

基于图卷积网络的新型电力系统实时无功功率优化

张沛^{1,2}, 刘晓菲², 李文云³, 路学刚³, 王珍意³, 翟苏巍⁴, 孙慧博⁵

(1. 天津大学电气自动化与信息工程学院, 天津 300072; 2. 北京交通大学电气工程学院, 北京 100044; 3. 中国南方电网云南电力调度控制中心, 昆明 650011; 4. 中国南方电网云南电网有限责任公司电力科学研究院, 昆明 650217; 5. 天津理工大学电气工程学院, 天津 300382)

摘要: 新能源出力的快速变化引起电网电压频繁波动, 严重威胁电网的安全与经济运行。为此, 提出了一种基于图卷积网络(graph convolutional network, GCN)的实时无功功率优化方法。首先, 构建了考虑节点重要性的多目标无功功率优化模型。基于此, 建立无功功率优化模型的图表示, 并结合优化问题重构邻接矩阵。然后, 基于GCN算法映射出最优解集, 并利用改进CRITIC-AHP-TOPSIS组合赋权算法选取最优解, 获得实时优化策略。最后, 以改进的IEEE 39节点系统和实际电网为例, 验证了所提方法不仅具有求解速度快和避免陷入局部最优解的优势, 而且获得了更理想的电压偏差和有功功率网损, 保障新型电力系统运行的安全性和经济性。

关键词: 图卷积网络; 新能源; 实时无功功率优化; 节点重要性; 最优解

Real-Time Reactive Power Optimization for New Power Systems Based on Graph Convolutional Networks

ZHANG Pei^{1,2}, LIU Xiaofei², LI Wenyun³, LU Xuegang³, WANG Zhenyi³, ZHAI Suwei⁴, SUN Huibo⁵

(1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 2. School of Electrical Engineering, Beijing Jiaotong University, Beijing 100044, China; 3. Yunnan Electric Power Dispatching and Control Center, CSG, Kunming 650011, China; 4. Electric Power Research Institute of Yunnan Power Grid Co., Ltd., CSG, Kunming 650217, China; 5. School of Electrical Engineering, Tianjin University of Technology, Tianjin 300382, China)

Abstract: The rapid fluctuations in renewable energy output cause frequent voltage oscillations in power grids, severely threatening the safe and economical operation of power grids. To address this issue, a real-time reactive power optimization method based on graph convolutional networks (GCN) is proposed. Firstly, a multi-objective reactive power optimization model considering the importance of nodes is constructed. Based on this, the graph representation of the reactive power optimization model is established, and the adjacency matrix is restructured in conjunction with the optimization problem. Then, the optimal solution set is mapped using the GCN algorithm, and the improved CRITIC-AHP-TOPSIS combined weighting algorithm is employed to select the optimal solution, forming a real-time optimization strategy. Finally, using the modified IEEE 39-node system and an actual power grid as examples, the proposed method is verified. The results show that the method not only has the advantages of fast solving speed and avoiding local optima but also achieves more favorable voltage deviation and active power loss, ensuring the safety and economy of new power system operation.

Key words: graph convolutional networks; renewable energy; real-time reactive power optimization; importance of nodes; optimal solution

基金项目: 中国南方电网有限责任公司云南电力调度控制中心科技项目(YNKJXM20222463)。

Foundation item: Supported by the Science and Technology Project of Yunnan Electric Power Dispatching and Control Center, China Southern Power Grid Co., Ltd.(YNKJXM20222463).

0 引言

随着我国新型电力系统建设进程的加速推进,电网中新能源占比不断提高^[1]。风电大规模并网后,因风机的动态无功功率支撑能力弱于常规电源,导致电网电压波动变得更加剧烈和频繁,甚至电压越限,严重影响电网的安全和经济运行^[2-3]。此外,随着我国多类电源接入的多样化输电格局的形成,一天不同时段主要的供电电源由不同类型电源担任,电网运行方式的多变导致电网电压随之产生波动,这也大大增加了电网运行的复杂性和电压波动频率^[4-5]。因此,面对高比例风电并网的发展趋势,亟需研究快速、有效的日内实时无功功率优化策略,保障风电并网系统运行的安全性和经济性。

电力系统无功功率优化是指在满足系统约束的条件下利用各类无功功率调节设备来提高电能质量并降低系统网损^[6-7]。目前,针对无功功率优化问题的求解方法主要分为三类,即传统算法、智能优化算法和混合算法^[8-9]。传统算法(如内点法)是以某个点为初始点,根据特定的运行轨迹对当前的解不断地进行调整,最终迭代得到最优解。但是其需要确定合适的初始点,且面对大电网时会出现“维数灾难”问题,导致无法获得可行解,实用性欠佳^[10-11]。面对传统算法的困境,研究人员提出了智能优化算法,通过模拟某种生物现象来搜寻最优解。文献[12]考虑了分布式电源的不确定性,构建了以系统有功功率网损和节点电压偏差最小为目标函数的多目标无功功率优化模型,并采用非支配排序遗传算法进行求解。然而,智能优化算法(如粒子群算法)存在易陷入局部最优解或易早熟等问题,且求解速度较慢^[13-15]。混合算法是将两种或多种算法进行合理的搭配,优势互补,以实现更好的动态无功功率优化效果。文献[16]以系统网损最小为目标函数,采用整数粒子群算法和内点法相结合的算法获得无功功率优化策略。混合算法虽然提高了算法寻优效率,但依赖于参数的精细调节,且难以满足新型电力系统对实时性的需求。

电力系统规模逐渐庞大,结构日益复杂,近年来随着人工智能和大数据技术的发展基于数据驱动的优化方法逐渐成为研究热点。其主要是通过机器

学习的方法对海量电网运行数据的学习,提取有价值的信息,并提供优化决策^[17]。文献[18]通过深度强化学习将无功功率优化建模为马尔可夫决策过程,实现了复杂动态电网中的实时优化与策略调整。文献[19]基于极限学习机(extreme learning machine, ELM)和自动编码器(autoencoder, AE)的方法构建了无模型的特征映射与优化策略,快速实现了无功功率优化的非线性决策。文献[20]提出基于深度置信网络(deep belief net, DBN)的优化方法,通过无监督预训练和监督精调结合实现了高渗透率新能源场景下无功功率优化的特征提取与鲁棒性提升。

针对具有快速求解需求的新型电力系统无功功率优化问题,本文提出了一种基于图卷积网络的多目标无功功率优化方法。所提方法能够有效挖掘电网节点之间的复杂关联关系,感知电网的拓扑结构,从而显著提升优化结果的全局性与可靠性。本文的主要贡献如下。

1)结合风电并网系统的实际问题构建了考虑节点重要性的多目标无功功率优化模型。在此基础上将无功功率优化模型映射到图特征上,并结合优化问题重新构造 GCN 的邻接矩阵。

