

文章编号:1671-5896(2026)04-0808-08

基于 IGAN-IChOA 的主动配电网源储双层优化配置

任爽, 郭钰婷, 何明晨, 吕鑫康

(东北石油大学 电气信息工程学院, 黑龙江 大庆 163318)

摘要: 针对风光出力随机性与分布式电源(DG: Distributed Generation)高渗透率并网对电网的冲击, 融合改进生成对抗网络(IGAN: Improved Generative Adversarial Network)和改进黑猩猩优化算法(IChOA: Improved Chimpanzee Optimization Algorithm), 构建主动配电网源储双层优化配置模型。首先, 采用 IGAN 生成风光典型出力场景表征其不确定性, 进而构建含电压质量指标的源储双层优化架构: 上层由 IChOA 优化确定储能系统(ESS: Energy Storage Systems)与 DG 的容量及位置配置方案, 下层采用二阶锥规划(SOCP: Second-Order Cone Programming)求解储能最优日内调度策略。最后, 经 IEEE33 节点系统验证表明, 该协同策略可显著降低系统年化成本与网损, 改善电压水平, 有效规避电压越限和 DG 功率波动问题。

关键词: 主动配电网; 改进生成对抗网络; 改进黑猩猩优化算法; 分布式电源; 储能系统

中图分类号: TP18; TM73

文献标志码: A

Bi-Level Planning of Distributed Energy Storage Systems in Active Grids Enabled by IGAN-IChOA Synergy

REN Shuang, GUO Yuting, HE Mingchen, LÜ Xinkang

(School of Electrical and Information Engineering, Northeast Petroleum University, Daqing 163318, China)

Abstract: In response to the impact of the randomness of wind and solar power generation and the high penetration rate of DG (Distributed Generation) on the grid, the IGAN (Improved Generative Adversarial Network) and the IChOA (Improved Chimpanzee Optimization Algorithm) are integrated to construct a source-storage two-layer optimal configuration model for active distribution networks. Firstly, IGAN is used to generate typical wind and solar power generation scenarios to represent their uncertainty. Then, a source-storage two-layer optimization architecture containing voltage quality indicators is constructed. The upper layer uses IChOA to optimize the capacity and location configuration schemes of ESS (Energy Storage Systems) and DG, and the lower layer uses SOCP (Second-Order Cone Programming) to solve the optimal daily dispatch strategy of energy storage. Finally, the IEEE 33-node system verification shows that this collaborative strategy can significantly reduce the annualized cost and network loss of the system, improve the voltage level, and effectively avoid voltage limit violations and DG power fluctuations.

Key words: active distribution network; generative adversarial networks; improved chimpanzee optimization algorithm; distributed generation(DG); energy storage system(ESS)

0 引言

随着 DG(Distributed Generation)、ESS (Energy Storage Systems)等新技术的开发应用, 其在改变支路

收稿日期: 2025-06-20

基金项目: 东北石油大学科研基金资助项目(2019YDL-10)

作者简介: 任爽(1979—), 女, 吉林榆树人, 东北石油大学副教授, 硕士生导师, 主要从事电力系统及其自动化研究, (Tel) 86-13945968670 (E-mail) rensh-2009@163.com。

潮流传输方向与量级的同时,还对系统稳定性与安全性形成新的挑战^[1]。目前传统场景分析法通常需要预先假设数据服从特定概率分布且建模过程繁琐,而生成对抗网络(GAN: Generative Adversarial Network)无需预设数据分布,可直接从历史数据学习分布特征并生成新样本。米阳等^[2]提出梯度惩罚 WGAN (GP-WGAN: Wasserstein GAN with Gradient Penalty) 模型。徐熠玮等^[3]构建了基于 GAN 的文本-图像生成模型。姜因等^[4]创新性地将注意力机制应用于语谱图特征学习网络。周丰丰等^[5]提出双尺度注意力图网络。胥桂仙等^[6]提出预训练模型 GCN (Graph Convolutional Networks) 的混合架构。葛延良等^[7]提出循环 GAN 以解决素描图轮廓模糊问题。刘远红等^[8]提出自注意力条件 CDCGAN (Conditional Deep Convolutional Generative Adversarial Networks) 模型。

