基于 PID 搜索算法的大规模储能动态经济调度研究

丁清华，吴冬梅*

南京邮电大学自动化学院 江苏南京

【摘要】伴随可再生能源渗透率的提升，大规模储能系统（Energy Storage System, ESS）于电力系统动态经济调度（Dynamic Economic Dispatch, DED）中的作用愈发凸显。然而，储能所引入的时序耦合约束致使传统 DED 问题更具非线性且求解难度增大，传统启发式算法通常难以在收敛速度与寻优精度间达成平衡。为在满足复杂约束的条件下降低发电成本，本文提出一种基于 PID 搜索算法（PID-based Search Algorithm, PSA）融合比例再分配约束修复机制的储能型动态经济调度方法。该方法借助 PID 控制器在误差消除方面的卓越特性，从比例、积分、微分三个维度引导种群向全局最优解收敛，有效克服了传统算法易陷入局部最优的弊端。5 机组测试系统的仿真结果显示，与粒子群算法（Particle Swarm Optimization, PSO）和遗传算法（Genetic Algorithm, GA）相比，PSA 算法在 24 小时调度周期内可获取最低的燃料成本 19380.53 美元，较 PSO 和 GA 分别降低了约 4.5%和 7.4%。在收敛性能层面，PSA 在 200 代内即可趋于稳定，迭代过程中适应度值持续下降，这证实了其具备更强的稳定性。表明 PSA 能够精准规划储能系统的充放电行为，有效实现“削峰填谷”，显著提升了电力系统的运行经济性。

【关键词】动态经济调度；储能系统；PID 搜索算法；时序耦合约束；非线性优化

【基金项目】江苏省自然科学基金项目（BK20130873）；南京邮电大学科研项目（NY220216）

【收稿日期】2026 年 8 月 15 日 【出刊日期】2026 年 9 月 20 日 【DOI】10.12208/j.jeea.20260019

Research on dynamic economic scheduling of large-scale energy storage based on PID-based search algorithm

*Qinghua Ding, Dongmei Wu**

School of Automation, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu

【**Abstract**】With the increasing penetration of renewable energy, large-scale energy storage systems (ESS) have become increasingly vital in dynamic economic dispatch (DED) of power systems. However, the time-coupled constraints introduced by energy storage make traditional DED problems more nonlinear and challenging to solve, as conventional heuristic algorithms often struggle to balance convergence speed and optimization accuracy. To reduce generation costs while satisfying complex constraints, this paper proposes an energy storage-based dynamic economic dispatch method based on the PID-based search algorithm (PSA) integrated with a proportional redistribution constraint repair mechanism. Leveraging the error elimination advantages of PID controllers, this method guides the population toward global optimal solutions through proportional, integral, and differential dimensions, effectively overcoming the tendency of traditional algorithms to get trapped in local optima. MATLAB simulations on a 5-unit test system demonstrate that compared to particle swarm optimization (PSO) and genetic algorithms (GA), the PSA algorithm obtains a minimum fuel cost of 19380.53 USD within the 24-hour dispatch cycle, which is approximately 4.5% and 7.4% lower than that of the PSO and GA, respectively. For convergence performance, PSA stabilizes within 200 generations, with the fitness value decreasing continuously during iterations, which confirms its superior stability. The results show that PSA can precisely plan energy storage system charging and discharging behaviors, effectively realizing “peak shaving and valley filling,” and significantly improving the operational economic efficiency of power systems.

【**Keywords**】Dynamic economic scheduling; Energy storage system; PID-based search algorithm; Time-coupled constraints; Nonlinear optimization

*通讯作者：吴冬梅

引言

近年来，随着“双碳”战略目标的推进，风能、太阳能等新能源实现了快速发展，可再生能源在电力结构中的占比持续提升。尽管煤电装机和发电占比有所下降，但其仍然是我国电力结构的基础和主体。同时，化石能源需求的持续增长以及燃料成本的高企，使电力行业面临显著的成本压力。在此背景下，提高化石能源利用效率、降低发电成本，已成为保障电力行业经济性与可持续发展的关键问题。

电力系统经济调度问题通常可分为静态经济调度（Static Economic Dispatch, SED）和动态经济调度（Dynamic Economic Dispatch, DED）两大类。静态经济调度是动态经济调度研究的基础，其特点是负荷保持恒定，并且仅发生在一个调度周期内，主要考虑电力系统的经济性。然而，由于未考虑负荷的动态变化，静态经济调度无法完全反映实际电力系统的运行状态。动态经济调度是电力系统运行的核心问题之一，最早于 1971 年由 Bechert 和 Kwatny 提出，是静态经济调度的延伸，主要是指将一天划分为几个时段，根据日负荷预测，进行日经济调度优化，并且考虑了火电机组的阀点效应和传输损耗，比静态经济调度更加符合实际电力系统的运行状态[1]。

