

融合多策略增强 GWO 的永磁同步电机多参数辨识研究

姜智军, 蔡京城, 任田良, 张家喻, 薛文嘉

(中车时代电动汽车股份有限公司, 湖南 株洲 412007)

摘要:针对永磁同步电机参数辨识中存在的多变量耦合、非线性强、传统方法精度不足的问题, 本文提出一种多策略改进灰狼优化算法。该算法采用混合种群初始化策略提升初始解多样性, 运用动态领导狼机制强化全局搜索, 引入速度方向感知策略动态优化狼群移动轨迹, 并融合个体历史最优与全局历史最优双重引导策略, 以增强全局寻优能力。仿真结果表明, 相比传统灰狼优化算法, 本文所提策略可有效提升算法的参数辨识精度。

关键词:永磁同步电机; 在线参数辨识; 电机控制; 灰狼优化算法

中图分类号: TM341; TP273 **文献标志码:** A **DOI:** 10.15917/j.cnki.1006-3331.2026.03.004

A Study on Multi-parameter Identification of Permanent Magnet Synchronous Motor Based on Multi-strategy Enhanced GWO

LOU Zhijun, CAI Jingcheng, REN Tianliang, ZHANG Jiayu, XUE Wenjia

(CRRC Electric Vehicle Co., Ltd., Zhuzhou 412007, China)

Abstract: To address the problems of multivariate coupling, strong nonlinearity, and insufficient accuracy of traditional methods in Permanent Magnet Synchronous Motor parameter identification, this paper proposes a Multi-Strategy Improved Grey Wolf Optimizer. The algorithm adopts a hybrid population initialization strategy to enhance the diversity of initial solutions. It employs a dynamic leader-wolf mechanism to strengthen global search and introduces a speed-direction-aware strategy to dynamically optimize the wolf pack's movement trajectory. It incorporates a dual guidance strategy that integrates individual historical optima and the global historical optimum to enhance global optimization ability. The simulation results show that compared with the traditional Grey Wolf Optimizer, the proposed strategy can significantly improve the parameter identification accuracy of the permanent magnet synchronous motor.

Key words: Permanent Magnet Synchronous Motor; online parameter identification; motor control; Grey Wolf Optimizer

获得准确可靠的电机参数是伺服系统优化控制、状态监测和稳定运行的关键^[1]。永磁同步电机(Permanent Magnet Synchronous Motor, PMSM)参数辨识的对象主要包括电气参数和机械参数^[2], 本文聚焦于电气参数, 即定子电阻、直轴(d轴)电感、交轴(q轴)电感及永磁体磁链。在线辨识方法能够真实跟踪参数变化^[3], 但其中传统方法(如递推最小二乘法^[4]、扩展卡尔曼滤波^[5])对非线性时变系统和噪声干扰较为敏感, 辨识精度与收敛性受限。

启发式算法^[6-7]无需模型线性化、全局搜索能力强, 已逐步被引入参数辨识领域。现有灰狼优化算法(Grey Wolf Optimizer, GWO)在参数辨识任务中存在辨识精度不高、算法收敛性差、局部精细搜索能力弱等问题。为此, 本文提出一种多策略改进灰狼优化算法(Multi-Strategy Improved Grey Wolf Optimizer, MSI-GWO), 并使用多策略速度辅助灰狼优化器(Multi-Strategy Velocity-Aided Grey Wolf Optimizer, MS-VAGWO)对PMSM电气参数进行在线辨识。所提算

收稿日期: 2025-08-19。

第一作者: 姜智军(1999—), 男, 助理工程师, 主要从事新能源商用车整车低压设计及电气控制等设计研发相关工作。E-mail: louzhijun.cy@crrec.cc。

法通过混合种群初始化、动态领导狼机制及双重引导与自适应变异策略,提升初始解质量与种群多样性,增强局部收敛能力,从而获得更准确的辨识结果。仿真与实验验证了该方法的有效性。

1 PMSM 电气参数辨识模型

PMSM 在同步旋转 d-q 坐标系下的数学方程如式(1)所示^[8]。

$$\begin{cases} u_d = R_s i_d + L_d \frac{di_d}{dt} - \omega_e \psi_q \\ u_q = R_s i_q + L_q \frac{di_q}{dt} - \omega_e \psi_d \end{cases} \quad (1)$$