2)所提算法能够利用先验知识快速获取无功功率优化策略,加快了多目标优化问题的求解速度,并有效避免了智能优化算法易陷入局部最优解的问题。

3)提出了一种基于改进 CRITIC-AHP-TOPSIS 组合赋权算法的最优解选取方法,为从最优解集中筛选得到最优解提供有力的支撑。

1 考虑节点重要性的多目标无功功率优化模型

本节以系统有功功率网损和节点电压偏差最小为目标函数,构建多目标无功功率优化模型。

1.1 系统有功功率网损

系统有功功率网损的数学表达式如式(1)所示。

$$\begin{aligned} \min f_1 &= \min \Delta P_{\text{loss}} \\ &= \min \left[\sum_{i,j \in N_b} G_{ij} (V_i^2 + V_j^2 - 2V_i V_j \cos \theta_{ij}) \right] \end{aligned} \quad (1)$$

式中: f_1 为系统有功功率网损目标函数; ΔP_{loss} 为输电电能时通过热能形式散发的功率损耗; V_i 、 V_j 分

别为节点*i*和*j*的电压; N_b 为系统支路数量; G_{ij} 为节点*i*和*j*之间的电导; θ_{ij} 为节点*i*和*j*之间的相角差。

1.2 节点电压偏差

传统电压偏差指标通常将所有节点同等对待,但不同节点对电压波动的影响可能存在差异。例如负荷或风机有功功率大的节点更容易引起电压稳定问题。因此,这些节点在无功功率优化时应该被给予更高的调整优先级。基于上述考虑设计了一种考虑节点重要性的电压偏差指标。节点电压偏差指标 ΔV_{total} 包括3部分,分别是考虑权重的负荷节点、风机节点的电压偏差以及传统发电机节点电压偏差。其数学表达式如下。

$$\begin{aligned} \min f_2 &= \min \Delta V_{\text{total}} \\ &= \min \left[\left(\sum_{i \in L} \rho_i \cdot \frac{|V_i - V_{i,N}|}{V_{i,N}} \right) + \left(\sum_{j \in W} \rho_j \cdot \frac{|V_j - V_{j,N}|}{V_{j,N}} \right) + \left(\sum_{k \in G} \frac{|V_k - V_{k,N}|}{V_{k,N}} \right) \right] \\ &\quad \begin{cases} \rho_i = P_i / P_{\text{load}} \\ \rho_j = P_j / P_{\text{wind}} \end{cases} \end{aligned} \quad (2)$$

式中: ρ_i 、 ρ_j 分别为负荷节点*i*和风机节点*j*的权重; P_i 、 P_j 、 P_{load} 和 P_{wind} 分别为负荷节点*i*的有功功率、风机节点*j*的有功功率、所有负荷的总有功功率、所有风机发出的总有功功率; V_i 、 V_j 、 V_k 分别为负荷节点*i*、风机节点*j*和传统发电机节点*k*的电压; $V_{i,N}$ 、 $V_{j,N}$ 、 $V_{k,N}$ 分别为负荷节点*i*、风机节点*j*和传统发电机节点*k*的额定电压; L 、 W 和 G 分别为负荷、风机和传统发电机的集合。

1.3 电力系统潮流约束

$$\begin{cases} P_{Gi} + P_{Wi} - P_{Li} - V_i \sum_{j=1}^{N_b} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_{Gi} + Q_{Wi} - Q_{Li} - V_i \sum_{j=1}^{N_b} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (4)$$

式中: N_n 为系统节点数量; P_{Gi} 和 Q_{Gi} 分别为传统发电机节点*i*的有功功率出力和无功功率出力; P_{Wi} 和 Q_{Wi} 分别为风机节点*i*的有功功率出力和无功功率出力; P_{Li} 和 Q_{Li} 分别为负荷节点*i*的有功功率和无功功率; B_{ij} 为节点*i*和*j*之间的电纳。

1.4 安全运行约束

$$\begin{cases} V_i^{\min} \leq V_i \leq V_i^{\max}, i = 1, 2, \dots, N_n \\ I_i \leq I_i^{\max}, i = 1, 2, \dots, N_b \end{cases} \quad (5)$$

式中: $V_i^{\min}$ 和 $V_i^{\max}$ 分别为母线节点*i*允许的最小和最大电压值; $I_i^{\max}$ 为支路*i*允许流过的最大电流。

1.5 控制变量约束

$$\begin{cases} Q_{ci, \min} \leq Q_{ci} \leq Q_{ci, \max}, i \in N_C \\ Q_{ri, \min} \leq Q_{ri} \leq Q_{ri, \max}, i \in N_R \\ T_{i, \min} \leq T_i \leq T_{i, \max}, i \in N_T \end{cases} \quad (6)$$

式中: Q_{ci} 、 Q_{ri} 、 T_i 分别为电容器*i*的容量、电抗器*i*的容量、可调变压器*i*的档位; $Q_{ci, \min}$ 、 $Q_{ri, \min}$ 、 $T_{i, \min}$ 分别为电容器*i*的容量、电抗器*i*的容量、可调变压器*i*档位的下限; $Q_{ci, \max}$ 、 $Q_{ri, \max}$ 、 $T_{i, \max}$ 分别为电容器*i*的容量、电抗器*i*的容量、可调变压器*i*档位的上限; N_C 、 N_R 、 N_T 分别为电容器补偿点数量、电抗器补偿点数量、可调变压器数量。

2 无功功率优化问题的图定义

2.1 无功功率优化问题的图表示

无功功率优化问题本质上是混合整数非线性规划(mixed-integer nonlinear programming, MINLP)问题。一般MINLP问题的数学表达式如式(7)所示。

$$\begin{cases} \min f(\mathbf{x}_0, \mathbf{y}_0) \\ \text{s.t. } h(\mathbf{x}_0, \mathbf{y}_0) = 0 \\ g(\mathbf{x}_0, \mathbf{y}_0) < 0 \\ \mathbf{x}_0 \in \mathbb{R}^p, \mathbf{y}_0 \in \mathbb{Z}^q \end{cases} \quad (7)$$

式中: $f(\mathbf{x}_0, \mathbf{y}_0)$ 为目标函数; $h(\mathbf{x}_0, \mathbf{y}_0) = 0$ 和 $g(\mathbf{x}_0, \mathbf{y}_0) < 0$ 分别为等式约束和不等式约束; $\mathbf{x}_0$ 为

维连续变量, $\mathbb{R}$ 为实数集合; $\mathbf{y}_0$ 为

维的整数变量; $\mathbb{Z}$ 为整数集合; p 、 q 分别为连续变量与整数变量的维度。

由于式(7)中的目标函数或约束中含有非线性成分,且它们的数学表达式均采用函数来表示,不便于显示数学表达式中的元素。为了便于研究,通常将MINLP的表达式转换为混合整数线性规划(mixed-integer linear programming, MILP)的表现形式。假定转换后的数学表达式如式(8)所示。

$$\begin{cases} \min f(x) = z^T x \\ \text{s.t. } Bx \circ c \\ l \leq x \leq u \\ x_j \in \mathbb{Z}, \forall j \in I \end{cases} \quad (8)$$