电力系统的动态经济调度目标是在满足各种约束条件的基础上，合理匹配发电机组的出力，从而实现最优的运行成本。传统的 DED 问题通常采用简单的二次成本函数，具有光滑的非线性特征，且只有一个局部最优解，因此可以用经典的数学方法求解，如线性规划法[2]、动态规划法[3]、梯度投影法[4]等．然而，随着电力系统规模的不断扩大和结构的日益复杂，传统的优化方法在处理高维强约束问题时逐渐暴露出收敛速度慢、易陷入局部最优等问题，难以满足实际需求。

为了解决这一问题，近年来，众多随机搜索算法及启发式群体智能算法相继问世。群体智能算法模拟生物群体的行为规律，能有效避免模型在迭代过程中陷入局部最优解。较典型智能算法有遗传算法（GA）[5]、差分进化算法（Differential Evolution, DE）[6]、模拟退火算法（Simulated Annealing, SA）[7]、粒子群优化算法（PSO）[8]、鲸鱼优化算法（Whale Optimization Algorithm, WOA）[9]、蚁群优化算法（Ant Colony Optimization, ACO）[10]等，这些方法已被证明是解决经济负荷分配问题非常有效的手段。同时，一些优秀的元启发式算法被提出，比如帝国竞争算法（Imperialist Competitive Algorithm, ICA）[11]、混合骨干粒子群优化算法（Hybrid Bare-bones Particle Swarm Optimization, BBPSO）[12]、改进差分进化算法（Modified Differential Evolution, MDMDE）[13]和共生生物搜索算法（Symbiotic Organisms Search Algorithm, SOS）[14]等算法，尽管这些算法在降低优化成本方面表现良好，但所得解通常仍非全局最优。因此，探索更高质量的解，仍然是提升电力系统调度经济性的关键所在。随着智能电网的发展，大规模储能系统（Energy Storage System, ESS）因其削峰填谷的能力被广泛引入。然而，ESS 的引入增加了荷电状态（SOC）的时序耦合约束，使得 DED 问题演变为一个高维、非凸、非线性的复杂优化问题，当前的决策（充电/放电）会直接影响未来的可用电量。

PID 搜索算法（PID-based Search Algorithm, PSA）是一种基于控制理论的优化算法，核心思想是将 PID 控制策略应用于优化问题的搜索过程中[15]。与其他启发式算法相比，PSA 的独特之处在于其积分和微分机制。积分项通过累积历史搜索路径中的误差信息，不仅能消除稳态误差，还能在算法陷入停滞时提供额外的“推力”，帮助种群跳出局部最优，这对于处理储能系统严格的 SOC 端点约束至关重要；而微分项则利用误差的变化率预测解的移动趋势，在解空间梯度变化剧烈时起到阻尼作用，防止过冲，并加速收敛。因此在处理复杂的带储能系统的 DED 问题时，PSA 能够有效平衡全局搜索与局部搜索，应对时序耦合约束，避免陷入局部最优解，从而获得更优的调度方案。

本文将 PSA 应用于含大规模储能的 DED 问题中，利用其独特的积分和微分机制，在解空间中进行高效搜索。通过 MATLAB 仿真实验，对 PSA、PSO 和 GA 三种算法在 5 机组测试系统中的表现进行了对比分析。实验结果表明，PSA 算法在解决含储能系统的动态经济调度问题中具有明显的优越性。

1 DED-ES 问题建模

本文提出结合充放电效率差异和 SOC 时序耦合约束的 DED-ES（Dynamic Economic Dispatch with Energy Storage）模型。DED-ES 是一个典型的多时间尺度、非线性且约束复杂的优化问题，不仅需要优化机组出力，还需确定储能设备的充放电策略，从而在保证系统稳定性和安全性的前提下进一步降低总运行成本。其调度周期通常按小时或分钟分解为多个时刻进行优化，储能系统能够通过充电吸收多余电力或放电补充负荷以实现负荷平衡与峰谷调节，约束条件包括机组运行

约束、储能约束和系统功率平衡约束等，核心目标则是最小化系统总运行成本，同时考虑燃料成本、启停成本及约束违背惩罚。

DED-ES 模型通过将储能系统引入经济调度，不仅可以削峰填谷、平滑负荷曲线，还能降低燃料消耗和系统运行成本。同时，由于其储能的快速响应特性，DED-ES 模型能够更好地应对可再生能源出力波动，提升电力系统的灵活性和可靠性。

