

# 基于自适应海鸥优化算法的电力系统优化调度问题

王春源

安徽电子信息职业技术学院机电工程学院, 安徽 蚌埠

收稿日期: 2026年5月4日; 录用日期: 2026年5月26日; 发布日期: 2026年6月5日

## 摘要

电力系统优化调度是保障电力系统安全、经济、稳定运行的核心环节, 其本质是一类多约束、非线性、多极值的复杂组合优化问题。传统优化算法易出现收敛速度慢、早熟收敛、寻优精度不足等缺陷, 难以满足调度需求。针对上述问题, 文章提出了基于自适应海鸥优化算法(Adaptive Seagull Optimization Algorithm, ASOA), 用于求解电力系统优化调度问题。首先, 在原始海鸥优化算法(Seagull Optimization Algorithm, SOA)的基础上, 引入自适应权重因子, 通过非线性动态调节搜索步长, 平衡算法的全局探索与局部开发能力; 其次, 构造融合种群平均位置与全局最优个体的迁移算子, 替代原始单一最优引导机制, 维持种群多样性, 有效抑制早熟收敛。将改进算法应用于求解电力系统优化调度问题, 验证了该算法的有效性。

## 关键词

电力系统, 海鸥优化算法, 自适应, 迁移算子

# Optimization Scheduling of Power Systems Based on Adaptive Seagull Optimization Algorithm

Chunyuan Wang

School of Mechanical and Electrical Engineering, Anhui Vocational College of Electronics & Information Technology, Bengbu Anhui

Received: May 4, 2026; accepted: May 26, 2026; published: June 5, 2026

## Abstract

The optimization scheduling of power systems is a core aspect of ensuring the safe, economical, and

stable operation of power systems. It essentially represents a complex combinatorial optimization problem characterized by multiple constraints, nonlinearity, and multiple extrema. Traditional optimization algorithms often suffer from drawbacks such as slow convergence speed, premature convergence, and insufficient optimization accuracy, making it challenging to meet scheduling requirements. To address these issues, this paper proposes an Adaptive Seagull Optimization Algorithm (ASOA) for solving the optimization scheduling problem in power systems. First, an adaptive weight factor is introduced based on the original Seagull Optimization Algorithm (SOA) to dynamically adjust the search step size nonlinearly, thereby balancing the global exploration and local exploitation capabilities of the algorithm. Second, a migration operator that integrates the average position of the population with the global optimal individual is constructed to replace the original single optimal guidance mechanism, maintaining population diversity and effectively suppressing premature convergence. The improved algorithm is applied to solve the optimization scheduling problem in power systems, demonstrating its effectiveness.

## Keywords

Power System, Seagull Optimization Algorithm, Adaptive, Migration Operator

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着我国电力工业的快速发展和新能源机组(风电、光伏等)的大规模并网,电力系统的结构日益复杂,调度场景呈现出多源、多约束、非线性的特点,对电力系统优化调度的科学性和高效性提出了更高要求。电力系统优化调度的核心目标是在满足系统功率平衡、机组出力上下限、网损约束等前提下,合理分配各发电机组的出力,最小化系统运行成本、降低能耗,同时保障电力供应的安全性和稳定性,其求解质量直接影响电力系统的运行效益和可靠性[1]。

目前,求解电力系统优化调度问题的算法主要分为传统优化算法和智能优化算法两大类。传统优化算法如线性规划、动态规划等,虽具有原理简单、计算严谨的优势,但在处理高维、非线性、多极值的复杂调度问题时,易陷入局部最优解,且收敛速度慢,难以适配复杂电力系统的调度需求[2]。近年来,智能优化算法凭借其全局搜索能力强、不依赖问题模型特性、鲁棒性好等优点,被广泛应用于电力系统优化调度领域。梁静[3]等针对电力系统经济调度问题,提出了一种改进的粒子群优化算法,通过广义反向学习策略加快收敛速度,并借鉴差分进化算法增强种群多样性。杨德友[4]等提出利用飞蛾算法解决电力系统经济调度问题,该算法利用飞蛾扑火原理对设定目标进行螺旋式搜索,并在目标位置进行重复检索。