式中: $z^T \in \mathbb{R}^n$ 为目标函数的行向量系数; $B \in \mathbb{R}^{m \times n}$ 为约束系数矩阵; $c \in \mathbb{R}^m$ 为约束右端向量; $\circ \in \{\leq, =, \geq\}$ 为运算符; $l \in (\mathbb{R} \cup \{-\infty\})^n$ 和 $u \in (\mathbb{R} \cup \{+\infty\})^n$ 分别为变量 x 的上下限; 索引集 $I \in \{1, 2, \dots, n\}$ 包含索引 j , 其中 x_j 为整数变量; m 和 n 分别为约束数量和变量数量。

本文采用带顶点特征的加权二部图表示 MINLP 问题。加权二部图 $G = (S \cup D, E)$ 包含顶点集 S 、 D 和边集 E , 顶点集满足 $S \cap D = \emptyset$ 且 $S \cup D =$ 所有顶点, 边集 E 中的边分别连接顶点集 S 中的一个点和顶点集 D 中的一个点。假定顶点集 S 中有 k 个顶点, $S = \{s_1, s_2, \dots, s_k\}$, 其中 s_i 表示第 i 个约束。顶点集 D 中有 h 个顶点, $D = \{d_1, d_2, \dots, d_h\}$, 其中 d_j 表示第 j 个变量。

为了将 MINLP 的数学模型映射到图中, 在加权二部图的基础上为每个顶点赋予一个特征向量: 将特征向量 $f_i^s = (c_i, \circ_i)$ 赋予顶点集 S 中的顶点, 特征向量 $f_j^d = (z_j, l_j, u_j, \gamma_j)$ 赋予顶点集 D 中的顶点。其中, c_i 和 $\circ_i$ 分别为第 i 个约束的右端常数项和运算符; z_j 、 l_j 和 u_j 分别为第 j 个变量在目标函数中的系数、上限值和下限值; $\gamma_j = 1$ 表示第 j 个变量为整数变量, $\gamma_j = 0$ 表示第 j 个变量为连续变量。 f_i^s 属于空间 $\mathcal{F}^s = \mathbb{R} \times \{\leq, =, \geq\}$, f_j^d 属于空间 $\mathcal{F}^d = \mathbb{R} \times (\mathbb{R} \cup \{-\infty\}) \times (\mathbb{R} \cup \{+\infty\}) \times \{0, 1\}$, 边集 $E_{ij} = B_{ij} \in \mathbb{R}$ 。注意, 当约束 s_i 和变量 d_j 之间没有联系时, 对应边的值为 0。最后, 定义特征集 $F = (f_1^s, f_2^s, \dots, f_k^s, f_1^d, f_2^d, \dots, f_h^d) \in F_k^s \times F_h^d$, $\mathcal{G}_{k,h}$ 表示加权二部图 $G = (S \cup D, E)$, 则带顶点特征的加权二部图为 $(G, F) \in \mathcal{G}_{k,h} \times F_k^s \times F_h^d$ 。通过上述方法得到一般 MINLP 问题的特征与图之间的关联, 构建出了 MINLP 问题的图, 简称为“MINLP-图”。下面以一个 MINLP 问题案例展示 MINLP-图。

假定原 MINLP 问题转换为混合整数线性规划的数学表达式如式(9)所示, 其中 x_1 、 x_2 为连续变量, x_3 为整数变量。该 MINLP 问题的图表示如图 1 所示。图中左边和右边的顶点分别表示约束和变量, 边集 B 中的元素为约束中变量的系数。

$$\begin{cases} \min (x_1 + x_2 + x_3) \\ \text{s.t. } x_1 + 2x_2 \geq 8 \\ x_2 + x_3 \geq 2 \\ x_1 + 3x_3 \geq 6 \\ x_1 \leq 49, x_2 \leq 63, x_3 \leq 81 \\ x_1, x_2 \in \mathbb{R}, x_3 \in \mathbb{Z} \end{cases} \quad (9)$$




图 1 一个 MINLP-图的示例

Fig. 1 Example of a MINLP-graph

2.2 基于优化问题的边集矩阵构建

图卷积网络 (graph convolutional network, GCN) 是一种用于处理图结构数据的神经网络模型, 其基本组成为节点和边^[21]。其中一个节点代表图中的一个元素, 边表示节点之间的连接关系。GCN 通过在图形数据上进行卷积可以捕捉图结构信息和节点之间的关联。其中图卷积的数学公式如式(10)所示。

$$H^{l+1} = \sigma(D^{-\frac{1}{2}} \hat{A} D^{-\frac{1}{2}} H^l W^l) \quad (10)$$

式中: H^{l+1} 为 GCN 第 l 层经卷积操作后输出的信息; H^l 为第 l 层的输入信息; $\hat{A} = A + I$, A 为邻接矩阵, I 为单位阵; D 为度矩阵; W^l 为第 l 层的权重矩阵; $\sigma(\cdot)$ 为激活函数。

在电力系统中, 无功功率优化问题不仅依赖于网络的拓扑结构 (即节点间的连接关系), 还受到支路物理参数的显著影响。将无功功率优化问题映射到图中后, 其邻接矩阵中的元素已经发生改变。本文采用基于一阶泰勒展开的雅可比矩阵线性化方法, 以电压幅值和相角的增量为优化变量实现问题的线性建模。采用边集矩阵 B 代替传统的邻接矩阵, 结合上述的无功功率优化模型可知, 由于有功功率、无功功率、电压、相角均为变量, 所以对于无功功率电压优化问题而言, 系数是节点 i 、 j 之间的电导 G_{ij} 和电纳 B_{ij} 。基于此, 图卷积网络的映射函数为:

$$Y = f(\phi(X, A)W + b) \quad (11)$$

式中: X 为输入特征矩阵; A 为上述重构后的邻接

矩阵,元素为节点 i 、 j 之间的电导 G_{ij} 和电纳 B_{ij} ; $\phi(\cdot)$ 为非线性激活函数; $\mathbf{W}$ 、 $\mathbf{b}$ 为可训练参数; $f(\cdot)$ 为图神经网络的映射函数; $\mathbf{Y}$ 为输出结果。

通过激活函数对聚合后的特征进行非线性变换,进一步增强模型对复杂非线性关系的建模能力。以节点间的电导和电纳作为边的权重,这种重构后的邻接矩阵不仅反映了电力系统的物理连接,还通过边的权重量化了节点间的电气特性。为此本研究通过重构邻接矩阵将支路的电导和电纳作为边权重,使GCN能够更准确地捕捉电力系统的物理特征。