1.1 目标函数

DED-ES 问题的核心目标是最小化系统在调度周期内的总成本F_{Total}。该成本由火电机组的燃料成本及违反约束的惩罚成本两部分构成：

$$min\ F_{\text{Total}} = \sum_{t=1}^{T} \sum_{i=1}^{n_{\text{Gen}}} F_i(P_{i,t}) + \text{F}_{\text{Penalty}} \quad (1)$$

其中：F_{Total}为总运行成本，T为调度周期长度。n_{Gen}为发电机组总数。$P_{i,\,t}$为第 i 台机组在 t 时刻的实际出力（MW）。F_i（$P_{i,\,t}$）为机组 i 在 t 时刻的燃料成本函数，通常采用二次函数形式：

$$F_i(P_{i,t}) = a_i + b_i P_{i,t} + c_i P_{i,t}^2 \quad (2)$$

其中：a_i，b_i，c_i是机组 i 的成本系数。

为了引导算法搜索可行解，模型引入了功率平衡惩罚和储能状态越限惩罚：

$$F_{Penalty} = \lambda_1 \cdot (\sum |P_{mismatch}|)^2 + \lambda_2 \cdot (\max(0, |SOC_T - SOC_{ini}| - \epsilon))^2 \quad (3)$$

其中，λ_1，λ_2为惩罚系数，旨在强惩罚违反物理约束的不可行解。

1.2 约束条件

1.2.1 系统功率平衡约束

在任一时刻 t，所有发电机组的总出力$P_{\text{Gen},\,t}$与储能系统的净出力$P_{\text{ESS},\,t}^{\text{net}}$之和必须精确地等于系统负荷需求$P_{\text{Load},\,t}$。

$$\sum_{i=1}^{n_{\text{Gen}}} P_{i,t} + P_{\text{ESS},t}^{\text{net}} = P_{\text{Load},t}, \forall t \in [1,T] \quad (4)$$

本文在算法解码阶段设计了双层修复逻辑，来替代传统的等式约束。

（1）储能有限消纳策略

计算t时刻的初始功率不平衡量

$$Mismatch_t = P_{Load,t} - \sum P_{i,t}^{raw} \quad (5)$$

优先调用储能系统进行填补：

若$Mismatch_t > 0$（供不应求），ESS 在放电能力范围内尽可能放电；

若$Mismatch_t < 0$（供过于求），ESS 在充电能力范围内尽可能充电。

此策略充分利用了储能响应速度快、调节成本低的特性。

（2）机组比例再分配策略

若储能调节后仍存在功率残差$Residual$，则启动机组再分配机制。根据各机组当前的调节余量，将残差按比例分配给各机组：

$$P_{i,t}^{real} = P_{i,t}^{raw} + Residual \cdot \frac{R_{i,t}}{\sum_{k=1}^{N_{Gen}} R_{k,t}} \quad (6)$$

其中，$R_{i,\,t}$为机组i的可用调节容量。

该机制确保算法生成的每一个解都最大程度地满足了功率平衡约束，有效避免了死区效应，大幅提升了寻优效率。

1.2.2 发电机出力约束

每台发电机组在任一时刻的实际出力必须在其最小和最大运行限值之间：

$$P_i^{\min} \le P_{i,t} \le P_i^{\max} \quad (7)$$

1.2.3 储能系统运行约束

储能系统作为灵活性调节资源，需满足功率、容量及能量平衡约束。

（1）充放电功率约束

储能系统的净功率受限于变流器额定容量及当前可用能量，必须在其最大充/放电功率限值内：

$$-P_{\text{ch}}^{\max} \le P_{\text{ESS},t}^{\text{net}} \le P_{dis}^{\max} \quad (8)$$

（2）荷电状态（SOC）动态更新

ESS 的能量状态具有记忆性，其 t 时刻的储能量E_t取决于上一时刻的状态及当前的充放电行为：

$$E_t = E_{t-1} - \frac{\max(0, P_{ESS,t})}{\eta_{dis}} \cdot \Delta t - \min(0, P_{ESS,t}) \cdot \eta_{ch} \cdot \Delta t \quad (9)$$