在电力系统实际运行中, DG 与 ESS 的协同部署既能消纳分布式电源并网风险,又可全面提升电网运行效能。胡伟等^[9]提出双层优化框架的储能协同规划方法。Ping 等^[10]提出一种协同优化方法,决策 DG 的接入节点与安装容量,使系统网损全局最小。刘自发等^[11]基于 DG 和广义储能的动态特性提出一种双层优化架构。李振坤等^[12]建立考虑源-储-荷交互机制的配电网双层规划框架。周强等^[13]构建融合需求响应(DR: Demand Response)弹性的双层决策框架。赵新刚等^[14]通过重构 MOEA/D (Multi-Objective Evolutionary Algorithm based on Decomposition) 的分解策略和变异算子,建立了一种考虑风光不确定性的多目标优化模型。高金兰等^[15]提出储能运营商-电动汽车负荷聚合商协同决策的配电网双层规划架构。

上述文献报道从不同角度对 DG 与 ESS 优化配置做了较全面的研究,但大多聚焦 DG 和 ESS 协同规划或单一 GAN 类模型应用,缺乏二者融合的新方法。而现有 GAN 类模型难适配电力系统多源异构数据,并且传统规划也未充分结合数据驱动的潮流不确定性表征,为此,笔者针对配电网经济性、平抑电压波动及负荷峰谷调节需求,提出一种基于 IGAN-ICHOA (Improved Generative Adversarial Network-Improved Chimpanzee Optimization Algorithm) 混合智能算法的双层优化模型,以提升系统稳定性与潮流优化效能,实现源储高效配置。

1 基于自注意力模型的 IGAN 风光出力场景生成

针对传统 GAN 梯度消失问题,将最大均值差异 MMD (Maximum Mean Discrepancy) 引入 GAN 的损失函数中,采用最大均值差异度量生成样本和真实样本间的距离,训练过程中梯度不会消失,以生成高质量的样本。将改进后的生成器和鉴别器的损失函数分别定义为 L_G 和 L_D , E 为样本期望,则有:

$$\begin{cases} L_G = \frac{1}{m(m-1)} \sum_{i=1}^m \sum_{j \neq i}^m k_D(x_i, x_j) + \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j \neq i}^n k_D(x'_i, x'_j) - \\ \quad \frac{2}{mn} \sum_{i=1}^m \sum_{j=1}^n k_D(x'_i, x'_j), \\ L_D = \frac{1}{m(m-1)} \sum_{i=1}^m \sum_{j \neq i}^m k_D(x_i, x_j) - \frac{1}{n(n-1)} \sum_{i=1}^n \sum_{j \neq i}^n k_D(x'_i, x'_j), \end{cases} \quad (1)$$

其中 x_i 为真实样本集 X 中第 i 个真实样本, x_j 为真实样本集 X 中第 j 个真实样本, x'_i 和 x'_j 分别为生成样本集 X' 中第 i 个和第 j 个生成样本, m 和 n 分别为 X 和 X' 的样本个数, $k_D(\cdot)$ 为核函数。

定义真实样本 $x \sim P_r(x)$, 生成样本 $x' \sim P_g(x')$, 鉴别器输出标量 $D(\cdot)$ 。GAN 以 JS (Jensen-Shannon) 散度最小为目标,但存在梯度消失问题,因此引入梯度范数惩罚项:

$$G_p = \lambda E[\|\nabla D(X)\|_2 - 1]^2, \quad (2)$$

其中 $X = \varepsilon x + (1 - \varepsilon)x'$, $\varepsilon \sim U[0, 1]$, 为 $0 \sim 1$ 间随机数; λ 为梯度惩罚项的权重系数; E 为样本期望; $\|\cdot\|_2$ 为 2 范数。式(2)满足 Lipschitz 约束以加速网络训练收敛。