3 基于GCN的多目标无功功率优化模型求解和最优解选取

基于GCN的多目标优化算法的求解思路如下:首先,输入数据,利用训练好的GCN模型求解得到最优解集。然后,利用改进CRITIC-AHP-TOPSIS组合赋权算法从最优解集中筛选得到最优解,获得实时优化策略。基于GCN的无功功率优化研究的框架如图2所示。




图2 基于GCN的无功功率优化研究的框架

Fig.2 Framework of reactive power optimization research based on GCN

3.1 基于GCN的无功功率优化模型求解

对于本文所提算法,设定的GCN结构包含输入层、五层卷积层、两个全连接层和输出层,结构如图3所示。

通过利用历史数据,GCN能够在监督学习框架下挖掘电力系统中的隐含模式,从而揭示节点特征、拓扑结构与无功功率优化策略之间的关联性。其具体实现步骤如下。

1)输入数据。输入电力系统运行数据(负荷功




图3 GCN结构图

Fig.3 GCN structure diagram

率、风机功率、传统发电机功率)、拓扑结构和边集矩阵,以及所对应的无功功率优化策略。考虑到由于GCN在训练中可能对负值标签表现不稳定,因此将原始的 $[-4, 4]$ 档位值映射至 $[0, 8]$ 区间离散类别,使其适应神经网络分类任务框架。其中,在训练GCN之前,通过独立重复运行30次多目标鲸鱼优化算法,筛选出最佳的控制策略,实现给每个训练样本添加真实标签,即相应的无功功率优化策略。

2)设置GCN结构和参数。对于结构中的卷积层,每层卷积层含有16个卷积核,激活函数为LeakyReLU。利用多个图卷积层自动获取负荷、风机和传统发电机节点的特征,再经过激活函数进行非线性化的各个节点特征,经过全局平均池化得到整个图的表示作为全连接层的输入。对于每个节点来说,特征维度通过五层图卷积网络结构逐层向上扩展($4 \rightarrow 16 \rightarrow 32 \rightarrow 64 \rightarrow 128 \rightarrow 384$),使得模型具备足够的表达能力来描述复杂的状态空间关系和提取更丰富的非线性特征表示。

3)图卷积网络的训练。对于GCN的训练过程,主要利用GCN输出的预测值和预设的实际值之间的差值来计算损失函数和更新网络权重,从而进行反向传播。全连接层输出的是未归一化的得分值,在损失计算过程中,通过Softmax函数将这些未归一化得分转换为概率分布,Softmax确保所有可能动作的概率总和为1。本文采用交叉熵损失函数评估预测值与真实值之间的差异,通过多次迭代,当损失函数的值趋近于一个很小且趋于稳定的值时,所提算法即可学会输入数据到输出数据的映射规律。

在推理阶段,图卷积网络模型的主要计算复杂

度来源于节点特征的聚合和线性映射。每层图卷积的时间复杂度可近似表示为：

$$O(E \times d_{in}) + O(N_n \times d_{in} \times d_{out}) \quad (12)$$

式中： $O(\cdot)$ 为渐进时间复杂度，用于刻画算法随输入规模变化的计算复杂度上界； N_n 为节点数量； E 为边数； d_{in} 和 d_{out} 分别为输入与输出特征维度。

对于整个GCN模型的推理复杂度近似为：

$$O\left(\sum_{i=1}^5 (E \times d_i + N_n \times d_i \times d_{i+1})\right) + O(d_5 \times D_{dense}) \quad (13)$$

式中： d_i 为第 i 层的输入特征维度； d_5 为最后一层卷积输出的特征维度； D_{dense} 为全连接层输出的总维度。由于图结构在初始化阶段构建完成，推理过程中仅需加载信息，加载耗时极短，通常为毫秒级。数据加载和池化操作复杂度为 $O(N_n + E)$ 和 $O(N_n)$ ，相较于卷积和全连接操作可忽略。

具体而言，尽管输出层计算的时间复杂度为 $O(d_5 \times D_{dense})$ ，但随着电网规模的增大特征聚合部分的时间占比在推理阶段随着电网规模的增大逐渐提高。结合实际电力系统规模，当节点数 N_n 和边数 E 增加时，推理复杂度呈现近似线性增长趋势。由于特征维度 d_{max} 保持不变，系统规模的增大主要导致推理耗时按节点数 N_n 和边数 E 成比例增加，整体仍可满足实时性优化的要求。

3.2 基于改进CRITIC-AHP-TOPSIS组合赋权算法的最优解选取

基于GCN算法求解得到了一组最优解集，还需要从中选取一个解作为最终解。常用的选择方法有随机选择法和权重系数法^[22]。但是，随机选择法随机选择的偶然性较大，而权重系数法难以确定各优化目标的权重值。针对该问题，本文提出一种基于改进CRITIC-AHP-TOPSIS组合赋权算法的最优解选取方法，实现从最优解集中筛选得到最终解。其中，最优解选取时，首先采用改进CRITIC算法得到客观权重，并采用文献[23]中的层次分析法(analytic hierarchy process, AHP)计算主观权重；然后，基于主客观权重的组合得到综合权重；最后，采用逼近理想解排序法(technique for order preference by similarity to ideal solution, TOPSIS)对综合权重集进行综合评价，反映各组解之间的差距，并得到最终解。

3.2.1 CRITIC算法的改进

CRITIC算法^[24]是一种依据数据给评价对象赋予客观权重的方法，该方法能够同时考虑评价对象间的差异性和相关性。然而，该算法存在两方面问题：1)采用均方差计算差异性时其结果易受到指标均值的影响；2)算法中采用皮尔逊相关系数计算相关性，而该相关系数仅适用于符合正态分布的数据，其在电力系统领域的实用性不强。针对上述问题，本节对CRITIC算法做如下改进：1)采用相对离散度表征差异性克服均方差易受指标均值影响的不足；2)采用斯皮尔曼等级相关系数表征相关性解决对数据分布的硬性要求。假设有 X 和 Y 两组数据，相对离散度和斯皮尔曼等级相关系数的数学表达式分别如式(14)–(15)所示。

$$V_j = \sum_{i=1}^N |c_{ij} - \bar{c}_j| / (N \bar{c}_j) \quad (14)$$

$$\rho_{jj'} = \frac{\sum_{i=1}^N (R_{ij} - \bar{R}_j)(R_{ij'} - \bar{R}_{j'})}{\sqrt{\sum_{i=1}^N (R_{ij} - \bar{R}_j)^2 \sum_{i=1}^N (R_{ij'} - \bar{R}_{j'})^2}} \quad (15)$$

式中： V_j 为第 j 个评价指标的相对离散度； c_{ij} 为第 i 个评价对象的第 j 个评价指标的值； $\bar{c}_j$ 为第 j 个评价指标的平均值； N 为总的观测样本量； $\rho_{jj'}$ 为指标 j 和 j' 的相关系数； R_{ij} 和 $R_{ij'}$ 分别为评价对象 i 的指标 j 和 j' 的取值的等级； $\bar{R}_j$ 和 $\bar{R}_{j'}$ 分别为变量 X 和 Y 的平均等级。