式中: u_d 和 u_q 分别为 d 轴和 q 轴的定子电压分量; i_d 和 i_q 分别为 d 轴和 q 轴的定子电流分量; di_d/dt 和 di_q/dt 为电流随时间的变化率; R_s 为定子电阻; L_d 和 L_q 分别为 d 轴和 q 轴的电感; ψ_d 和 ψ_q 分别为 d 轴和 q 轴的磁链分量; ω_e 为转子电角速度。

PMSM 的磁路方程、电磁转矩 T_e 的方程和运动方程如式(2)~(4)所示。

$$\begin{cases} \psi_d = L_d i_d + \psi_f \\ \psi_q = L_q i_q \end{cases} \quad (2)$$

$$T_e = \frac{3}{2} n_p [(L_d - L_q) i_d i_q + i_q \psi_f] \quad (3)$$

$$J \cdot \frac{d\omega_m}{dt} = T_e - B \cdot \omega_m - T_L \quad (4)$$

式中: ψ_f 为转子永磁体磁链; n_p 为电机极对数; J 为转动惯量; ω_m 为转子机械角速度($\omega_m = \omega_e/n$); B 为黏性摩擦系数; T_L 为负载转矩。

PMSM 稳定运行时,近似认为 $di_d/dt = 0$, $di_q/dt = 0$ 。采用 $i_d = 0$ 的控制策略,d-q 轴稳态离散电压方程如式(5)所示。

$$\begin{cases} u_{d0}(k) = -\omega_{e0}(k) \dot{L}_q i_{q0}(k) \\ u_{q0}(k) = \dot{R}_s i_{q0}(k) + \omega_{e0}(k) \dot{\psi}_f \end{cases} \quad (5)$$

式中: $u_{d0}(k)$ 和 $u_{q0}(k)$ 为 $i_d = 0$ 时 d 轴和 q 轴的定子电压测量值; $i_{q0}(k)$ 为 $i_d = 0$ 时的定子电流测量值; $\omega_{e0}(k)$ 为 $i_d = 0$ 时的转速; $\dot{R}_s$ 、 $\dot{L}_q$ 和 $\dot{\psi}_f$ 为待辨识参数估计值。

在智能辨识方法中,常采用向 d 轴注入负向弱磁电流的策略^[9]。实施注入操作时,对应的数据采样时序如图 1 所示。每个采样周期内,以 100 ms 为间隔

采集数据,可根据需要调整采集时长。




图 1 参数辨识数据采样时序图

注入负向 d 轴电流后形成的增秩方程组如式(6)所示。

$$\begin{cases} u_{d1}(k) = \dot{R}_s i_{d1}(k) - \dot{L}_q i_{q1}(k) \omega_{e1}(k) \\ u_{q1}(k) = \dot{R}_s i_{q1}(k) - \dot{L}_d i_{d1}(k) \omega_{e1}(k) + \omega_{e1}(k) \dot{\psi}_f \end{cases} \quad (6)$$

式中: $i_{d1}(k)$ 和 $i_{q1}(k)$ 分别为 $i_d \neq 0$ 时 d 轴和 q 轴的电机电流测量值; $u_{d1}(k)$ 和 $u_{q1}(k)$ 分别为 $i_d \neq 0$ 时 d 轴和 q 轴的电压; $\omega_{e1}(k)$ 为 $i_d \neq 0$ 时的转速测量值。

如图 1 所示,在一个采样周期内,分别在两种运行状态($i_d = 0$ 和注入负向 d 轴电流)下采集相同数量的样本数据。采集时长可根据实际需求调整。将该周期内采集的全部数据发送至上位机系统,再由上位机传递给智能算法模块,即可完成一次参数辨识。由此构建的满秩参数辨识模型如式(7)所示。

$$\begin{cases} \dot{u}_{d0}(k) = -\dot{L}_q i_{q0}(k) \omega_{e0}(k) \\ \dot{u}_{q0}(k) = \dot{R}_s i_{q0}(k) + \omega_{e0}(k) \dot{\psi}_f \\ \dot{u}_{d1}(k) = \dot{R}_s i_{d1}(k) - \omega_{e1}(k) \dot{L}_q i_{q1}(k) \\ \dot{u}_{q1}(k) = \dot{R}_s i_{q1}(k) + \omega_{e1}(k) \dot{L}_d i_{d1}(k) + \omega_{e1}(k) \dot{\psi}_f \end{cases} \quad (7)$$