式中，η_{ch}和η_{dis}分别为充电效率和放电效率；Δt为调度时间间隔（1 小时）。

（3）SOC 容量及周期性约束

$$SOC_{\min} \le SOC_t \le SOC_{\max} \quad (10)$$

为保证调度周期的可持续性，要求调度结束时的储能状态回归至初始水平的允许偏差ϵ范围内：

$$|SOC_T - SOC_{ini}| \le \epsilon \cdot Cap \quad (11)$$

2 基于 PID 的搜索算法

PID 算法是控制领域的经典算法，分为增量 PID 控制和位置 PID 控制。在过程控制中，PID 控制器通过比例（P）、积分（I）和微分（D）三个环节进行控制，是应用最为广泛的自动控制器之一。经典 PID 控制结构如图 1 所示，输出公式如下：

$$u（t）= K_p e（t）+ k_i \int_0^t e（\tau）d\tau + k_d \frac{d}{dx} i_q e（t）\quad（12）$$

式中：$u（t）$为控制量；$e（t）$为偏差，即期望值与实际值之差；K_p为比例系数；K_i为积分系数；K_d为微分系数。

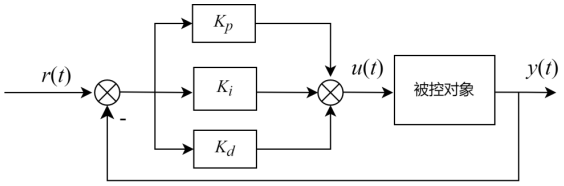


图 1　典型 PID 控制系统

PSA 算法是一种基于增量式 PID 控制启发的新颖算法。该算法通过连续调整系统偏差将整个种群收敛到最优状态。增量 PID 控制是一种比例积分微分控制方法，它通过计算当前时刻与前一时刻控制量的差值，并将该差值作为新的控制量。当设定目标值后，增量 PID 控制器将输出值提供给执行器，执行器根据输出值调节受控对象，调节后受控对象的实际值由传感器获取，并再次传递给增量 PID 控制器。

PSA 算法求解优化问题时，首先将种群进行初始化。对于一般优化问题，通常可将其描述为由一组决策变量、约束条件和目标函数构成的数学模型[16]。假设决策变量的数量为 d，变量的上界和下界分别为 ub 和 lb。最大迭代次数为$MaxIt$，种群大小为 N，初始种群可以表示为：

$$X_{mi} = (ub_i - lb_i) \cdot r_1 + lb_i \quad（13）$$

其中，X_{mi}表示第 m 个体的第 i 个维度。ub_i和lb_i分别是第 i 个变量（维度）的上界和下界，r_1是 0 到 1 之间的随机数。

然后，计算系统偏差。对于最小化问题，迭代次数 t 时的最佳个体$X_{best}（t）$是对应全局历史最小值的个体。经过 t 次迭代后，偏差$e_k（t）$为：

$$e_k（t）= X_{best}(t-1) - X(t-1) \quad（14）$$

最后，将全局历史最佳个体记为参考目标，进行 PID 调节。在实际问题中，比例、积分和微分因子会根据不同的情况和问题进行调整。当迭代次数为 t 时，PID 调节的输出值△u（t）为：

$$\Delta u(t) = K_p \cdot r_2 \cdot \left[e_k(t) - e_{k-1}(t)\right] + K_i \cdot r_3 \cdot e_k(t) + K_d \cdot r_4 \cdot \left[e_k(t) - 2e_{k-1}(t) + e_{k-2}(t)\right] \quad（15）$$

当所有解都非常接近最优解时，对该算法是不利的，在前期探索中，这种现象可能导致算法陷入局部最优。因此，在原有的输出值上，增加一个称为零输出的条件因子$o（t）$，以防止算法陷入局部最优。

$$o(t) = (\cos(1 - t/MaxIt) + \kappa r_5 \cdot Lv) \cdot e_k(t)（16）$$

式中，κ是调整系数，在前期阶段，随着 t 增大，其缓慢减小，这一特性有助于算法进行充分的探索。而在后期，接近最大迭代次数时，κ值迅速下降，这一变化则有助于算法及时转向开发阶段。r_5是 0 到 1 之间的随机数。Lv表示莱维飞行函数[17]，其定义为：

$$Lv = \frac{u\sigma}{\frac{1}{|v|^{\beta}}} \quad（17）$$

式中，u 和 v 是独立的正态分布随机量，$u \sim N(0, \sigma^2)$，$v \sim N(0, 1)$，σ是与β相关的尺度系数，满足：

$$\sigma = \left(\frac{\Gamma(1+\beta)\times sin(\pi\beta/2)}{\Gamma((1+\beta)/2)\times\beta\times 2^{(\beta-1)/2}}\right)^{\frac{1}{\beta}} \quad（18）$$