3.2.2 基于TOPSIS的综合评价模型

假定基于改进CRITIC算法得到的指标 j 的客观权重为 W_1^j ，基于AHP算法得到的指标 j 的主观权重为 W_2^j ，则综合权重 W_3^j 的数学表达式如式(16)所示。

$$W_3^j = (W_1^j \times W_2^j) / \sum_{j=1}^r (W_1^j \times W_2^j) \quad (16)$$

式中 r 为评价指标的数量。

TOPSIS综合评价的步骤如下。

1)采用灰色关联度分析法^[25]对原指标进行规范化处理，得到规范化矩阵 F 。然后将综合权重 W 和矩阵 F 相乘得到加权矩阵 E 。

2)计算加权矩阵 E 的正、负理想解 E^+ 、 E^- 。其数学表达式如下。

$$\begin{cases} E^+ = (\max_{1 \leq i \leq m} e_{ij} | j \in j^+, \min_{1 \leq i \leq m} e_{ij} | j \in j^-) \\ \quad = (e_1^+, e_2^+, \dots, e_m^+) \\ E^- = (\max_{1 \leq i \leq m} e_{ij} | j \in j^-, \min_{1 \leq i \leq m} e_{ij} | j \in j^+) \\ \quad = (e_1^-, e_2^-, \dots, e_m^-) \end{cases} \quad (17)$$

式中: e_{ij} 为加权矩阵 E 的元素, 表示第 i 个评价对象在第 j 个指标上的值; $\max_{1 \leq i \leq m} e_{ij} | j \in j^+$ 表示为当 $j \in j^+$ 时, 对 e_{ij} 在 $i \in [1, m]$ 范围内求最大值; j^+ 和 j^- 分别为正向指标和负向指标; m 为评价对象的数量; e^+ 、 e^- 分别为正负理想解, 为各评价指标的最优值组合和最劣值组合。

3) 计算评价对象的欧式距离, 并得到综合评估指数。第 i 个评价对象到正、负理想解的欧氏距离 d_i^+ 、 d_i^- 分别为:

$$\begin{cases} d_i^+ = \sqrt{\sum_{j=1}^n (e_{ij} - e_j^+)^2}, (i = 1, 2, \dots, m) \\ d_i^- = \sqrt{\sum_{j=1}^n (e_{ij} - e_j^-)^2}, (i = 1, 2, \dots, m) \end{cases} \quad (18)$$

4) 各评价对象的综合评估指数如下。

$$f_i = d_i^- / (d_i^+ + d_i^-) \quad (i = 1, 2, \dots, m) \quad (19)$$

式中 f_i 为第 i 个评价对象的综合评价指数, 反映其接近正理想解的程度。 f_i 的值越大, 则该评价对象的表现越好。

4 算例分析

4.1 仿真参数

为验证所提算法的可行性和优越性, 以改进的 IEEE 39 节点系统和某地区实际电网为例进行验证和分析 (见附录 A)。改进的 IEEE 39 节点系统中, 以 Matpower 7.0 自带的标准 IEEE-39 系统为基础, bus32、bus35、bus37、bus38 和 bus39 处的发电机替换为风机, 其对应的有功功率分别为 650 MW、650 MW、1 395 MW、830 MW、1 000 MW。同时, 移除风机母线处的负荷。潮流收敛时改进的 IEEE 39 节点系统的风电渗透率为 70 % 电容器所在母线为 bus3-bus8、bus12, 电抗器所在母线为 bus1-bus2、bus9、bus25-bus29。其中所有可调变压器的变比调节范围设定在 0.9~1.1 之间, 以 1 为中心, 每步调节幅度为 ± 0.025 , 共分为 9 个档位。在配置有电容器或电抗器的节点上, 每处最多可安装 15 组无功功率设备, 每组容量均为 10 Mvar。日最大动作次数均为 12 次。

对于本文所使用的数据集, 本文设定负荷符合正态分布, 波动范围为 $[-15\%, 15\%]$, 而风速服从双参数威布尔分布, 并根据风速与功率的函数关系计算, 反映了风力涡轮机在不同风速区间的实际运行特性, 波动范围为 $[-20\%, 10\%]$ 。根据以上

设定通过 Monte Carlo 法进行模拟生成大量的风电出力和负荷需求的场景。对于生成的大量的运行算例经过潮流计算进行数据清洗后得到所需的数据集。其中 70 % 的样本作为训练集, 验证集和测试集的样本各占 15 %。

所提方法均在 win10 操作系统的 PyCharm 平台下运行, 所用的深度学习的框架包括 PyTorch 2.4.1 和 PyTorch Geometric 2.6.1。

4.2 改进的 IEEE 39 节点系统性能分析

将所提基于 GCN 的多目标无功功率优化算法 (multi-objective graph convolution network, MOGCN) 分别与以下 3 种算法进行对比: 多目标粒子群优化算法 (multi-objective particle swarm optimization, MOPSO)、非支配排序遗传算法 (non-dominated sorting genetic algorithms-II, NSGA-II)、多目标灰狼算法 (multi-objective grey wolf optimization, MOGWO)。下面分别从 GCN 的收敛性能和求解速度、最优解的选取、节点重要性对比和无功功率优化效果 4 个角度进行对比分析。

4.2.1 GCN 的收敛性能和求解速度

为了了解 GCN 训练的收敛性和训练好的 GCN 模型的求解速度, 以 GCN 的损失函数曲线和任一待优化时刻的算法求解速度进行展示。图 4 为 GCN 的损失函数随迭代次数的变化曲线, 表 1 为 4 种算法的求解速度对比。对于评估 GCN 模型的综合性能, 采用 F1 分数^[26] 指标进行评估, 表 2 为部分类别的精确率、召回率和 F1 分数 3 个典型分类评价。表 3 为各类指标的宏平均值和加权平均值, 评价模型整体性能表现。

根据图 4 可知, GCN 的损失函数随迭代次数的




图4 损失函数的变化过程

Fig. 4 Change processes of loss function

表 1 4 种算法的求解速度对比

Tab. 1 Comparison of the solving speed of four algorithms

算法	训练时长/h	日决策时长/s
MOGCN	2.1	0.069
MOPSO	0	122.518
NSGA-II	0	150.305
MOGWO	0	154.729

表 2 部分类别性能指标评估结果

Tab. 2 Evaluation metrics for representative categories

类别	精确率	召回率	F1 分数
0	0.948 2	0.958 6	0.953 3
1	0.891 7	0.893 6	0.892 7
2	0.924 0	0.911 1	0.917 5
3	0.919 2	0.910 1	0.914 6
4	0.919 7	0.916 3	0.918 0