此时, IGAN 的目标函数转化为

$$\min_G \max_D V(D, G) = E_{x \sim p_r(x)}[D(x)] - E_{x' \sim p_g(x')}[D(x')] - \lambda E[\|\nabla D(X)\|_2 - 1]^2. \quad (3)$$

为增强 GAN 判别器性能并加速收敛,笔者在 IGAN 训练网络中加入自注意力机制,并根据新能源出力数据特征,最终通过融入自注意力机制的 IGAN 实现风光出力场景的高效生成。

2 配电网双层优化配置模型

2.1 上层优化配置模型

2.1.1 上层目标函数

1) DG 年投资运维成本:

$$C_{WP} = \sum_{m=1}^M \left[P_{WP,m} \left(\left(\frac{r(1+r)^T}{(1+r)^T - 1} + \eta \right) C_{D,m} + C_{r,m} \right) \right], \quad (4)$$

其中 M 为待安装 DG 总数, $P_{WP,m}$ 为第 m 台机组额定功率, r 为贴现率, T 为规划期限, η 为运维成本系数, $C_{D,m}$ 为机组 m 的单位投资成本系数, $C_{r,m}$ 为机组 m 的单位运维成本系数。

2) ESS 年投资运维成本:

$$C_{ESS} = \sum_{m=1}^M \left[\left(\left(\frac{r(1+r)^T}{(1+r)^T - 1} + \eta \right) C_{p,m} P_{ESS,m} + C_{e,m} E_{ESS,m} \right) \right], \quad (5)$$

其中 $C_{p,m}$ 和 $C_{e,m}$ 分别为 ESS 单位功率和容量成本; $P_{ESS,m}$ 和 $E_{ESS,m}$ 分别为第 m 台储能配置功率和容量。

2.1.2 上层约束条件

1) DG 接入容量约束:

$$\sum_{i=1}^n P_{WP,k} < \mu P_{load}^{sum}, \quad (6)$$

其中 P_{load}^{sum} 为系统总负荷容量; μ 为风光渗透率。

2) ESS 额定功率和容量约束:

$$\begin{cases} P_{ESS,min} \leq P_{ESS,k} \leq P_{ESS,max}, \\ E_{ESS,min} \leq E_{ESS,k} \leq E_{ESS,max}, \end{cases} \quad (7)$$

其中 $P_{ESS,max}$ 、 $P_{ESS,min}$ 为储能额定功率上下限; $E_{ESS,max}$ 、 $E_{ESS,min}$ 为储能额定容量的上下限; $P_{ESS,k}$ 、 $E_{ESS,k}$ 分别为第 k 台储能额定功率与容量。

2.2 下层优化配置模型

2.2.1 下层目标函数

1) 购电成本:

$$f_1 = C_{Buy} = 365 \sum_{s=1}^4 \sum_{t=1}^{24} p_s c^{Buy} E_{s,t}^{Buy} \Delta t, \quad (8)$$

其中 c^{Buy} 为购电单价; $E_{s,t}^{Buy}$ 为场景 s 在时段 t 的购电量。

2) 网络损耗:

$$f_2 = P_{loss} = \sum_{t=1}^{24} \sum_{k=1}^l C_t \frac{P_{k,t}^2 + Q_{k,t}^2}{U_{k,t}^2} R_k, \quad (9)$$

其中 C_t 为网损惩罚系数, $P_{k,t}$ 为节点 k 在 t 时刻注入的有功功率, $Q_{k,t}$ 为节点 k 在 t 时刻注入的无功功率, $U_{k,t}$ 为节点 k 在 t 时刻电压幅值。