海鸥优化算法(Seagull Optimization Algorithm, SOA)是一种新型智能优化算法[5],由 Gaurav Dhiman 于 2019 年提出,其灵感来源于海鸥在自然界中的迁徙和觅食行为,具有结构简单、参数少、易实现等特点,在各类优化问题中展现出良好的应用潜力。然而,原始 SOA 在求解电力系统优化调度这类复杂问题时,仍存在明显缺陷:一方面,算法无权重控制,迁徙步长仅由线性收敛因子单一调节,导致全局探索与局部开发能力失衡,前期搜索范围不足、后期挖掘精度不够,收敛速度较慢;另一方面,算法仅依赖全局最优个体进行单一引导,所有个体过度追随最优解,易导致种群多样性下降,出现早熟收敛现象,难以跳出局部最优,影响调度方案的最优性。针对原始 SOA 的不足,本文提出了一种自适应海鸥优化算法(Adaptive Seagull Optimization Algorithm, ASOA)。通过引入自适应权重因子动态调节搜索步长,平衡算

法的全局探索与局部开发能力；其次，构造融合种群平均位置与全局最优个体的迁移算子，替代原始单一最优引导机制，维持种群多样性，有效抑制早熟收敛。

## 2. 自适应海鸥算法

### 2.1. 自适应权重因子改进

原始 SOA 的迁徙步长仅由线性收敛因子  $A$  单一控制，未引入权重调节机制，导致算法在迭代过程中全局探索与局部开发能力失衡，难以适配电力系统优化调度的复杂需求。为解决上述问题，本文引入自适应权重因子  $w$ ，通过非线性动态变化调节迁徙步长，实现算法在不同迭代阶段全局探索与局部开发能力的动态平衡，适配电力系统优化调度的多约束、多极值特性。其具体计算公式为：

$$w = w_{\max} - (w_{\max} - w_{\min}) \cdot (t/T_{\max})^{\mu} \quad (1)$$

其中， $w_{\max}$  为最大权重， $w_{\min}$  为最小权重， $\mu$  为非线性调节系数， $t$  为迭代次数， $T_{\max}$  为最大迭代次数。经过多次调试，本文取值为： $w_{\max} = 0.9$ ， $w_{\min} = 0.2$ ， $\mu = 2$ 。

将自适应权重因子融入原始 SOA 的迁徙步长公式，改进后的迁徙步长公式为：

$$M(t) = w \cdot A \cdot D_s \quad (2)$$

其中， $D_s$  表示海鸥个体与全局最优个体的距离， $M(t)$  表示海鸥的迁徙步长。改进后，迁徙步长由自适应权重  $w$  和收敛因子  $A$  共同控制，实现了不同迭代阶段搜索力度的动态调节，有效解决了原始算法探索与开发失衡的问题。

### 2.2. 迁移算子改进

原始算法未考虑种群整体分布信息，个体搜索方向单一，进一步加剧了早熟收敛的风险。为解决原始算法单一引导导致的早熟收敛问题，本文优化迁移算子，引入种群平均位置信息，构造融合全局最优个体与种群平均位置的双重引导迁移算子，丰富种群搜索方向，维持种群多样性，确保算法能够跳出局部最优。具体如下：