种群依据下式更新位置，

$$X_{mi}（t+1）= X_{mi}（t）+ \eta \cdot \triangle u（t）+（1-\eta）\cdot o（t）（19）$$

式中，$\eta = r_6 \cos（t/MaxIt）$，r_6是 0 到 1 之间的随机数。

本文采用 PSA 算法来求解 DED 问题，通过模拟 PID 控制器的调节过程，将 DED 问题中的目标函数和约束条件转化为控制系统的输入信号，利用比例、积分和微分三个环节的协同作用，在解空间中进行高效搜索，从而找到满足系统负荷需求且经济性最优的发电机组出力方案。具体步骤如下表。

PSA 算法求解 DED 问题时，比例环节（P）响应当前解与全局最优解的偏差 $e（t）$。它负责将种群中的个体快速拉向当前已知的最优区域。K_p决定基础的搜索速度，确保算法具备基本的开发能力。积分环节（I）关注历史累积误差$\int e（\tau）d\tau$。在处理储能系统的时序耦合约束时，单一时刻的优化往往容易导致局部最优。积分项能够记忆历史的搜索停滞状态。当算法陷入局部极值点，致使偏差不再减小时，积分项的累积值将持续递增，从而产生一个强力的修正信号，强制改变搜索方向，使算法具备强大的逃逸能力。微分环节（D）预测未来的误差趋势$\dot{e}（t）$。在动态经济调度中，负荷波

动可能导致目标函数地形复杂。微分项通过感知误差梯度的变化，提前调整搜索步长。例如，在快速接近最优解时，微分项会产生反向作用力减缓步长，从而抑制震荡，提高收敛精度。

算法 1 PSA 算法求解 DED 问题

初始化:设定种群规模N,最大迭代次数$MaxIt$，参数K_p, K_i, K_d，莱维飞行参数β，以及 DED 系统参数。
基于负荷均值进行启发式初始化，生成初始机组出力X
调用 SmartDispatch 评估初始种群适应度，确定全局最优解X_{best}
for $t = 1$ to $MaxIt$
　根据迭代次数计算自适应调整因子λ
　for 每个个体 $X_i \in X$
　　利用式(14)计算当前系统偏差
　　检索历史偏差e_{k-1}和e_{k-2}，计算增量式 PID 输出$\Delta u(t)$
　　生成莱维飞行步长Lv，计算零输出探测项$o(t)$
　　计算平衡权重η，根据式(19)更新个体位置:
　　执行 SmartDispatch 约束修复:
　　Step 1:计算功率不平衡量，优先调用 ESS 充放电进行消纳
　　Step 2:计算残差，按机组调节余量执行比例再分配得到可行解X_{real}
　　计算修复后解X_{real} 的适应度值$Cost_{new}$
　　if $Cost_{new} < Cost_{min}$
　　更新全局最优解$X_{best} \leftarrow X_{real}$及最低成本$Cost_{min}$
　　end if
　　更新当前个体位置$X_i \leftarrow X_{real}$并更新误差记忆
　end for
end for
输出 $X_{best}, Cost_{min}$

此外，零输出条件因子 $o(t)$ 能够进一步防止算法早熟收敛。当 PID 控制器的输出趋近于零时，莱维飞行所产生的具有长尾特征的随机步长开始发挥作用，对决策变量实施大范围的随机扰动。该机制模拟了 PID 控制中的抗积分饱和策略，确保算法在搜索后期仍保持对解空间的探索活力，从而有效避免了高维非线性问题中的局部最优。

3 算例分析与实验结果

3.1 实验设置

实验采用经典的 5 机组测试系统进行仿真。实验环境为 MATLAB 2020a，运行于 Intel Core i7 处理器、16GB 内存的计算机上。测试系统包含 5 台火电机组和一个大规模储能电站，调度周期 T=24 小时。

各机组的耗量特性系数（a，b，c）以及出力上下限如表 1 所示。机组总装机容量足以覆盖最大负荷需求。

储能系统（ESS）参数：为了测试大规模储能对系统的调节能力，设定储能系统初始荷电状态$SOC_{ini} = 0.5$，充放电效率$\eta_{ch} = \eta_{dis} = 0.95$。

表 1　5 台发电机组的运行参数

机组（i）	a_i（\$）	b_i（\$/MW）	c_i（\$/MW²）	$P_{\min}$（MW）	$P_{\max}$（MW）
G1	0	2.0	0.0030	20	150
G2	0	2.5	0.0025	20	150
G3	0	3.0	0.0020	20	150
G4	0	3.5	0.0015	20	150
G5	0	4.0	0.0010	20	150