3) 电压偏移量:

$$f_3 = \sum_{t=1}^{24} \sum_{k=1}^N \left[\frac{1 - U_{k,t}^2}{1 - U_{k,min}^2} \right]^2, \quad (10)$$

其中 N 为节点数; $U_{k,min}$ 为 k 节点电压下限。

4) 规划总目标函数:

$$F = \omega_1 f_1' + \omega_2 f_2' + \omega_3 f_3', \quad (11)$$

其中 ω_1 为购电成本权重, ω_2 为网损权重, ω_3 为电压偏移权重, $\omega_1 + \omega_2 + \omega_3 = 1$; f_1' 、 f_2' 、 f_3' 分别为标幺化子目标值。

2.2.2 下层约束条件

1) 支路潮流约束:

$$\begin{cases} \sum_{i: i \rightarrow j} \left(P_{ij} - \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} R_{ij} \right) + P_j = \sum_{k: j \rightarrow k} P_{jk}, \\ \sum_{i: i \rightarrow j} \left(Q_{ij} - \frac{P_{ij}^2 + Q_{ij}^2}{U_i^2} R_{ij} \right) + Q_j = \sum_{k: j \rightarrow k} Q_{jk}, \end{cases} \quad (12)$$

其中 P_{ij} 、 Q_{ij} 分别为支路 ij 的有功和无功功率; U_i 为节点 i 的电压幅值; R_{ij} 为支路 ij 的电阻; P_j 、 Q_j 分别为节点 j 的有功和无功功率; P_{jk} 为节点 j 至下级网络的有功传输功率; Q_{jk} 为节点 j 至下级网络的无功传输功率。

2) 节点电压约束:

$$U_{\min} \leq U_i \leq U_{\max}, \quad (13)$$

其中 $U_{\max}$ 为节点 i 的上限允许电压; $U_{\min}$ 为节点 i 的下限允许电压。

3) 支路容量约束:

$$P_{ij,t}^2 + Q_{ij,t}^2 \leq (S_{ij}^{\max})^2, \quad (i,j) \in L, \quad (14)$$

其中 $S_{ij}^{\max}$ 为支路 ij 额定输送容量; L 为全网母线集合。

4) DG 运行约束:

$$\begin{cases} 0 \leq P_{WP} \leq P_{WP}^{\max}, \\ Q_{WP}^{\min} \leq Q_{WP} \leq Q_{WP}^{\max}, \end{cases} \quad (15)$$

其中 $P_{WP}^{\max}$ 为风光机组有功出力上限; $Q_{WP}^{\max}$ 、 $Q_{WP}^{\min}$ 为风光机组无功容量可行域。

6) ESS 运行约束:

$$\begin{cases} x_{i,t}^{\text{ch}} P_{e,i}^{\text{ch},\min} \leq P_{e,i,t}^{\text{ch}} \leq x_{i,t}^{\text{ch}} P_{e,i}^{\text{ch},\max}, & i \in B^e, \\ x_{i,t}^{\text{dis}} P_{e,i}^{\text{dis},\min} \leq P_{e,i,t}^{\text{dis}} \leq x_{i,t}^{\text{dis}} P_{e,i}^{\text{dis},\max}, & i \in B^e, \\ x_{i,t}^{\text{ch}} + x_{i,t}^{\text{dis}} \leq x_{i,t}, & i \in B^e, \\ E_{e,i,t} = E_{e,i,t-1} + \eta_i^{\text{ch}} \cdot P_{e,i,t}^{\text{ch}} \cdot \Delta t - \frac{P_{e,i,t}^{\text{dis}} \cdot \Delta t}{\eta_i^{\text{dis}}}, & i \in B^e, \\ \eta_{e,i}^{\min} E_{e,i}^{\text{rate}} \leq E_{e,i,t} \leq \eta_{e,i}^{\max} E_{e,i}^{\text{rate}}, & i \in B^e, \end{cases} \quad (16)$$