式中: $u_{d0}(k)$ 、 $u_{q0}(k)$ 、 $i_{q0}(k)$ 、 $\omega_{e0}(k)$ 是图 1 中 $0 \sim t_1$ 时间内第 k 次采样数据; $u_{d1}(k)$ 、 $u_{q1}(k)$ 、 $i_{d1}(k)$ 、 $i_{q1}(k)$ 、 $\omega_{e1}(k)$ 为图 1 中的 $t_1 \sim t_2$ 时间内第 k 次采样数据,带上标点的参数为待辨识参数估计值。

2 融合多策略增强灰狼优化算法

2.1 灰狼优化算法

GWO 模拟了灰狼的捕猎行为与社会等级^[10]。算法将狼群按适应度值从高到低划分为四个等级:最优解记为 α ,次优解记为 β ,第三优解记为 δ ,其余解统称为 ω 。在每次迭代中, α 、 β 、 δ 作为领导狼^[11],指导 ω 狼更新位置以搜索猎物。 ω 狼在狩猎过程中利

用式(8)和式(9)实现对猎物的包围。

$$D_{p,j}^t = |C_{p,j}^t \times X_{p,j}^t - X_{i,j}^t| \quad (8)$$

$$X_{i,j}^{t+1} = X_{p,j}^t - A_{p,j}^t \times D_{p,j}^t \quad (9)$$

式中: $A_{p,j}^t$ 为猎物加速度, $A_{p,j}^t = 2r_1 \times a_0 - a_0$; $C_{p,j}^t$ 为权重参数, $C_{p,j}^t = 2r_2$ (其中 a_0 为控制参数, r_1 和 r_2 是在 $[0, 1]$ 中产生的两个随机数); $D_{p,j}^t$ 和 $X_{p,j}^t$ 为第 t 次迭代中在第 j 维的 ω 狼与猎物的距离向量和猎物位置; $X_{i,j}^{t+1}$ 、 $X_{i,j}^t$ 分别为第 $t+1$ 、 t 次迭代中第 i 只灰狼在第 j 维中的位置。

标准 GWO 中, 灰狼个体的位置更新不依赖于速度向量, 而是根据社会等级规则直接计算新位置。这种更新方式可能导致搜索轨迹在迭代中出现不连续, 即当前代的位置与上一代之间缺乏方向性关联, 使部分灰狼在移动过程中偏离有效搜索区域 (类似“漂移”现象), 从而削弱算法的全局覆盖能力, 增加错过最优解的风险。为此, 速度辅助灰狼优化算法引入速度项, 为 α 、 β 和 δ 三只领导狼保留独立的运动轨迹^[12], 以增强算法的探索能力, 并更好地平衡探索与开发阶段。

首先为第 i 个 ω 狼建立速度项。当 ω 狼受 α 、 β 和 δ 狼引导时, 其速度更新如式(10)所示。

$$V_{m,j}^{t+1} = k \times [\text{sgn}(A_{m,j}^t) \times |V_{m,j}^t|] + A_{m,j}^t \times D_{m,j}^t \quad (10)$$

式中: k 为惯性权重参数, 用于平衡算法的探索与开发能力, 其计算如式(11)所示; $A_{m,j}^t$ 为加速度项, 用于控制速度的变化幅度, 其计算如式(12)和式(13)所示; $V_{m,j}^t$ 、 $V_{m,j}^{t+1}$ 分别为在第 t 、 $t+1$ 次迭代中分别被领导狼 (α 、 β 、 δ 狼) 引导时第 j 维中 ω 狼的速度; $D_{m,j}^t$ 为在第 t 次迭代中第 j 维的 ω 狼与领导狼 (α 、 β 、 δ 狼) 之间更新后的距离, 用来随机强调领导狼的影响程度。

$$k = k_{\max} - (k_{\max} - k_{\min}) \times \frac{t-1}{T-1} \quad (11)$$

$$A_{m,j}^t = (2 \times r_m - 1) \times a^2 \quad (12)$$

$$a = a_{\max} - (a_{\max} - a_{\min}) \times \frac{t-1}{T-1} \quad (13)$$

式中: $k_{\max}$ 和 $k_{\min}$ 分别为 k 的最大值和最小值, $k_{\max} = 0.9$, $k_{\min} = 0.9$; T 为算法的最大迭代次数; a 为随时间变化的加速度权重参数; r_m 是 $[0, 1]$ 中生成的均匀分布随机数; $a_{\max}$ 和 $a_{\min}$ 分别为加速度系数的最大值与最小值, $a_{\max} = \sqrt{2}$, $a_{\min} = 0$ 。

