^[17]、MAGWO^[18]。为了达到验证目的,确保实验的公平性。实验进行 30 次独立测试,实验设置 500 次迭代,30 头灰狼进行全局搜索。取 30 次实验结果的平均值避免实验的随机性,确保实验结果真实有效。同时,取 30 次实验结果的标准差表示实验的稳定性,验证其实验结果浮动较小。实验结果对比如表 3、4 所示。

表 3 单峰函数实验数据对比
Table 3 Comparison of experimental data for unimodal functions

		GWO	MIGWO	MAGWO	PSO	MSGWO
f_1	平均值	7.50E-28	2.78E-36	2.22E+03	3.85E-04	0.00E+00
	标准差	1.46E-27	4.03E-36	9.25E+02	1.40E-03	0.00E+00
f_2	平均值	1.18E-16	8.47E-22	1.71E+01	3.93E-02	5.25E-219
	标准差	1.23E-16	1.15E-21	4.42E+00	4.76E-02	0.00E+00
f_3	平均值	2.63E-05	1.56E-06	4.42E+04	8.44E+01	0.00E+00
	标准差	9.73E-05	4.85E-06	9.28E+03	2.34E+01	0.00E+00
f_4	平均值	5.02E-07	2.32E-09	8.57E+01	1.10E+00	7.80E-291
	标准差	5.07E-07	3.34E-09	4.88E+00	2.05E-01	0.00E+00

续表

		GWO	MIGWO	MAGWO	PSO	MSGWO
f_5	平均值	2.71E+01	2.68E+01	2.47E+06	9.96E+01	2.79E+01
	标准差	6.72E-01	6.40E-01	1.58E+06	6.51E+01	7.37E-01
f_6	平均值	8.51E-01	6.86E-01	2.73E+03	1.48E-04	1.81E+00
	标准差	4.45E-01	3.55E-01	8.68E+02	1.38E-04	7.56E-01
f_7	平均值	2.00E-03	1.50E-03	1.33E+00	1.84E-01	5.30E-05
	标准差	1.10E-03	6.94E-04	6.06E-01	6.87E-02	6.84E-05

表 4 多峰函数实验数据对比

Table 4 Comparison of experimental data on multimodal functions

		GWO	MIGWO	MAGWO	PSO	MSGWO
f_8	平均值	-6.03E+03	-5.55E+03	-4.49E+03	-4.89E+03	-5.82E+03
	标准差	9.65E+02	1.23E+03	2.87E+02	1.28E+03	1.47E+03
f_9	平均值	2.74E+00	1.82E-01	2.44E+02	5.94E+01	0.00E+00
	标准差	3.49E+00	9.98E-01	3.42E+01	1.56E+01	0.00E+00
f_{10}	平均值	9.62E-14	2.29E-14	2.00E+01	2.76E-01	4.20E-15
	标准差	1.37E-14	4.70E-15	5.70E-03	5.55E-01	9.01E-16
f_{11}	平均值	7.65E-04	8.53E-04	2.73E+01	7.60E-03	0.00E+00
	标准差	2.90E-03	3.30E-03	1.42E+01	8.70E-03	0.00E+00
f_{12}	平均值	5.27E-02	3.59E-02	2.75E+06	1.04E-02	1.46E-01
	标准差	2.97E-02	1.52E-02	2.58E+06	4.17E-02	7.06E-02

由表 3、4 综合分析可知,MSGWO 在 f_1 、 f_2 、 f_3 、 f_4 、 f_7 、 f_9 、 f_{10} 、 f_{11} 函数上取得了最佳优化效果,所表现出的结果与实际情况更为接近。PSO 算法则在分别在 f_6 、 f_{12} 函数上取得了最佳。MIGWO 算法在函数 f_5 上取得了最佳。MAGWO 算法在函数 f_8 上取得了最佳。在所有函数中,标准 GWO 均未取得最佳效果。对比 MSGWO 算法在 f_5 、 f_6 、 f_8 、 f_{12} 函数上的表现,PSO 算法在函数 f_6 上略优于 MSGWO 算法,其它函数上 MSGWO 算法的表现则与其它 3 种算法相差甚少,仍然具备竞争能力。对整个实验对比结果分析,MSGWO 算法有着更明显的优化成绩。