其中 $x_{i,t}^{\text{ch}}$ 、 $x_{i,t}^{\text{dis}}$ 分别为节点 i 在 t 时段储能充放电状态(充电为1, 放电为0); $P_{e,i}^{\text{ch},\max}$ 、 $P_{e,i}^{\text{ch},\min}$ 分别为节点 i 储能充电功率的上下限; $P_{e,i}^{\text{dis},\max}$ 、 $P_{e,i}^{\text{dis},\min}$ 分别为节点 i 储能放电功率的上下限; B^e 为储能节点集合; $E_{e,i,t}$ 为节点 i 在 t 时段储能的剩余电量; $E_{e,i}^{\text{rate}}$ 为节点 i 储能的额定容量; η_i^{ch} 、 η_i^{dis} 为节点 i 储能的充放电效率; $\eta_{e,i}^{\min}$ 、 $\eta_{e,i}^{\max}$ 为节点 i 的 SOC(State Of Charge)安全区间。

3 配电网双层优化配置模型求解

3.1 改进的黑猩猩优化算法

首先, 采用 Circle 映射种群初始化增强解空间遍历性, 优化收敛速率及求解精度; 其次, 针对 ChOA 后期易早熟收敛问题, 笔者引入改进非线性收敛系数:

$$f = f_0 \times \left[1 - \left(\frac{e^{t/t_{\max}} - 1}{e - 1} \right)^k \right], \quad (17)$$

其中 k 为控制参量, 取值区间为 $[1, 10]$; t 为当前迭代次数; $t_{\max}$ 为最大迭代次数。

进一步, 引入时变自适应权重因子 ω :

$$\omega(t) = \omega_{\max} + (\omega_{\min} - \omega_{\max}) \frac{1}{1 + e^{-[5(2t/t_{\max} - 1)]}}, \quad (18)$$

其中 $\omega_{\min} = 0.4$, $\omega_{\max} = 0.9$ 。

最后, 融合差分进化算法(DE: Differential Evolution)变异算子, 更新 ChOA(Chimpanzee Optimization Algorithm)位置方程, 其中攻击者位置为 X_a , 第 i 个黑猩猩个体在 t 次迭代的位置更新为 $X_i(t)$:

$$X_i(t+1) = \frac{X_1 + X_2 + X_3 + X_4}{4} + r_3 F_1(X_a - X_j(t)) + r_4 F_2(X_k(t) - X_l(t)), \tag{19}$$

其中 $r_3, r_4 \in U[0,1]$; 差分缩放因子 $F_1=F_2=0.5$; 且 $j \neq k \neq l \neq i$ 。

3.2 基于 IGAN-ICHOA 的双层优化配置模型求解方法

基于 IGAN-ICHOA 的源储双层优化模型求解流程如图 1 所示。




图 1 求解流程
Fig. 1 The solving flow chart

4 算例分析

4.1 基于 IGAN 的风光出力场景生成

在测试集真实样本中随机抽样，并与生成集 X' 中筛选出的视觉相似样本构成样本对，为减小异常值的影响，计算各样本对的平均绝对误差 (MAE: Mean Absolute Error)。部分风光样本对的对比结果及 MAE 值如图 2、图 3 所示。




图 2 光伏场景对比图
Fig. 2 The comparison diagram of photovoltaic scenarios




图 3 风电场景对比图
Fig. 3 The comparison diagram of wind power scenarios

从图 2、图 3 可看出，风光测试集与生成样本的时序形态高度一致，其中光伏样本 3 的 MAE 低至 0.024 6，说明所提 IGAN 的对抗训练机制可精准捕捉风光出力非平稳时序特性。

4.2 算例

以 IEEE33 节点辐射型配电网为仿真平台，拓扑结构如图 4 所示。其中光伏安装节点为 3、14、26、32，风电安装节点为 7、18、25，储能安装节点为 13、29。