α 、 β 和 δ 狼的位置更新公式如式(14)~式(16)所示。

$$D_{m,j}^t = |C_{m,j}^t \times X_{m,j}^t - X_{i,j}^t| \quad (14)$$

$$C_{m,j}^t = 1 + (2 \times r_m - 1) \times c^2 \quad (15)$$

$$c = c_{\max} - (c_{\max} - c_{\min}) \times \frac{t-1}{T-1} \quad (16)$$

式中: $X_{i,j}^t$ 为第 t 次迭代中第 i 个 ω 狼在第 j 维的位置; $C_{m,j}^t$ 为关键权重系数, 用于降低适应度不确定性对志优的影响; c 为领导狼系数; $c_{\max}$ 和 $c_{\min}$ 分别为 c 的最大和最小值, $c_{\max} = 1$, $c_{\min} = 0$ 。

ω 狼的 $t+1$ 次迭代后的最终位置 $X_{i,j}^{t+1}$ 可通过式(17)~(20)中的三个候选位置分量 $X_{1,j}^{t+1}$ 、 $X_{2,j}^{t+1}$ 、 $X_{3,j}^{t+1}$ 的计算进行更新。

$$X_{1,j}^{t+1} = X_{\alpha,j}^t - V_{\alpha,j}^{t+1} \quad (17)$$

$$X_{2,j}^{t+1} = X_{\beta,j}^t - V_{\beta,j}^{t+1} \quad (18)$$

$$X_{3,j}^{t+1} = X_{\delta,j}^t - V_{\delta,j}^{t+1} \quad (19)$$

$$X_{i,j}^{t+1} = (X_{1,j}^{t+1} + X_{2,j}^{t+1} + X_{3,j}^{t+1}) / 3 \quad (20)$$

2.2 混合初始化策略

元启发式算法普遍采用随机方式生成初始种群, 这可能导致种群分布不均, 进而影响收敛效率。标准灰狼优化算法同样存在这一问题, 制约了其性能的进一步提升。为改善初始种群质量, 本文采用拉丁超立方采样 (Latin Hypercube Sampling, LHS)、混沌映射与随机初始化相结合的混合种群初始化策略, 三种方法按 60%、20%、20% 的比例分配, 各自作用如下:

1) LHS (占比 60%): LHS 是一种分层抽样技术, 能确保每个变量在整个取值范围内被均匀采样, 样本间具有良好的空间填充性。相比于简单随机抽样, LHS 能更均匀地覆盖搜索空间, 避免样本聚集, 使算法在初始阶段就能定位到更具潜力的区域, 从而显著提升全局探索效率, 此优势在高维问题中尤为突出。

2) 混沌映射 (占比 20%): 采用 Logistic 映射生成混沌序列, 利用其遍历性、非周期性和初值敏感等特性, 产生多样且不重复的个体, 弥补 LHS 在非线性和复杂性方面的不足, 进一步增强种群多样性。

3) 随机初始化 (占比 20%): 保留传统随机方式, 作为上述两种策略的补充, 维持种群的一定随机性, 避免过度结构化。

三种策略协同作用, 既能确保搜索空间的充分覆盖, 又能维持种群的多样性与灵活性, 从而有效提升灰狼优化算法的整体性能。

Logistic 映射的数学表达式如式(21)所示。

$$x(t+1) = \mu x(t) (1 - x(t)) \quad (21)$$

式中: $x(t)$ 、 $x(t+1)$ 分别为第 t 、 $t+1$ 次迭代时的混沌序列值; μ 为可调参数, 取 3.9。

在实际问题(如工程约束优化)中, 最优解常位于搜索空间的边界附近。然而, 随机采样在边界区域的采样概率较低, 易忽略边界附近的最优解。为此, 将 10% 的粒子分别初始化在下界、上界和中心点处。