实验过程中有意识地选取大量实验数据对其稳定性进行分析,对每次迭代后生成的最优值进行记录。可以明显发现 MSGWO 算法在所有函数上标准差最小,即 MSGWO 算法具有极佳的稳定性。同时,对 3 种策略进行了单独以及两两组合验证其优化性能,充分考虑多种情况,实验表明 MSGWO 算法最优。

算法收敛速度性能如图 2 所示,相比于其它标准算法以及算法变体,除 f_6 优化结果不佳外,MSGWO 在处理标准基准函数时明显拥有更快的收敛速度。多模态函数的收敛速度也要优于其它 3 种方法。综合分析,改进算法的搜索机制,初始化种群以及引入非线性收敛因子后,MSGWO 算法收敛速度、精确度、准确度以及平衡全局和局部搜索能力等方面具有更优异的表现。

4 实际应用分析

4.1 MSGWO-ESN 模型

回声状态网络是由 H. Jaeger 和 H. Ass 在 2004 年提出的一种新型递归神经网络。回声状态网络使用储备池来代替传统递归神经网络原有的隐含层,又称储备池计算(reservoir computing, RC)。其随机产生大规模稀疏连接的储备池,隐藏层权值矩阵,仅对输出层的权值矩阵进行训练。基本思想是生成的储备池具有某种良好的属性,往往能够保证仅采用线性方法训练储备池至输出层的权值即可获得优良的性能。恰恰是因为模型需要训练的参数较少,所以对其超参数的选择则至关重要,本文利用 MSGWO 算法针对其储备池个数、学习率以及正则化因子进行优化。首先,储备池个数即其中神经元的个数 N ,常规来讲 N 值越大,预测的精度越高,但同时也会导致效率低下,容易过拟合;然后,学习率是模型所依赖的最重要的超参数,模型学习速率的调整非常耗时。因此,为了获得成功的模型,必须找到合适的方法设置适合所有学员的学习率;最后,正则化因子是一种可以用来减轻过拟合现象的因素,它可以通过改变模型的参数,使得模型更加稳定,更能适应不同情况的数据。