图 4 IEEE33 节点接线图

Fig. 4 The IEEE33 node wiring diagram

配电系统不同时间段的电价如表 1 所示, 笔者计算时假设全年的分时电价保持不变。

表 1 分时电价价格

Tab. 1 Time-of-use pricing

时段	时点/h	电价/¥ · (kWh) ⁻¹	时段	时点/h	电价/¥ · (kWh) ⁻¹
峰时段	[10,11,18,19]	1.143 5	谷时段	[1-6,23,24]	0.363 3
平时段	[7-9,12-17,20-22]	0.646 0			

4.3 算例结果分析

表 2 给出了笔者提出的协同优化策略所求得 DG-ESS 配置方案。

表 2 DG-ESS 协同优化配置方案

Tab. 2 The coordinated DG-ESS deployment scheme

光伏/kW	风电/kW	储能/(kW,kW · h)
节点 3: 500, 节点 14: 700	节点 7: 800, 节点 18: 600	节点 13: 600,2 400
节点 26: 400, 节点 32: 600	节点 25: 400	节点 29: 400,1 600

为分析引入 ESS 的影响及模型的不同求解方法, 设计 3 方案验证模型与算法的合理性与有效性。

方案 1: DG 独立配置的双层优化模型。

方案 2: DG-ESS 协同配置的双层优化模型, 采用 IChOA 算法求解。

方案 3: DG-ESS 协同配置的双层优化模型, 采用 IChOA 算法+二阶锥求解。

1) 容量配置及各指标对比分析。表 3 给出了 3 种方案下的 DG-ESS 容量配置及网损、电压质量等指标对比结果。

表 3 不同方案 DG-ESS 容量配置及各指标对比

Tab. 3 DG-ESS capacity deployment and performance metrics comparison under different schemes

优化方案	风电容量/kW	光伏容量/kW	ESS 功率/kW	ESS 能量/(kW · h)	年化总成本/(万元 · 年 ⁻¹)	线损降低/%	电压偏差/(p. u.)	可再生消纳率/%	峰谷差降低/%
方案 1	1 250.0	1 450.0	0.0	0.0	46.75	28.4	0.042	92.5	12.8
方案 2	950.0	1 250.0	650.0	2 200.0	42.30	34.6	0.031	97.2	26.5
方案 3	880.0	1 180.0	750.0	2 600.0	38.65	41.8	0.024	98.6	32.7

由表 3 可知, 方案 2 相比方案 1 年化总成本降低 9.5%, 方案 3 相比方案 2 年化总成本降低 8.6%, 说明引入 ESS 后, 通过 DG 与 ESS 的协同优化, 年综合成本有较大幅度降低。方案 2 相比方案 1 线损降低效果提升 21.8%, 电压偏差改善 26.2%, 方案 3 相比方案 2 线损降低效果提升 20.8%, 电压偏差改善 22.6%, 说明方案 3 相比于 1 和 2, 其显著提升了系统电压稳定性, 增强了电网可靠性。

2) 网络损耗分析。如图 5 所示, 方案 3 平均网损为 90.03 kW, 较方案 1 降低 26.7%, 且全时段网损均低于其他方案。说明通过 DG-ESS 协同优化, 系统损耗显著降低, 配电网运行效率获得有效提升。




图 5 网络损耗对比

Fig. 5 The comparison of network loss

3) 电压质量分析。如图 6 和图 7 所示, 方案 2 电压最低点位于节点 21, 电压幅值标幺值为 0.880 0 p.u., 而方案 3 电压最低点迁移至线路末端(节点 22, 幅值 0.920 0 p.u.), 较方案 2 提高 0.04 p.u.。说明通过 DG-ESS 协同优化, 系统电压水平得到改善, 同时配电网运行稳定性也得到提升。




图 6 方案 2 节点各时刻电压水平
Fig.6 The voltage levels at each moment of each node in plan 2