此外, 不同电机参数对目标函数的影响程度存在显著差异。为在初始化阶段更合理地分配采样资源, 通过全局敏感性分析, 确定各参数的相对影响权重。权重越大表示该参数对目标函数越敏感, 在后续的种群初始化(如 LHS 分层或混沌映射扰动)中应赋予更高的采样精细度或更大的扰动幅度, 从而进一步提升算法的寻优效率。

先通过式(22)生成基础随机位置 b_i , 然后在式(23)所示的变量范围内进行均匀随机采样。

$$b_i = x_{\min} + r_1 \odot (x_{\max} - x_{\min}) \quad (22)$$

$$x_{i,j} = \begin{cases} b_{i,j} + 0.3(x_{\max,j} - x_{\min,j})(r_3 - 0.5), & \text{if } r_2 < s_j, \\ b_{i,j}, & \text{otherwise} \end{cases}$$

$$s_j = [0.8, 0.2, 0.5, 0.3] \quad (23)$$

式中: b_i 为第 i 个个体的基础随机位置向量; $b_{i,j}$ 为第 j 维位置向量; $x_{\max}$ 和 $x_{\min}$ 分别为待辨识参数的上下边界向量; $x_{\max,j}$ 和 $x_{\min,j}$ 分别为第 j 维参数的上限和下限; $x_{i,j}$ 为第 i 个灰狼在第 j 维的位置; r_3 为扰动强度随机数; s_j 为第 j 维待辨识参数的全局敏感性权重, $s_j = [0.8, 0.2, 0.5, 0.3]$ 。

每个维度 j 生成一个随机数, 如果 $r_2 < s_j$, 则在第 j 维参数上添加扰动, 敏感度权重越高添加扰动的概率越大, 从而在敏感方向增强多样性; 当 $r_3 = 0$ 时, 扰动幅度为 $-0.15(x_{\max,j} - x_{\min,j})$; 当 $r_3 = 1$ 时, 扰动幅度为 $0.15(x_{\max,j} - x_{\min,j})$, 扰动幅度随机且均匀分布, 确保在敏感维度上增加多样性。

在速度初始化阶段, 引入速度方向感知策略: 80% 的狼朝向搜索空间中心移动, 以促进快速收敛; 20% 的狼背离中心方向探索, 以增强全局逃逸能力。同时, 在每只狼的速度更新过程中引入随机扰动, 以维持种群多样性。具体实现如式(24)~(26)所示: 首先, 在最小速度与最大速度之间进行均匀随机采样, 生成基础速度向量 V_{base} ; 然后, 根据当前位置与搜索空间中心的比较, 计算得到朝向中心或背离中心的方向向量; 最后, 按上述概率(80%朝向中心、20%背离中心)分配速度方向, 从而完成初始速度的设定。

$$V_{\text{base}} = V_{\min} + r_4 \odot (V_{\max} - V_{\min}) \quad (24)$$

$$d = \text{sign}\left(x_j - \frac{x_{\min} + x_{\max}}{2}\right) \quad (25)$$

$$V_{\alpha,j} = \begin{cases} V_{\text{base}} \odot d, & \text{prob 0.8} \\ V_{\text{base}} \odot (-d), & \text{prob 0.2} \end{cases}$$

$$V_{\beta,j} = V_{\alpha,j} \odot (0.8 + 0.4r_5)$$

$$V_{\delta,j} = V_{\alpha,j} \odot (0.6 + 0.6r_6) \quad (26)$$

式中: $V_{\max}$ 和 $V_{\min}$ 分别为初始化阶段设定的狼群搜索最大速度和最小速度; $V_{\alpha,j}$ 、 $V_{\beta,j}$ 、 $V_{\delta,j}$ 分别为 α 、 β 和 δ 狼的速度分量; d 为方向感知向量; x_j 为 w 狼在 j 维的位置向量; r_4 、 r_5 和 r_6 是三个不相同的 $[0, 1]$ 区间均匀分布的随机数向量。