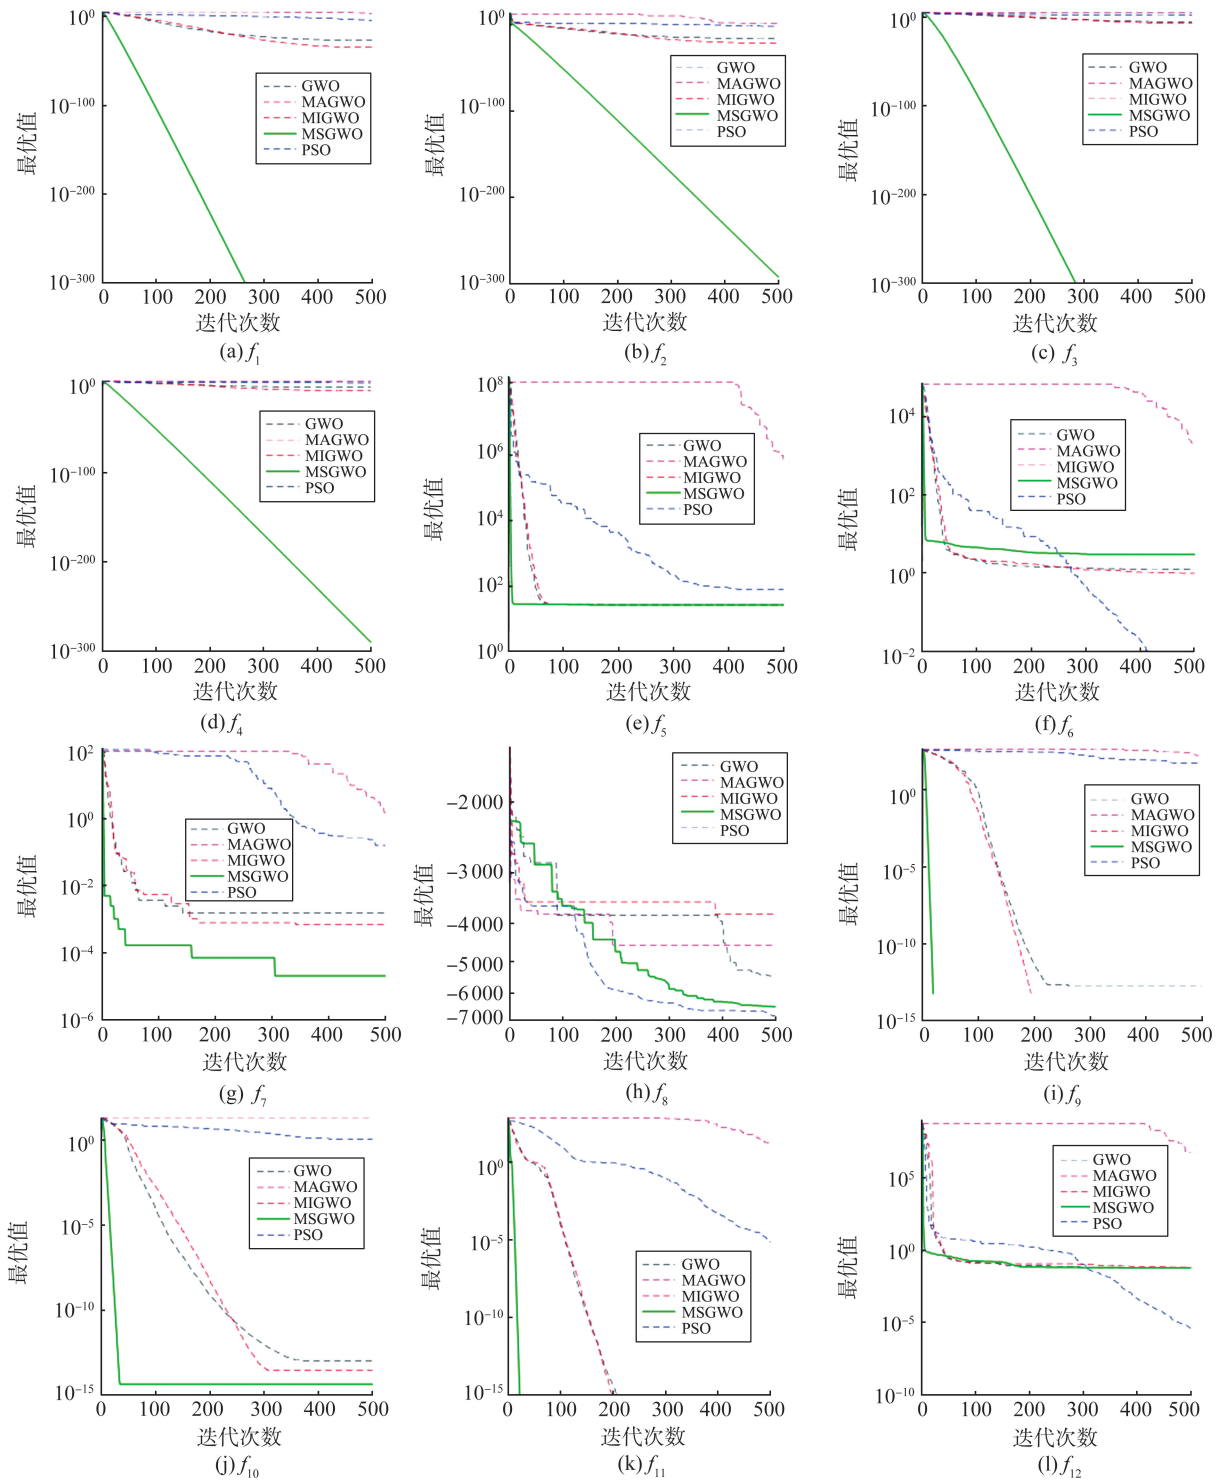


图2 函数 f_1 — f_{12} 曲线收敛图

Fig.2 Convergence diagram of function f_1 — f_{12} curve

MSGWO-ESN 预测模型基本步骤如下:

- 1) 规划数据集,划分训练集、测试集。
- 2) 利用 MSGWO 优化超参数,得出恰当的储备池神经元个数、学习率以及正则化因子。
- 3) 缩放矩阵,使得谱半径 <1 ,并且随机生成输入权值矩阵、储备池权值矩阵。
- 4) 样本数据一次输入输出,进行训练,确定输出权值矩阵。
- 5) 最终利用测试集进行测试模型效果并使用。

4.2 数据描述

为本文提供真实数据的联合循环电厂主要由燃气轮机、蒸汽轮机和余热锅炉等设备组成。本文所用数

据是从 UCI(University of California, Irvine)数据库网站下载实验所用的联合循环电厂输出功率数据。该数据集为每小时采集一次的真实数据,共由 9 568 个数据点组成。该电厂被设置为满负荷运行。为实现对发电量高精度地预测,必须选择接近最大负荷系数的运行数据,故该数据集符合模型测试的数据对象。数据集给出了环境温度(AT)、环境压力(RH)、相对湿度(RH)、排气真空(V)、电能输出(PE)的基本统计特征。