表 2　储能系统运行参数

参数名称	符号	值	单位
容量	C_{ap}	50	MWh
最大充放电功率	P_{ESS}^{max}	10	MW
充电效率	η_{ch}	0.95	
放电效率	η_{dis}	0.95	
最小荷电状态	SOC_{min}	0.1	
最大荷电状态	SOC_{max}	0.9	
初始荷电状态	SOC_{ini}	0.5	

比例系数K_p=1.2，积分系数K_i=0.05，微分系数K_d=0.5，莱维飞行步长因子$\beta = 1.5$。该参数配置旨在通过较大的微分增益，在搜索初期实现快速收敛，并利用积分项消除稳态误差。PSO 设置惯性权重 w=0.7，学习因子$c_1 = c_2$=1.5。GA 设置交叉概率P_c=0.8，变异概率P_m=0.1。种群规模 N=50，最大迭代次数$MaxIt = 200$。

3.2 结果对比分析

图 2 展示了 PSA、PSO 和 GA 三种算法在求解 DED-ES 问题时的适应度收敛曲线对比。纵坐标为包含惩罚项在内的系统总成本，横坐标为迭代次数。从图中可以看出，PSA 算法（红线）在迭代初期（前 20 代）展现出极快的下降速度，这得益于 PID 控制器中微分项对误差变化趋势的预测能力，驱动种群迅速向最优解区域移动。相比之下，GA 算法（绿线）下降缓慢，搜索效率较低，PSO 算法（蓝线）虽在初期下降较快，但在第 25 代左右陷入停滞。PSO 算法在第 30 代至 200 代之间曲线几乎水平，表明其陷入了局部最优解难以逃脱。而 PSA 算法在第 20-40 代之间出现了明显的阶梯式下降，这表明积分项（I）的累积误差机制发挥了作用，成功帮助算法跳出了局部极值陷阱，最终收敛至全局更优解。

在迭代结束时（200 代），PSA 算法寻优得到的总成本显著低于 PSO 和 GA。GA 的最终适应度值最高，PSO 次之，PSA 最低，验证了 PSA 在处理高维非线性约束问题时的优越性。

表 3　24 小时系统负荷需求数据

时刻	1-6	7-12	13-18	19-24
负荷（MW）	150，160，170，180，200，230	260，300，350，400，420，450	430，400，380，350，320，300	280，260，240，220，180，160

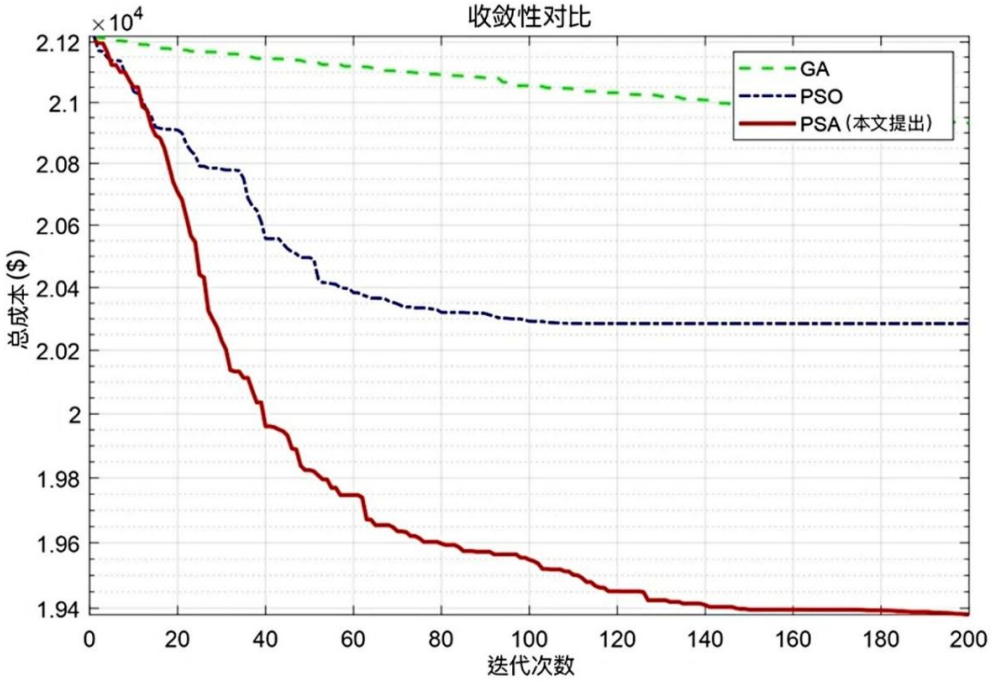


图 2　三种算法的收敛曲线

表 4 的统计数据进一步证实，PSA 算法成本较 PSO 降低约 4.5%，表明其在寻找最优解方面具有明显优势。在计算效率方面，PSA 平均耗时为 0.59 s，略高于 PSO 的 0.46 s 和 GA 的 0.32 s，但三种算法的计算时间均处于秒级，PSA 以略长的计算时间换取了更低的燃料成本，对于 24 小时动态调度仍具有可接受的时效，更适合对实时性要求较高的动态调度场景。