图 7 方案 3 节点各时刻电压水平
Fig.7 The voltage levels at each moment of each node in plan 3

4.4 改进黑猩猩优化算法优化结果分析

为测试笔者提出算法的改进效果, 将笔者改进的算法与原始的黑猩猩优化算法 (ChOA) 和遗传算法 (GA: Genetic Algorithm) 进行对比分析, 结果如图 8 所示。从图 8 可看出, 笔者提出的改进算法收敛精度优于 ChOA 和 GA, 并且其收敛速度更快, 且最终适应度值更小, 即年化总成本更小, 故可知所提 IChOA 算法在求解 DG 和 ESS 双层优化配置模型中具有更大优势。




图 8 算法对比曲线

Fig.8 Algorithm comparison curve

5 结 论

针对主动配电网源储协同优化问题, 笔者构建了基于 IGAN-IChOA 的双层优化配置模型。经改进求解策略(自适应 IChOA)及多尺度算例验证, 证实了模型及算法有效性, 得到结论如下:

- 1) 所提 IGAN 场景生成方法规避了参数化建模偏差, 可生成高质量风光出力时序场景, 适配高比例可再生能源接入需求;
- 2) IChOA 可高效求解源储双层规划模型, 其快速的收敛速度与强大的全局搜索能力, 在处理复杂配置问题时具有显著优势;
- 3) 所提 IGAN-IChOA 协同规划模型同步提升了主动配电网经济性、电压质量及运行可靠性等指标, 实现了技术-经济多目标优化。

参考文献:

[1]王子辉, 贾燕冰, 李彦晨, 等. 计及电能质量影响的主动配电网光储容量优化 [J]. 电网技术, 2024, 48 (2): 607-620.
WANG Z H, JIA Y B, LI Y C, et al. Optimization of Photovoltaic Storage Capacity in Active Distribution Networks Considering the Impact of Power Quality [J]. Power System Technology, 2024, 48(2): 607-620.

[2]米阳, 周杰, 卢长坤, 等. 基于改进生成对抗网络与碳足迹的配电网多目标双层规划 [J]. 中国电机工程学报, 2024, 44(21): 8421-8435.

MI Y, ZHOU J, LU C K, et al. Multi-Objective Bilayer Programming of Distribution Network Based on Improved Generative Adversarial Network and Carbon Footprint [J]. Proceedings of the CSEE, 2024, 44(21): 8421-8435.

[3]徐熠玮, 陈刚. 基于改进 GAN 算法的文本匹配生成图像模型 [J]. 吉林大学学报(信息科学版), 2025, 43 (2): 258-264.