4.3 结果验证分析

为了确保实验环境的一致性,实验数据采用本文标准数据 500 次迭代、30 头灰狼进行全局搜索。ESN 模型对数据进行训练和预测,分别采用 9 568 组数据,选取 80% 作为训练数据,20% 作为预测数据。对比 ESN、LSTM、ELM、GWO-ESN、MAGWO-ESN 等模型,全面验证 MSGWO 对 ESN 的优化效果。最终选取平均绝对误差(MAE)、均方根误差(RMSEP)、平均绝对百分比误差(MAPE)以及决定系数(R^2)作为判定数据。均方误差(MSE)是预测值与实际值之差的平方的期望值,MSE 的值越小,说明预测模型具有更好的精确度,实验结果如表 5。

表 5 实验结果数据对比
Table 5 Comparison of experimental results and data

	MAE	MAPE	RMSEP	R^2
LSTM	3.700 4	0.008 1	4.708 6	0.945 05
ELM	3.262 7	0.007 2	4.181 9	0.938 56
ESN	3.532 7	0.007 8	4.452 1	0.930 25
GWO-ESN	1.967 1	0.004 3	2.506 8	0.977 88
MAGWO-ESN	1.986 2	0.004 4	2.524 6	0.977 57
MSGWO-ESN	1.725 1	0.003 8	2.198 8	0.982 99

由表 5 可知,6 种模型对测试数据均有较好的准确性,MAPE 皆低于 1%。但是对比标准 ESN 模型,MSGWO-ESN 算法得到的 MAE 提升 51.1%;MSGWO-ESN 算法得到的 RMSEP 提升 50.6%;MSGWO-ESN 算法得到的 MAPE 提升 51.2%。同时,MSGWO-ESN 模型在 MAE、MSE、MAPE 以及 R^2 上的表现也要优于其它模型。除 LSTM, R^2 皆在 0.9 以上,MSGWO-ESN 最优,达到 0.982 99。另外,本文进行了 GWO-ESN 对比 MSGWO-ESN 实验,在时间开销上,MSGWO-ESN 时间更短,效果更优。

最后取 100 组实验结果数据进行数据对比。如图 3、4 分别为预测结果对比图与预测结果误差图。结合误差图与对比图可以看出预测数据曲线与实际曲线基本吻合,且误差上下波动较小。综合分析实验图表,本研究提出的多策略灰狼算法优化的 ESN 预测模型与其它模型预测的结果相比,预测模型更加精确,预测结果更接近实际行走轨迹的总趋势,预测值与实际值的相对误差更小。综合来看,模型内部构造以及储备池神经元个数对模型预测精度具备一定的影响,同时模型的学习率以及正则化因子具备一定的修正误差的能力,可以增加模型的预测精度。




图 3 预测结果对比图

Fig.3 Comparison of prediction results




图4 预测结果误差图

Fig.4 Prediction result error chart

灰狼优化算法属于元启发式算法,对于类似问题,皆可采用元启发式算法进行优化求解。但是标准元启发式算法优化效果有限,收敛速度以及精度较差,优化效果低于本文提出的MSGWO算法。实验也表明MSGWO算法在此类问题上要优于其它智能算法。但是,在面对其它复杂工程问题时,还需要根据实际具体考证,进行优化和验证。

5 结论

本文在经典灰狼优化算法的基础上,结合多策略思想,提出多策略结合的灰狼优化算法(MSGWO)。此算法将3种策略结合应用于一体,增加了搜索过程中灰狼位置的多样性,并且使得每一头狼都具有相同的机率成为最优狼。该方法不仅增强了算法开发和探索的均衡配合,而且能有效提高算法的精度和收敛速度。

在MSGWO中,引用混沌映射、收敛因子、轮盘赌策略结合多策略思维形成多策略灰狼优化算法。将MSGWO算法与其它灰狼算法变体进行对比,MSGWO在精确度、收敛速度、稳定性上的优化效果明显。另外,将MSGWO应用到ESN网络进行回归预测,建立了MSGWO-ESN预测模型,对联合循环电厂输出功率进行有效预测。实验结果显示,MAPE值最优为0.38%, R^2 最高达到0.98,证明了MSGWO算法的优越性能和竞争力,表明多策略集成方法可以显著增强群体智能优化算法的性能。同时,也说明智能优化算法结合神经网络模型可有效提高时序预测的精确度。