3.3 动态调度结果分析

图 3 展示了利用 PSA 算法得出的最优动态调度方案，包含机组出力堆叠图（上图）和储能系统充放电策略（下图）。

表 4　统计数据

算法	最优燃料成本（$）	平均耗时（s）
PSA	19380.53	0.59
PSO	20285.09	0.46
GA	20932.77	0.32

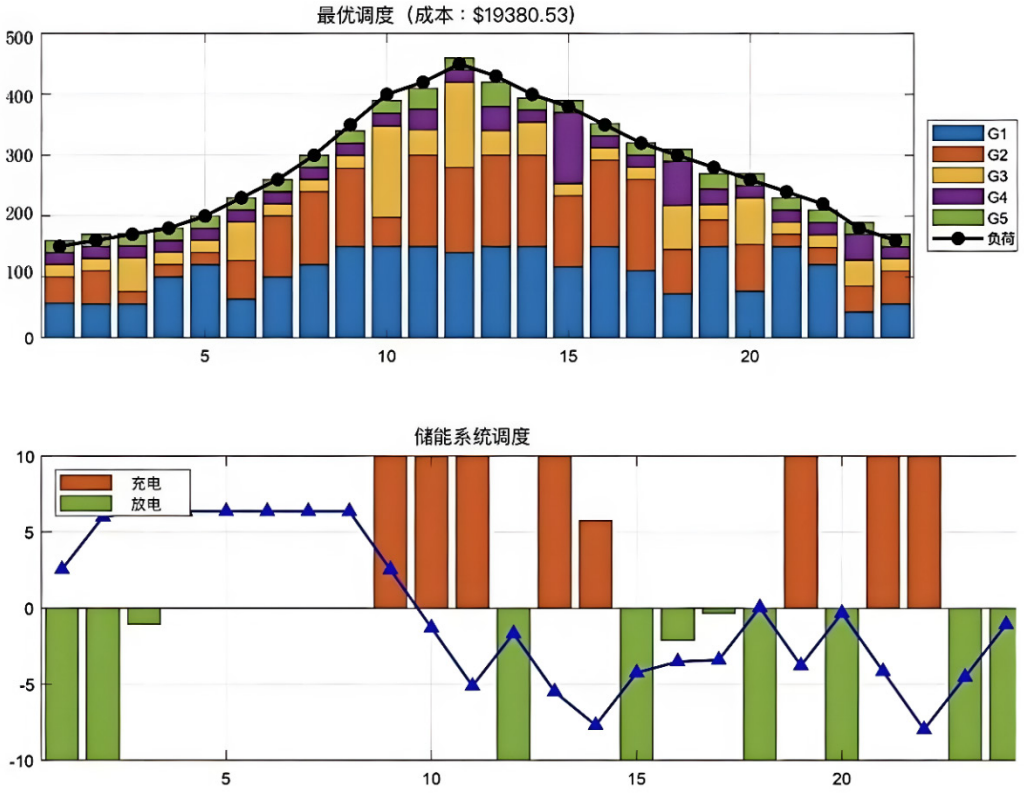


图 3　基于 PSA 算法的机组出力与储能最优调度结果

图中彩色堆叠柱状图代表 5 台机组的实时出力，黑色折线代表系统负荷需求。可以看出，在 PSA 的调度下，各机组的出力总和紧密跟随负荷变化。在负荷较低的时段（如第 1-5 小时），机组出力平稳；在负荷高峰时段（如第 10-15 小时），机组出力明显增加以满足需求。

图 3 下图中绿色柱状图表示储能系统充电（Power<0），橙色柱状图表示储能系统放电（Power>0）。PSA 算法成功规划出了具有明显“削峰填谷”特征的储能策略：

填谷（Valley Filling）：在凌晨低负荷时段（第 1-3 小时）及午间低谷（第 15 小时），电网负荷较轻，系统边际成本较低。此时 PSA 控制储能系统进行充电，吸收多余电力，提高了火电机组的负荷率，使其运行在更经济的区间。

削峰（Peak Shaving）：在上午的负荷高峰期（第 9-11 小时）及傍晚高峰（第 19-21 小时），系统负荷激增。此时 PSA 控制储能系统满功率放电，辅助火电机组供电。这不仅避免了启动高成本的调峰机组，还缓解了系统的供电压力，有效降低了高峰时段的燃料成本。