表 3 模型分类性能宏平均与加权平均指标

Tab. 3 Macro and weighted average evaluation metrics

评价指标	精确率	召回率	F1 分数
宏平均	0.923 8	0.925 7	0.924 6
加权平均			0.932 2

增加逐步下降, 经 1 600 轮训练后, 损失函数趋于平稳, 说明此时算法已经收敛。为了保证 GCN 能够收敛, 设定迭代次数达到 1 800 次后再将 GCN 用于无功功率优化。

根据表 1 可知, 相对于其他 3 种传统的智能优化算法, MOGCN 算法需要花费较多时间进行训练; 但决策速度是衡量算法优良性的重要指标, 使用离线训练好的 GCN 模型进行求解时, 其仅需 0.069 s 即可实现优化。相比其他传统的智能优化算法的 2 ~ 3 min 求解时间, 本文所提算法在求解速度方面具有显著的优势, 其在应对日内实时的优化问题时, 可以辅助系统运行人员快速得到所需结果。

由表 2 可知模型在不同类别上均表现出较好的性能且在各个类别上的表现相对均衡。从表 3 所示的宏平均和加权平均指标可以看出, 模型的整体分类性能较为稳定, 其中宏平均 F1 (92.46 %) 和加权平均 F1 (93.22 %) 非常接近, 说明模型在处理类别不平衡问题上表现良好, 且各项指标高达 92 % 以上, 进一步验证了所提模型在多类别复杂场景下的有效性和鲁棒性。

4.2.2 最优解的选取

为了展示最优解的选取过程, 仍以时刻进

行展示。采用 3.2 节的最优解选取方法, 得到基于改进 CRITIC-AHP 算法的各评价指标的权重如表 4 所示, 基于 TOPSIS 算法得到的各评价对象的综合评估指数如图 5 所示。

根据表 4 可知, 基于专家认知得到的两个评价指标的主观权重虽有差异, 但是相差不大, 而基于数据自身信息获得的两个评价指标权重相差较大。因此, 结合主观和客观权重得到的有功功率网损综合权重明显高于电压偏差, 突出了评估过程中有功功率网损指标的重要性。根据图 5 可知, 第 55 个评价对象的综合评估指数最大, 其值为 1。因此, 选择最优解集中的第 55 个解作为最终解。

表 4 各评价指标的权重

Tab. 4 Weights of each evaluation index

评价指标	主观权重	客观权重	综合权重
有功功率网损	0.522 2	0.643 4	0.663 5
电压偏差	0.477 8	0.356 6	0.336 5




图 5 各评价对象的综合评估指数

Fig. 5 Comprehensive evaluation index of each evaluation object

4.2.3 节点重要性对比分析

为了验证本文设计的考虑权重的电压偏差指标能否给重要的节点以更高的优先级, 将所提电压偏差指标与不考虑权重的电压偏差指标进行对比分析, 得到两种目标函数下的电压优化结果如表 5 所示。其中, 表 5 中以有功功率最大的前 5 个负荷节点和前两个风机节点为例进行展示。

根据表 5 可知, 当采用本文设计的带权重的电压偏差指标时, 得到的重要节点的电压值更接近 1 p.u., 表明其获得了更好的电压分布。这说明了本

表 5 不同目标函数下电压对比

Tab. 5 Voltage comparison under different objective functions

节点类型	母线号	有功功率/ MW	有权重的电压/ p. u.	无权重的电压/ p. u.
负荷	7	833.8	1.011	1.026
	8	822.0	1.014	1.018
	20	680.0	1.002	1.011
	4	600.0	1.012	1.027
	16	329.0	1.016	1.019
风机	37	1 395.0	1.013	1.021
	39	1 000.0	1.031	1.037

文设计的电压偏差指标可以在无功功率优化时给予重要的节点以更高的电压调整优先级。

4.2.4 无功功率优化性能对比分析

为了对比算法的优化性能, 以 5 min 为一个优化时刻, 采用 4 种优化算法连续优化 24 个时刻, 得到有功功率网损和电压偏差的平均值如表 6 所示。

表 6 不同算法的有功功率网损和电压偏差的平均值

Tab. 6 Average values of active power loss and voltage deviation under different algorithms

目标函数	电压偏差/p. u.	有功功率网损/MW
MOGCN	0.022	51.605
MOPSO	0.027	55.313
NSGA-II	0.026	51.037
MOGWO	0.028	50.930

根据表 6 可知, 所提算法能够获得最小的电压偏差, 其平均电压偏差比 MOPSO、NSGA-II 和 MOGWO 算法分别低了 18.5 %、15.4 % 和 21.4 %。同时, 所提算法得到的有功功率网损平均值处于其他 3 种对比算法之间, 其仅比 NSGA-II 和 MOGWO 算法分别高了 1.1 %、1.3 %。所以, 根据 24 个时刻的整体优化效果可知, 本文所提 MOGCN 算法能够兼顾获得理想的有功功率网损和电压偏差, 其无功功率优化性能更优。

为了对比和分析电压分布情况, 利用 4 种优化算法, 得到各节点在 24 个时刻下的电压平均值如图 6 所示。

根据图 6 可知, 4 种算法优化后的各节点电压平均值均在允许范围内, 且 MOGCN 算法优化后的各节点电压平均值更接近于 1 p. u., 说明所提 MOGCN 算法能够获得更好的电压分布。此外, 另外 3 种算法的电压优化效果各有优劣, 整体上




图 6 各节点在 24 个时刻下的电压平均值

Fig. 6 Average voltage of each node in 24 moments

MOPSO 算法的电压优化性能优于 NSGA-II 和 MOGWO 算法。

4.3 实际电网性能分析

为了进一步验证本文所提算法在大系统上的无功功率优化性能, 本节以某地区实际电网为例进行验证和分析。该实际电网共有 810 个母线节点, 764 个负荷, 977 条支路, 48 个发电机节点(含风电), 负荷总有功功率和总无功功率分别为 16 934.15 MW、3 691.02 Mvar, 系统电压等级包括 500 kV、220 kV、110 kV、66 kV、35 kV 及以下。研究中针对 110 kV 等级及以上的母线节点电压进行优化和观察。

1) 节点重要性对比分析

采用与改进 IEEE 39 节点系统相同的方法验证所提考虑权重的电压偏差指标是否有效。两种目标函数下的电压优化结果如表 7 所示。其中, 表 7 中以有功功率最大的前 5 个负荷节点和前 4 个风机节点为例进行展示。

根据表 7 可知, 带权重的电压偏差指标得到的重要节点的电压值更接近 1 p. u., 具有更好的电压分布。

2) 为了对比所提算法的优化性能, 仍采用四种优化算法连续优化 24 个时刻, 得到有功功率网损和电压偏差的平均值如表 8 所示。

根据表 8 可知, 所提 MOGCN 算法能够获得最小的电压偏差, 其平均电压偏差比 MOPSO、NSGA-II 和 MOGWO 算法分别低了 25.0 %、28.0 % 和 14.3 %。同时, MOGCN 算法得到的有功功率网损平均值处于其他 3 种对比算法之间, 其仅