参考文献:

- [1] SULTANA N, HOSSAIN S, ABUSAAD M, et al. Prediction of biodiesel production from microalgal oil using Bayesian optimization algorithm-based machine learning approaches[J]. Fuel, 2022, 309:122184.
- [2] ZHANG Yudong, WANG Shuihua, JI Genlin, et al. An MR brain images classifier system via particle swarm optimization and kernel support vector machine[J/OL]. The Scientific World Journal, 2013, 2013: 130134 [2022-10-10]. <https://doi.org/10.1155/2013/130134>.
- [3] 李真,王帆,王冉珺. 一种结合灰狼算法的粒子群优化算法[J]. 计算机测量与控制,2021,29(10):217-222.
LI Zhen, WANG Fan, WANG Ranjun. A particle swarm optimization algorithm combined with grey wolf algorithm[J]. Computer Measurement and Control, 2021, 29(10):217-222.
- [4] MORRIS G M, GOODSELL D S, HALLIDAY R S, et al. Automated docking using a Lamarckian genetic algorithm and an empirical binding free energy function[J]. Journal of Computational Chemistry, 2015, 19(14):1639-1662.
- [5] KRISHNANAND K N, GHOSE D. Glowworm swarm optimisation: a new method for optimising multi-modal functions[J].

International Journal of Computational I, 2009, 1(1):93-119.

- [6] GAO Weifeng, LIU Sanyang. A modified artificial bee colony algorithm[J]. Computers & Operations Research, 2012, 39(3):687-697.
- [7] MIRJALILI S. Dragonfly algorithm: a new metaheuristic optimization technique for solving single-objective, discrete, and multi-objective problems[J]. Neural Computing and Applications, 2016, 27(4):1053-1073.
- [8] ALJARAH I, FARIS H, MIRJALILI S. Optimizing connection weights in neural networks using the whale optimization algorithm[J]. Soft Computing, 2018, 22(1):1-15.
- [9] GONG Wenyin, CAI Zhihua. Parameter optimization of PEMFC model with improved multi-strategy adaptive differential evolution[J]. Engineering Applications of Artificial Intelligence, 2014, 27(1):28-40.
- [10] XIONG Guojiang, SHI Dongyuan, DUAN Xianzhong. Multi-strategy ensemble biogeography-based optimization for economic dispatch problems[J]. Applied Energy, 2013, 111(4):801-811.
- [11] WANG H, WU Z, RAHNAMEYAN S, et al. Multi-strategy ensemble artificial bee colony algorithm[J]. Information Sciences, 2014, 279(1):587-603.
- [12] DU Wenlin, LI Bin. Multi-strategy ensemble particle swarm optimization for dynamic optimization[J]. Information Sciences, 2008, 178(15):3096-3109.
- [13] LI M Q, XU L P, XU N, et al. SAR image segmentation based on improved grey wolf optimization algorithm and fuzzy c-means[J]. Mathematical Problems in Engineering, 2018, 2018(10):1-11.
- [14] MIRJALILI S, MIRJALILI S M, LEWIS A D. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(1):46-61.
- [15] 马晓宁,李笑含. 基于 Tent 混沌映射的可复制的鲸鱼算法[J]. 计算机仿真, 2022, 39(8):363-368.
MA Xiaoning, LI Xiaohan. A replicable whale algorithm based on tent chaotic mapping[J]. Computer Simulation, 2022, 39(8):363-368.
- [16] 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):30-38.
ZHANG Xiaofeng, WANG Xiuying. Review of grey wolf optimization algorithms[J]. Computer Science, 2019, 46(3):30-38.
- [17] MITTAL N, SINGH U, SOHI B S. Modified grey wolf optimizer for global engineering optimization[J/OL]. Applied Computational Intelligence and Soft Computing, 2016, 2016:7950348[2022-10-10]. <https://doi.org/10.1155/2016/7950348>.
- [18] MALIK M R S, MOHIDEEN E R, ALI L. Weighted distance grey wolf optimizer for global optimization problems[C]//2015 IEEE International Conference on Computational Intelligence and Computing Research (ICIC2015). Tirunelveli, India; Institute of Electrical and Electronics Engineers, 2015:1-6.

(编辑:甄鹏)