平抑波动：在第 12-18 小时的负荷波动期，储能系统根据实时供需差额灵活切换充放电状态，体现了 PSA 算法对动态约束的精确掌控能力。此外，调度结束时 SOC 成功回归至初始水平，保证了周期的可持续性。

4 结论

本文针对含大规模储能的电力系统动态经济调度（DED-ES）问题，提出了一种融合比例再分配约束修

复机制的 PSA 算法。针对储能引入后产生的高维时序耦合与非线性优化难题，该方法通过物理层面的约束修复，解决了功率平衡等式约束难以满足的问题，有效消除了随机搜索中的死区效应。MATLAB 仿真实验结果显示，与 PSO 及 GA 算法相比，PSA 算法借鉴增量 PID 控制思想，将个体与全局最优的偏差作为反馈量，通过比例-积分-微分三项动态调节搜索步长与方向，从而更精准地兼顾全局探索与局部开发，显著提升了收敛精度。在应用层面，该算法能够智能规划储能充放电策略，实现“低储高发”的削峰填谷，显著降低系统总燃料成本。同时，高效的约束处理能力使得 PSA 能够在极短时间内输出高质量可行解，充分具备了在线实时调度的应用潜力。

参考文献

[1] Bechert T E, Kwatny H G. On the optimal dynamic dispatch of real power, IEEE Transactions on Power Apparatus and Systems, 1972, PAS-91(3): 889–898.

[2] Somuah C B, Khunaizi N. Application of linear programming redispatch technique to dynamic generation allocation[J]. IEEE Transactions on Power Systems, 1990, 5(1):20-26.

[3] Travers D L, Kaye R J. Dynamic dispatch by constructive dynamic programming[J]. IEEE Transactions on Power Systems, 1998, (1):72-78.

[4] Granelli G P, Marannino P, Montagna M, et al. Fast and efficient gradient projection algorithm for dynamic generation dispatching[J]. IEE Proceedings C (Generation, Transmission and Distribution), 1989, 136(5): 295-302.

[5] Jethmalani R C, Simon P S, Sundareswaran K, et al. Real coded genetic algorithm-based transmission system loss estimation in dynamic economic dispatch problem[J]. Alexandria Engineering Journal, 2018, 57(4): 3535-3547.

[6] Shen X, Zou D, Duan N, et al. An efficient fitness-based differential evolution algorithm and a constraint handling technique for dynamic economic emission dispatch[J]. Energy, 2019, 186: 115801.

[7] Panigrahi C K, Chattopadhyay P K, Chakrabarti R N, et al. Simulated annealing technique for dynamic economic dispatch[J]. Electric Power Components and Systems, 2006, 34(5): 577-586.

[8] Kennedy J, Eberhart R. Particle swarm optimization[C]. 1995

[9] Mirjalili S, Lewis A. The whale optimization algorithm[J]. Advances in Engineering Software, 2016, 95: 51-67.

[10] Dorigo M, Birattari M, Stutzle T. Ant colony optimization[J]. IEEE Computational Intelligence Magazine, 2006, 1(4): 28-39.

[11] Mohammadi-Ivatloo B, Rabiee A, Soroudi A, et al. Imperialist competitive algorithm for solving non-convex dynamic economic power dispatch[J]. Energy, 2012, 44: 228-240.

[12] Zhang Y, Gong D, Geng N, et al. Hybrid barebones PSO for dynamic economic dispatch with valve-point effects[J]. Applied Soft Computing, 2014, 18: 248-260.

[13] 肖鹏. 基于差分进化算法的电力系统动态经济调度研究[D]. 徐州: 江苏师范大学, 2019.

[14] Sonmez Y, Kahraman H T, Dosoglu M K, et al. Symbiotic organisms search algorithm for dynamic economic dispatch with valve-point effects[J]. Journal of Experimental & Theoretical Artificial Intelligence, 2017, 29(3): 495-515.

[15] Gao Y. PID-based search algorithm: A novel metaheuristic algorithm based on PID algorithm[J]. Expert Systems with Applications, 2023, 232: 120886.

[16] Rao S S. Engineering Optimization: Theory and Practice[M]. 4th ed. Hoboken: John Wiley & Sons, 2009.

[17] Viswanathan G M, Afanasyev V, Buldyrev S V, et al. Lévy flights in random searches[J]. Physica A: Statistical Mechanics and its Applications, 2000, 282(1-2): 1-12.

版权声明：©2026 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。
https://creativecommons.org/licenses/by/4.0/

OPEN ACCESS