表 7 不同目标函数下电压对比

Tab. 7 Voltage comparison under different objective functions

节点类型	母线编号	有功功率/ MW	有权重的电压/ p. u.	无权重的电压/ p. u.
负荷	807	575.5	1.009	1.026
	810	440.2	1.007	1.028
	806	264.4	1.011	1.021
	205	137.2	1.018	1.023
	124	117.0	1.012	1.019
风机	281	1 000.0	1.002	0.996
	575	1 000.0	0.999	0.994
	576	1 000.0	1.002	0.990
	593	500.0	1.003	1.017

表 8 不同算法的有功功率网损和电压偏差的平均值

Tab. 8 Average values of active power loss and voltage deviation under different algorithms

目标函数	电压偏差/p. u.	有功功率网损/MW
MOGCN	0.036	76.196
MOPSO	0.048	81.259
NSGA-II	0.050	75.850
MOGWO	0.042	76.154

比 NSGA-II 和 MOGWO 算法分别高了 0.5 %、0.1 %。所以, 根据 24 个时刻的整体优化效果可知, 所提算法能够兼顾获得理想的有功功率网损和电压偏差。

综上, 本文所提 MOGCN 算法能够兼顾获得理想的有功功率网损和电压偏差。同时, 本文所提算法直接映射得到最优解集, 有效避免了传统智能优化算法易陷入局部最优解的问题。因此, 本文所提算法既可以保障系统电压的安全性, 又可以兼顾到系统运行的经济性。

5 结论

本文针对电力系统日内实时的无功功率优化问题, 提出了一种基于图卷积网络的多目标无功功率优化求解方法, 其具有以下特点。

1) 构建了考虑节点重要性的无功功率优化模型, 并将无功功率优化问题映射到图特征上。同时, 结合实际问题重构邻接矩阵, 实现物理问题与图神经网络的有效融合。

2) 所提算法能够直接映射出最优解集, 具有更快的求解速度, 并可以有效避免智能优化算法易陷

入局部最优解等问题。

3) 所提最优解选取算法, 既保留了专家对指标重要性的认知信息, 也保留了数据自身反映的客观信息, 为最优解的选取提供了兼顾多方面信息的方法, 辅助电网运行人员获得实时的优化策略。

4) 与 MOPSO、NSGA-II 和 MOGWO 方法相比, 所提方法能够兼顾获得理想的有功功率网损和电压偏差, 保障了新型电力系统运行的安全性和经济性。

鉴于当前方法基于离线生成的最优解标签进行训练, 其在应对未知场景或突发性负荷与出力变化时仍有进一步增强适应能力的空间。为此, 未来的研究着眼于构建更加灵活的优化框架, 特别是通过引入强化学习(reinforcement learning, RL)或元学习(Meta-learning)等技术, 使得优化过程可以在没有离线标签的情况下直接根据实时的系统状态进行动态调整, 提升电力系统在实际运行中的自适应能力。

参考文献

- [1] 舒印彪, 赵勇, 赵良, 等. “双碳”目标下我国能源电力低碳转型路径[J]. 中国电机工程学报, 2023, 43(5): 1663–1671.
SHU Yinbiao, ZHAO Yong, ZHAO Liang, et al. Study on low carbon energy transition path toward carbon peak and carbon neutrality[J]. Proceedings of the CSEE, 2023, 43(5): 1663–1671.
- [2] 韩旭杉, 王维洲, 时帅, 等. 高占比新能源电源接入区域电网的无功优化策略研究[J]. 上海电力大学学报, 2022, 38(3): 251–263.
HAN Xushan, WANG Weizhou, SHI Shuai, et al. Study on reactive power optimization strategy of high proportion new energy sources connected to regional power grid[J]. Journal of Shanghai University of Electric Power, 2022, 38(3): 251–263.
- [3] 杨蕾, 李胜男, 黄伟, 等. 基于平衡优化器的含高比例风光新能源电网无功优化[J]. 电力系统及其自动化学报, 2021, 33(4): 32–39.
YANG Lei, LI Shengnan, HUANG Wei, et al. Reactive power optimization of power grid with high-penetration wind and solar renewable energies based on equilibrium optimizer[J]. Proceedings of the CSU-EPSA, 2021, 33(4): 32–39.
- [4] 孙秋野, 李大双, 王睿, 等. “双高”电力系统: 一种新的稳定判据和稳定性分类探讨[J]. 中国电机工程学报, 2024, 44(8): 3016–3036.
SUN Qiuye, LI Dashuang, WANG Rui, et al. “Double-high” power systems: a new stability criterion and discussion on stability classification[J]. Proceedings of the CSEE, 2024, 44(8): 3016–3036.
- [5] 薛霖, 牛涛, 方斯顿, 等. 计及高比例风电暂态电压安全的主从协同动态无功优化方法[J]. 电力系统自动化, 2023, 47(17): 57–66.