- XU Y W, CHEN G. Text Matching Image Generation Model Based on Improved GAN Algorithm [J]. Journal of Jilin University (Information Science Edition), 2025, 43(2): 258-264.
- [4] 姜囡, 庞永恒, 高爽. 基于注意力机制语谱图特征提取的语音识别 [J]. 吉林大学学报(理学版), 2024, 62(2): 320-330.
JIANG N, PANG Y H, GAO S. Speech Recognition Based on Attention Mechanism Spectrogram Feature Extraction [J]. Journal of Jilin University (Science Edition), 2024, 62(2): 320-330.
- [5] 周丰丰, 张金楷. 具有局部和全局注意力机制的图注意力网络学习单样本组学数据表征 [J]. 吉林大学学报(理学版), 2023, 61(6): 1351-1357.
ZHOU F F, ZHANG J K. Graph Attention Networks with Local and Global Attention Mechanisms Learn Single-Sample Omics Data Representation [J]. Journal of Jilin University (Science Edition), 2023, 61(6): 1351-1357.
- [6] 胥桂仙, 刘兰寅, 张廷, 等. 基于预训练模型和图神经网络的藏文文本分类研究 [J]. 东北师大学报(自然科学版), 2023, 55(1): 52-64.
XU G X, LIU L Y, ZHANG T, et al. Research on Tibetan Text Classification Based on Pre-Trained Model and Graph Neural Network [J]. Journal of Northeast Normal University (Natural Science Edition), 2023, 55(1): 52-64.
- [7] 葛延良, 孙笑笑, 王冬梅, 等. 基于循环生成对抗网络的人脸素描合成网络设计 [J]. 吉林大学学报(信息科学版), 2023, 41(1): 76-83.
GE Y L, SUN X X, WANG D M, et al. Design of Face Sketch Synthesis Network Based on Cyclic Generative Adversarial Network [J]. Journal of Jilin University (Information Science Edition), 2023, 41(1): 76-83.
- [8] 刘远红, 王庆龙, 张文华, 等. 基于改进生成对抗网络的抽油机故障诊断方法 [J]. 吉林大学学报(信息科学版), 2022, 40(6): 963-969.
LIU Y H, WANG Q L, ZHANG W H, et al. Fault Diagnosis Method of Pumping Unit Based on Improved Generative Adversarial Network [J]. Journal of Jilin University (Information Science Edition), 2022, 40(6): 963-969.
- [9] 胡伟, 杨硕. 考虑配电网脆弱性的储能双层优化配置模型 [J]. 智慧电力, 2024, 52(6): 1-8.
HU W, YANG S. Two-Layer Optimal Configuration Model of Energy Storage Considering the Vulnerability of Distribution Network [J]. Smart Power, 2024, 52(6): 1-8.
- [10] PING L, HENAN D, GUANFENG Z, et al. Research on Loss Reduction Strategy of Distribution Network Based on Distributed Generation Site Selection and Capacity [J]. Energy Reports, 2023, 9(S8): 1001-1012.
- [11] 刘自发, 于普洋, 李颀雨. 计及运行特性的配电网分布式电源与广义储能规划 [J]. 电力自动化设备, 2023, 43(3): 72-79.
LIU Z F, YU P Y, LI J Y. Planning of Distributed Power Sources and Generalized Energy Storage in Distribution Networks Considering Operational Characteristics [J]. Electric Power Automation Equipment, 2023, 43(3): 72-79.
- [12] 李振坤, 徐廷君. 考虑“源储荷”协同的主动配电网双层优化配置 [J]. 智慧电力, 2025, 53(3): 77-83.
LI Z K, XU T J. Two-Layer Optimal Configuration of Active Distribution Network Considering Synergy of “Source-Storage-Load” [J]. Smart Power, 2025, 53(3): 77-83.
- [13] 周强, 姚朴. 考虑需求响应的分布式光伏储能系统双层优化配置 [J]. 能源与环保, 2025, 47(1): 155-160.
ZHOU Q, YAO P. Considering Demand Response of Double Layer Distributed Photovoltaic Energy Storage Systems [J]. China Energy and Environmental Protection, 2025, 47(1): 155-160.
- [14] 赵新刚, 王桢. 基于改进 MOEA/D 算法的含可再生能源系统协同优化调度 [J]. 吉林大学学报(工学版), 2024, 54(4): 1129-1135.
ZHAO X G, WANG Z. Cooperative Optimal Scheduling of Systems with Renewable Energy Based on the Improved MOEA/D Algorithm [J]. Journal of Jilin University (Engineering and Technology Edition), 2024, 54(4): 1129-1135.
- [15] 高金兰, 侯学才, 刁楠, 等. 储能运营商和电动汽车利益的配电网双层优化方法 [J]. 吉林大学学报(信息科学版), 2023, 41(4): 685-692.
GAO J L, HOU X C, DIAO N, et al. Two-Layer Optimization Method of Distribution Network for the Interests of Energy Storage Operators and Electric Vehicles [J]. Journal of Jilin University (Information Science Edition), 2023, 41(4): 685-692.

(责任编辑: 张洁)