首先，计算种群平均位置  $X(t)$  反映种群的整体分布特征，计算公式为：

$$X_{\text{avg}}(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (3)$$

其中， $N$  为种群规模， $X(t)$  为第  $i$  只海鸥的位置向量。

其次，构造迁移复合引导向量  $L(t)$ ，融合全局最优个体  $C(t)$  和种群平均位置  $X(t)$  的双重信息，计算公式为：

$$L(t) = \alpha \cdot C(t) + (1 - \alpha) \cdot X_{\text{avg}}(t) \quad (4)$$

其中， $\alpha$  为平衡系数，用于调节全局最优个体与种群平均位置的引导权重，本文取值为： $\alpha = 0.8$ 。

最后，改写距离项和位置更新公式，用迁移复合引导向量  $L(t)$  替代原始的全局最优个体  $C(t)$ ，改进后的距离项和位置更新公式分别为：

$$D_L = |L(t) - X(t)| \quad (5)$$

$$M_L(t) = w \cdot A \cdot D_L \quad (6)$$

$$X(t+1) = L(t) + M_L(t) \cdot S(t) \quad (7)$$

其中， $D_L$  为海鸥个体与迁移复合引导向量的距离， $M_L(t)$  为改进后的迁徙步长，融合了自适应权重和迁

移算子的双重优化。 $S(t)$  表示海鸥的螺旋飞行轨迹， $X(t+1)$  表示海鸥下一次迭代的位置。

### 3. 案例分析

#### 3.1. 电力系统调度数学模型

电力系统调度核心目标是在满足所有机组及系统的等式和不等式约束的前提下，最小化发电燃料成本，相应的目标函数和约束条件如下。

目标函数：

$$F_i(P_i) = a_i + b_i P_i + c_i P_i^2 \quad (8)$$

$$F_t = \sum_{i=1}^n F_i(P_i) \quad (9)$$

其中，每个机组单元的燃料成本表示为  $F_i(P_i)$ ，而  $n$  组机组的总燃料成本  $F_t$ ， $F_i$  是第  $i$  组机组单元的燃料成本， $a_i$ 、 $b_i$ 、 $c_i$  对应的是第  $i$  组单元的燃料成本系数， $P_i$  是第  $i$  组发电机产生的电能， $n$  是发电机组的总个数。

约束条件：

$$\sum_{i=1}^n P_i = P_{load} + P_{loss} \quad (10)$$

$$P_{loss} = \sum_{i=1}^n \sum_{j=1}^n P_i B_{ij} P_j \quad (11)$$

$$P_{i,\min} \leq P_i \leq P_{i,\max} \quad (12)$$

$$\begin{cases} P_i - P_i^0 \leq UR_i \\ P_i^0 - P_i \leq DR_i \end{cases} \quad (13)$$

其中， $P_{load}$  是整个系统的负载， $P_{loss}$  是线上的传输损失，用  $B$  系数法计算，其中  $P_{i,\min}$ 、 $P_{i,\max}$  ( $i=1, 2, \dots, n$ ) 分别为第  $i$  组发电机组的上下限， $UR_i$  与  $DR_i$  分别是上坡速率限制值与下坡速率。

#### 3.2. 结果分析

将自适应海鸥优化算法应用于一个包含 6 个发电机组的测试系统，该系统的负载为 1263 MW，并考虑了传输损失和禁行区间等约束条件。该测试系统的所有数据来源于文献[6]和文献[7]，机组参数则参考文献[8]。

将改进算法独立运行 50 次以获取平均值，并与 SOA、PSO [9]、BLPSO [10]、M-ABC [11]，以及 ATMES [12] 各自独立运行 50 次的平均值进行比较。所有算法的参数均采用相关文献中的推荐值，最大评估次数设定为 2000。表 1 展示了各算法的平均结果，结果表明 ASOA 的平均燃料成本低于其他对比算法。

Table 1. Fuel cost results of each algorithm

表 1. 各算法燃料成本结果

| 算法          | PSO    | SOA    | M-ABC  | ATMES  | BLPSO  | ASOA   |
|-------------|--------|--------|--------|--------|--------|--------|
| 燃料成本/(\$/h) | 15,794 | 15,532 | 15,488 | 15,492 | 15,494 | 15,292 |




Figure 1. Convergence curves of ASOA and the comparison algorithm

图 1. ASOA 与对比算法的收敛曲线

图 1 显示了 ASOA 与对比算法对实际案例求解的收敛曲线对比。可以看出，与多数对比算法相比，ASOA 找到较优可行解所经历的评估次数较少，收敛速度较快。在最终的收敛精度方面，ASOA 同样也表现出优秀的性能。本文提出的 ASOA 之所以表现优异，核心在于通过引入自适应权重因子，非线性动态调节搜索步长，有效平衡了算法的全局探索与局部开发能力，加快了收敛速度并提升了寻优精度；同时通过优化迁移算子，融合种群平均位置与全局最优个体的双重信息，替代原始单一引导机制，维持了种群多样性，有效抑制了早熟收敛现象，适配电力系统优化调度的多约束、多极值复杂特性。