2.3 双重引导与自适应变异

在迭代过程中, 参数 a (加速度系数)、 c (领导狼乘数)和 k (惯性权重)均采用非线性动态调整策略, 取代原有的线性调整方式。具体调整方式如下: ①加速度系数 a 根据式(27)进行指数衰减, 目的是在迭代早期快速探索, 后期精细开发; ②领导狼乘数 c 根据式(28)进行余弦变化, 使其值在迭代过程中产生波动, 以增加种群多样性; ③惯性权重 k 根据式(29)进行平方根增长, 早期惯性小以利于局部搜索, 后期惯性大以保持探索能力。

$$a = a_{\max} \times \exp[-3 \times (t/T)^2] \quad (27)$$

$$c = c_{\min} + (c_{\max} - c_{\min}) \times [1 - \cos(\pi \times t/T)/2] \quad (28)$$

$$k = k_{\min} + (k_{\max} - k_{\min}) \times \sqrt{t/T} \quad (29)$$

为进一步提升算法的全局开发能力并避免早熟收敛, 引入双重引导策略, 协同个体历史最优与全局历史最优信息驱动种群进化, 具体内容如下:

1) 采用精英策略保留个体历史最优位置。每次迭代中, 若历史最优值优于当前适应度, 则粒子回退至其历史最优位置, 确保个体搜索性能不退化; 反之, 则更新历史最优位置为当前位置并保留新解。

2) 强制种群周期性聚焦历史最优区域以增强开发能力。以 10 次迭代为 1 个周期, 在每个周期结束时, 将全局历史最优解注入狼群, 并据此更新下一周期领导狼层级。若该解优于当前 α 狼, 则将其置为新的 α 狼, 原 α 、 β 狼依次降级为 β 和 δ 狼; 反之, 则将该解作为普通灰狼加入种群, 保留当前领导层级不变。

在算法主循环中, 当灰狼完成位置更新后, 引入自适应变异策略。该策略根据迭代进程动态调整: 迭代初期采用较大的变异范围和概率, 以增强全局探索

能力;迭代后期逐渐减小变异幅度和概率,避免破坏已找到的较优解,侧重于局部开发;此外,配合精英策略,确保变异操作不会破坏当前已获得的最优解。整个 MS-VAGWO 的算法流程图如图 2 所示。




图 2 MS-VAGWO 算法流程图

3 融合多策略改进灰狼优化算法的 PMSM 参数辨识

3.1 PMSM 参数辨识原理

PMSM 参数辨识原理图如图 3 所示。




图 3 PMSM 参数辨识原理图

使用优化算法进行 PMSM 参数辨识所采用的适应度函数见式(30)。

$$\begin{aligned} f(\theta) &= \omega_1 [u_{d0}(k) - u'_{d0}(k)]^2 + \omega_2 [u_{q0}(k) - u'_{q0}(k)]^2 + \\ &\quad \omega_3 [u_{d1}(k) - u'_{d1}(k)]^2 + \omega_4 [u_{q1}(k) - u'_{q1}(k)]^2 \end{aligned} \quad (30)$$

式中: $f(\theta)$ 为适应度值; $\omega_1, \omega_2, \omega_3, \omega_4$ 为不相同的权

重系数。

3.2 基于 MS-VAGWO 算法的 PMSM 参数辨识步骤

基于 MS-VAGWO 的 PMSM 参数辨识流程图如图 4 所示,具体步骤如下:

- 1) 设置两种控制模式 ($i_d = 0$ 和 $i_d = -2$), 分别采集并存储多组 u_d, u_q, i_d, i_q 数据。
- 2) 初始化算法及相关参数配置。
- 3) 从采集数据中筛选稳态工况点。
- 4) 明确优化目标, 构建目标函数。
- 5) 将筛选数据输入算法, 通过迭代更新参数, 同时基于电机模型计算测量值。
- 6) 确定全局最优解。通过比较适应度函数值, 逐步收敛至全局最优位置。
- 7) 初步获得参数辨识结果, 经多次实验验证后确定最优值。
- 8) 评估辨识精度, 若不达标则返回步骤 5 继续迭代。




图 4 基于 MS-VAGWO 的 PMSM 参数辨识流程图

4 仿真实验分析

仿真环境中的电机不会受到各类工况条件的干扰,且电机信号采集过程不受采样器精度的制约。因此,仿真能够更有效地验证辨识算法的寻优性能。为了客观评估 MS-VAGWO 算法的性能优势,在 Simu-