- XUE Lin, NIU Tao, FANG Sidun, et al. Master-slave cooperative dynamic reactive power optimization method considering transient voltage security of high proportion of wind power[J]. Automation of Electric Power Systems, 2023, 47(17): 57 - 66.
- [6] 贺继锋, 张焱哲, 张涛, 等. 自储能柔性互联配电网多时间尺度无功优化方法[J/OL]. 南方电网技术, 1 - 12[2025 - 07 - 03]. <http://kns.cnki.net/kcms/detail/44.1643.tk.20240730.1606.015.html>.
- HE Jifeng, ZHANG Yanzhe, ZHANG Tao, et al. A multi-time-scale reactive power optimization method for self-energy-storage flexible interconnected distribution networks [J/OL]. Southern Power System Technology, 1 - 12 [2025 - 07 - 03]. <http://kns.cnki.net/kcms/detail/44.1643.tk.20240730.1606.015.html>.
- [7] 路镇铭, 徐英, 仪忠凯, 等. 基于双向安德森加速分解协调算法的输配协同无功优化[J]. 电力系统自动化, 2024, 48(12): 130 - 138.
- LU Zhenming, XU Ying, YI Zhongkai, et al. Transmission and distribution coordinated reactive power optimization based on bidirectional anderson acceleration decomposition coordination algorithm [J]. Automation of Electric Power Systems, 2024, 48(12): 130 - 138.
- [8] 莫静山. 基于LCC-HVDC的交直流系统电压无功优化方法研究[D]. 重庆: 重庆大学, 2021.
- [9] DELGADO J A, BAPTISTA E C. A primal - dual penalty-interior-point method for solving the reactive optimal power flow problem with discrete control variables. [J]. International Journal of Electrical Power & Energy Systems, 2022(138): 107917. 1 - 107917. 10.
- [10] 莫静山, 颜伟, 文旭, 等. 考虑换流站独立控制约束的交直流系统静态无功优化方法[J]. 电力系统自动化, 2021, 45(15): 77 - 84.
- MO Jingshan, YAN Wei, WEN Xu, et al. Optimization method for static reactive power of AC/DC system considering independent control constraints of converter station [J]. Automation of Electric Power Systems, 2021, 45(15): 77 - 84.
- [11] 张杰, 王恒凤, 刘生春, 等. 基于内点法和邻域搜索解耦动态规划法的区域电网动态无功优化方法[J]. 中国电力, 2023, 56(2): 59 - 67.
- ZHANG Jie, WANG Hengfeng, LIU Shengchun, et al. Algorithm for dynamic reactive power optimization of regional power grid based on interior point method and neighborhood search decoupling dynamic programming method [J]. Electric Power, 2023, 56(2): 59 - 67.
- [12] 张晓英, 张艺, 王琨, 等. 基于改进NSGA-II算法的含分布式电源配电网无功优化[J]. 电力系统保护与控制, 2020, 48(1): 55 - 64.
- ZHANG Xiaoying, ZHANG Yi, WANG Kun, et al. Reactive power optimization of distribution network with distributed generations based on improved NSGA-II algorithm [J]. Power System Protection and Control, 2020, 48(1): 55 - 64.
- [13] 马喜平, 甄文喜, 梁琛, 等. 考虑风电场无功潜力的风电集群接入电网双层无功优化[J/OL]. 南方电网技术, 1 - 10[2025 - 07 - 03]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20241205.1447.012.html>.
- MA Xiping, ZHEN Wenxi, LIANG Chen, et al. Bi-level reactive power optimization for wind power cluster grid integration considering the reactive power potential of wind farms [J/OL]. Southern Power System Technology, 1 - 10 [2025 - 07 - 03]. <http://kns.cnki.net/kcms/detail/44.1643.TK.20241205.1447.012.html>.
- [14] 李子健, 郭佩乾, 马宁宁, 等. 融合双重策略粒子群算法的分布式电源配电网无功优化[J]. 南方电网技术, 2022, 16(6): 14 - 22, 81.
- LI Zijian, GUO Peiqian, MA Ningning, et al. Reactive power optimization of distributed power distribution network based on dual strategy particle swarm optimization algorithm [J]. Southern Power System Technology, 2022, 16(6): 14 - 22, 81.
- [15] 杨顺吉, 李庆生, 明志勇, 等. 考虑源荷随机性的配电网多目标概率无功优化[J]. 南方电网技术, 2023, 17(1): 125 - 135.
- YANG Shunji, LI Qingsheng, MING Zhiyong, et al. Multi-objective probabilistic reactive power optimization of distribution network considering source-load randomness [J]. Southern Power System Technology, 2023, 17(1): 125 - 135.
- [16] 陈建华, 阎帅, 张瑶, 等. 基于IPM_intPSO的两阶段动态无功优化算法[J]. 电力自动化设备, 2020, 40(3): 174 - 180.
- CHEN Jianhua, YAN Shuai, ZHANG Yao, et al. Two-stage dynamic reactive power optimization algorithm based on IPM-intPSO [J]. Electric Power Automation Equipment, 2020, 40(3): 174 - 180.
- [17] 王珺, 田恩东, 马建, 等. 基于数据驱动的非全实时观测配电网无功优化方法[J]. 电力建设, 2021, 42(2): 68 - 76.
- WANG Jun, TIAN Endong, MA Jian, et al. A data-driven reactive power optimization method for non-full real-time observation distribution network based on data-driven [J]. Electric Power Construction, 2021, 42(2): 68 - 76.
- [18] 周良才, 周毅, 沈维健, 等. 基于深度强化学习的新型电力系统无功电压优化控制[J]. 电测与仪表, 2024, 61(9): 182 - 189.
- ZHOU Liangcai, ZHOU Yi, SHEN Weijian et al. Novel reactive power and voltage optimal control of power system based on deep reinforcement learning [J]. Electrical Measurement & Instrumentation, 2024, 61(9): 182 - 189.
- [19] 蔡昌春, 程增茂, 张关应, 等. 基于数据驱动的配电网无功优化[J]. 电网技术, 2024, 48(1): 373 - 382.
- CAI Changchun, CHENG Zengmao, ZHANG Guanying, et al. Reactive power optimization of distribution network based on data driven [J]. Power System Technology, 2020, 40(3): 174 - 180.
- [20] 邵美阳, 吴俊勇, 石琛, 等. 基于数据驱动和深度置信网络的配电网无功优化[J]. 电网技术, 2019, 43(6): 1874 - 1885.
- SHAO Meiyang, WU Junyong, SHI Chen, et al. Reactive power optimization of distribution network based on data-driven and deep belief network [J]. Power System Technology, 2019, 43(6): 1874 - 1885.
- [21] DONGMIAN Z, GILAD L. Graph convolutional neural networks via scattering [J]. Applied and Computational Harmonic Analysis, 2020, 49(3): 1046 - 1074.
- [22] ALAN F. Efficient user-oriented Pareto fronts and Pareto archives based on spatial data structures [J]. Swarm and Evolutionary Computation, 2021(65): 1 - 16.
- [23] 凡路平. 基于层次分析法-熵权法的绿色建材综合评价研究[D]. 武汉: 武汉轻工大学, 2023.
- [24] 欧阳森, 杨墨缘. 城市配电网直流化改造对象综合决策[J]. 电网技术, 2021, 45(8): 3145 - 3154.

OUYANG Sen, YANG Moyuan. Comprehensive decision for DC transformation objects of urban distribution network [J]. Power System Technology, 2021, 45(8): 3145 – 3154.

- [25] 曹华珍, 王天霖, 张黎明, 等. 基于组合赋权-TOPSIS 交直流配电网能效评估[J]. 南方电网技术, 2021, 15(3): 55 – 67.
CAO Huazhen, WANG Tianlin, ZHANG Liming, et al. Energy efficiency evaluation of AC/DC distribution network based on combined weighting TOPSIS [J]. Southern Power System Technology, 2021, 15(3): 55 – 67.
- [26] 程翔. 基于机器学习的滚动轴承故障诊断研究[D]. 淮南: 安徽理工大学, 2024.

收稿日期: 2025-02-26

作者简介:

张沛(1972), 男, 通信作者, 教授, 博士生导师, 博士, 研究方向为电力系统调度运行、电力系统规划、新能源预测与消纳, peizhang166@qq.com;

刘晓菲(1989), 男, 博士研究生, 研究方向为电压稳定和控制, lxf68563@163.com;

李文云(1965), 男, 高级工程师(教授级), 硕士, 研究方向为新型电力系统稳定运行和协调控制, lwy6505@sina.com.

附录 A

改进的 IEEE 39 节点系统的单线图如图 A1 所示, 实际电网的单线图(110 kV 及以上电压等级)

如图 A2 所示。




图 A1 改进的 IEEE-39 节点系统单线图

Fig. A1 Single-line diagram of modified IEEE 39-node bus system




图 A2 实际电网的单线图

Fig. A2 Single-line diagram of the actual power grid