#### 4. 结论

本文针对原始海鸥优化算法在电力系统优化调度中存在的收敛慢、易早熟收敛等缺陷，提出引入自适应权重因子和优化迁移算子的改进算法。通过自适应权重因子动态平衡算法全局探索与局部开发能力，借助融合种群平均与全局最优的迁移算子维持种群多样性，有效抑制早熟收敛。实例验证表明，改进算法相较于传统优化算法，在寻优精度、收敛速度和稳定性上均有显著提升，可高效求解电力系统优化调度问题，为电力系统经济、安全运行提供可靠技术支撑，同时也为同类复杂优化问题提供了参考思路。

#### 基金项目

安徽电子信息职业学院校级科研项目(2025KYZK014)。

#### 参考文献

- [1] 杨银国, 谢平平, 刘洋, 等. 基于深度优化算法的风光储多能互补电力系统优化调度策略[J]. 电网与清洁能源, 2025, 41(7): 122-131.
- [2] 郭智薇, 陈胜. 基于企业发展粒子群算法的微电网优化调度[J]. 四川文理学院学报, 2025, 35(5): 127-136.
- [3] 梁静, 葛士磊, 瞿博阳, 等. 求解电力系统经济调度问题的改进粒子群优化算法[J]. 控制与决策, 2020, 35(8):

- 1813-1822.
- [4] 杨德友, 刘世宇. 求解电力系统多目标环境经济调度的帕累托最优 MFO 算法[J]. 电工电能新技术, 2018, 37(2): 30-37.
- [5] Dhiman, G. and Kumar, V. (2019) Seagull Optimization Algorithm: Theory and Its Applications for Large-Scale Industrial Engineering Problems. *Knowledge-Based Systems*, **165**, 169-196. <https://doi.org/10.1016/j.knosys.2018.11.024>
- [6] Mohammadi-Ivatloo, B., Rabiee, A., Soroudi, A. and Ehsan, M. (2012) Iteration PSO with Time Varying Acceleration Coefficients for Solving Non-Convex Economic Dispatch Problems. *International Journal of Electrical Power & Energy Systems*, **42**, 508-516. <https://doi.org/10.1016/j.ijepes.2012.04.060>
- [7] Saber, A.Y. (2012) Economic Dispatch Using Particle Swarm Optimization with Bacterial Foraging Effect. *International Journal of Electrical Power & Energy Systems*, **34**, 38-46. <https://doi.org/10.1016/j.ijepes.2011.09.003>
- [8] Cai, J., Ma, X., Li, L., et al. (2007) Chaotic Particle Swarm Optimization for Economic Dispatch Considering the Generator Constraints. *Energy Conversion and Management*, **48**, 645-653. <https://doi.org/10.1016/j.enconman.2006.05.020>
- [9] Kennedy, J. and Eberhart, R. (1995) Particle Swarm Optimization. *Proceedings of ICNN'95 International Conference on Neural Networks*, Perth, 27 November-1 December 1995, 1942-1948. <https://doi.org/10.1109/icnn.1995.488968>
- [10] Chen, X., Tianfield, H., Mei, C., Du, W. and Liu, G. (2016) Biogeography-Based Learning Particle Swarm Optimization. *Soft Computing*, **21**, 7519-7541. <https://doi.org/10.1007/s00500-016-2307-7>
- [11] Mezura-Montes, E. and Cetina-Domínguez, O. (2012) Empirical Analysis of a Modified Artificial Bee Colony for Constrained Numerical Optimization. *Applied Mathematics and Computation*, **218**, 10943-10973. <https://doi.org/10.1016/j.amc.2012.04.057>
- [12] Wang, Y., Cai, Z.X., Zhou, Y., et al. (2008) An Adaptive Tradeoff Model for Constrained Evolutionary Optimization. *IEEE Transactions on Evolutionary Computation*, **12**, 80-92. <https://doi.org/10.1109/tevc.2007.902851>