图8 四种算法 L_d 辨识收敛过程对比图9 四种算法 L_q 辨识收敛过程对比图10 四种算法 ψ_f 辨识收敛过程对比

表1 辨识参数值

算法名称	R/Ω	L_d/H	L_q/H	ψ_f/Wb	时间/s
PSO	0.991	0.005 1	0.011 9	0.182 1	0.025
SSA	0.989	0.005 2	0.011 9	0.182 3	0.203
GWO	1.004	0.004 9	0.011 9	0.180 6	0.057
MS-VAGWO	0.976	0.005 2	0.011 9	0.182 5	0.529

表2 四种算法辨识误差对比

算法名称	平均适应度	R 误差/ Ω	L_d 误差/ H	L_q 误差/ H	ψ_f 误差/ Wb
PSO	1.915e-06	3.447	2.541	0.060	0.314
SSA	3.385e-07	3.237	1.249	0.051	0.241
GWO	1.536e-04	4.802	19.775	0.483	1.298
MS-VAGWO	1.453e-06	1.345	1.585	0.008	0.163

对 MS-VAGWO 算法的时间复杂度与参数辨识精度进行分析。在时间复杂度方面,相比标准 GWO, MS-VAGWO 增加了以下计算开销:①混合初始化: LHS 与混沌映射增加了 $O(N \times D)$ 的预处理开销,其中 N 为种群规模; D 为待辨识参数维度;②速度方向感知策略:引入速度向量更新,每代额外增加 $O(N \times D)$ 的计算量;③自适应变异操作:每代以概率 p_m 执行,平均复杂度为 $O(p_m \times N \times D)$ 。

尽管增加了上述开销,得益于 MS-VAGWO 优秀的收敛速度(见图6),总优化时间仅增加 0.4 s,且空间复杂度仍保持在 $O(N \times D)$,满足在线辨识的实时性要求。

在参数辨识精度方面,相较于 GWO、PSO 和 SSA 3 种对比算法,MS-VAGWO 在 PMSM 参数辨识中表现突出。其中,永磁磁链误差比 GWO 降低了约 87.5%,总体辨识误差比 GWO 降低了 94%,各参数误差显著减小。同时,由图 6~10 及表 2 可知 MS-VAGWO 的平均适应度良好,辨识结果更为稳定,准确率大幅提升,充分体现了算法的先进性。

5 结束语

针对灰狼优化算法初始种群分布不均、易早熟收敛等问题,本文提出了一种多策略改进的灰狼优化算法(MS-VAGWO)。通过融合拉丁超立方采样、混沌映射、边界值初始化及针对电阻参数的梯度敏感初始化,显著提升了初始解空间覆盖度;引入速度方向感知与领导狼速度差异化设计,平衡了全局勘探与局部开发能力;集成个体与全局历史最优双重引导策略,配合自适应变异及周期性最优注入,有效避免了早熟收敛。仿真结果表明,相较于 GWO、PSO 及 SSA 算法,MS-VAGWO 在 PMSM 参数辨识中表现出优异的性能,电阻辨识精度更高,电感误差和永磁磁链误差显著降低。该方法为 PMSM 高精度控制提供了可靠的技术支撑,具有显著的工程应用价值。

参考文献:

- [1] Zhu Zhiqiang, Liang Dawei, Liu Kan. Online parameter estimation for permanent magnet synchronous machines; an overview [J]. IEEE Access, 2021(9): 59059–59084.
- [2] Yu Yelong, Huang Xiaoyan, Li Zhaokai, et al. Full parameter estimation for permanent magnet synchronous motors [J]. IEEE Transactions on Industrial Electronics, 2022, 69(5): 4376–4386.
- [3] Pulvirenti M, Scarcella G, Celba G, et al. On-line stator resistance and permanent magnet flux linkage identification on open-end winding PMSM drives [J]. IEEE Transactions on Industry Applications, 2019, 55(1): 504–515.
- [4] Ma Zhao, Zhang Wei, He Jiabao, et al. Multi-parameter on-line identification of permanent magnet synchronous motor based on dynamic forgetting factor recursive least squares [C] // 2022 IEEE 5th International Electrical and Energy Conference (CIEEC). New York: IEEE, 2022: 4865–4870.
- [5] Zhang Yan, Bi Yongli, Wang Shigang. Parameter identification of permanent magnet synchronous motor based on extended Kalman filter and gradient correction [C] // 2020 IEEE International Conference on Mechatronics and Automation (ICMA). New York: IEEE, 2020: 718–722.
- [6] Zhou Shuai, Wang Dazhi, Li Yongliang, et al. Improved particle swarm optimization for parameter identification of permanent magnet synchronous motor [J]. Computers, Materials & Continua, 2024, 79(2): 2187–2207.
- [7] 姜金美. 基于改进灰狼算法的永磁同步电机多参数辨识方法研究 [D]. 湘潭: 湖南科技大学, 2022: 21–48.
- [8] Cheng Yuan, Huang Wan, Du Bochao, et al. Intelligent parameter identification of PMSM based on BPNN fitting nonlinear relationships. 2024 IEEE Transportation Electrification Conference and Expo, Asia-Pacific (ITEC Asia-Pacific) [C] // New York: IEEE, 2024: 594–599.
- [9] Minh X B, Fernando W, Duta R, et al. Reinforcement learning based method for online parameter identification of the permanent magnet synchronous machines [C] // 2024 IEEE 10th International Power Electronics and Motion Control Conference (IPEMC2024 – ECCE Asia) New York: IEEE, 2024: 2274–2279.
- [10] 龙文, 伍铁斌, 唐明珠, 等. 基于透镜成像学习策略的灰狼优化算法 [J]. 自动化学报, 2020, 46(10): 2148–2164.
- [11] 崔鸣, 靳其兵. 基于 Levy 飞行策略的灰狼优化算法 [J]. 计算机与数字工程, 2022, 50(5): 948–952.
- [12] Rezaei F, Safavi R H, Elaziz A M, et al. An enhanced grey wolf optimizer with a velocity-aided global search mechanism [J]. Mathematics, 2022, 10(3): 351.
- [4] Herrmann T, Christ F, Betz J, et al. Energy management strategy for an autonomous electric racecar using optimal control [C] // 2019 IEEE Intelligent Transportation Systems Conference (ITSC). Auckland, IEEE, 2019: 720–725.
- [5] Christ F, Wischniewski A, Heilmeier A, et al. Time-optimal trajectory planning for a race car considering variable tyre-road friction coefficients [J]. Vehicle System Dynamics, 2021, 59(4): 588–612.
- [6] Sundarraj S, Reddy R V K, Basam M B, et al. Route planning for an autonomous robotic vehicle employing a weight-controlled particle swarm-optimized Dijkstra algorithm [J]. IEEE Access, 2023(11): 92433–92442.
- [7] 丁承君, 阎欣怡, 冯玉伯, 等. 基于 APF 的 AGV 局部路径规划改进算法研究 [J]. 计算机工程与应用, 2022, 58(22): 305–312.
- [8] 余翔, 姜陈, 段思睿, 等. 改进 A* 算法和人工势场法的路径规划 [J]. 系统仿真学报, 2024, 36(3): 782–794.
- [9] Huang Xuanhao, Yan Chaobo. Dubins curve based continuous-curvature trajectory planning for autonomous mobile robots [PP/OL]. V2. arXiv (2025-06-22) [2025-10-10]. <https://doi.org/10.48550/arXiv.2309.07565>.
- [10] Ibrahim I, Decré W, Swevers J. Accelerated Reeds-Shepp and under-specified Reeds-Shepp algorithms for mobile robot path planning [J]. IEEE Transactions on Robotics, 2025(41): 2691–2708.
- [11] Heilmeier A, Wischniewski A, Hermansdorfer L, et al. Minimum curvature trajectory planning and control for an autonomous race car [J]. Vehicle System Dynamics, 2020, 58(10): 1497–1527.
- [12] Ögretmen L, Rowold M, Ochsenius M, et al. Smooth trajectory planning at the handling limits for oval racing [J]. Actuators, 2022, 11(11): 318.
- [13] Khanmohammadi S, Tinati M A, Ghaemi S, et al. Fuzzy and PSObased algorithm for driver's behavior modeling [C] // Proceedings of the Joint 2009 International Fuzzy Systems Association World Congress and 2009 European Society of Fuzzy Logic and Technology Conference. Lisbon, 2009: 1270–1275.
- [14] Du Feng, Li Jishun, Li Lun, et al. Robust control study for four-wheel active steering vehicle [C] // 2010 International Conference on Electrical and Control Engineering. Wuhan: IEEE, 2010: 1830–1833.

(上接第 9 页)