

DOI: 10.19783/j.cnki.pspc.231203

基于数据潮流模型的高比例光伏配电网三相不平衡优化

高雪寒¹, 高源¹, 赵健¹, 刘箭², 刘兴业²

(1. 上海电力大学电气工程学院, 上海 200090; 2. 国网浙江省电力有限公司杭州供电公司, 浙江 杭州 310016)

摘要: 随着分布式光伏的大规模接入, 配电网固有的三相不平衡问题日益严重, 给系统的电能质量、经济运行等带来不利影响。此外, 高比例光伏的接入使得配电网的物理结构和运行方式更加复杂多变, 导致当前依赖精确拓扑结构和线路参数的三相不平衡优化方法难以应用。因此, 提出一种基于数据潮流模型的高比例光伏配电网三相不平衡优化方法。首先, 采用基于双阶段注意力机制的循环神经网络方法建立数据潮流模型, 拟合三相潮流约束中变量之间的函数关系。同时, 提出图特征嵌入的方法将部分已知的拓扑信息嵌入到数据潮流模型中以提高拟合精度。其次, 以训练后的数据潮流模型为基础重建配电网三相不平衡优化模型。最后, 通过条件梯度下降方法求解该模型, 以修改的 IEEE33 节点配电网为例, 验证了所提方法的有效性。

关键词: 配电网三相不平衡; 分布式光伏; 潮流模型; 数据驱动; 深度神经网络

Three-phase unbalanced optimization of a distribution network with a high proportion of distributed photovoltaic energy based on a data-driven power flow model

GAO Xuehan¹, GAO Yuan¹, ZHAO Jian¹, LIU Jian², LIU Xingye²

(1. College of Electric Engineering, Shanghai University of Electric Power, Shanghai 200090, China;

2. Hangzhou Power Supply Company, State Grid Zhejiang Electric Power Co., Ltd., Hangzhou 310016, China)

Abstract: With the increasing penetration of distributed photovoltaic energy, the inherent three-phase unbalanced problem of a distribution network is becoming more serious. This brings adverse effects on power quality and economic operation of the system. In addition, a high proportion of photovoltaic leads to a more complex physical structure and operation mode of the distribution network, resulting in it being difficult to apply the current three-phase unbalanced optimization method that relies on precise topology and line parameters. Therefore, this paper proposes a three-phase unbalanced optimization method of a distribution network with a high proportion of photovoltaic based on a data-driven power flow model. First, a dual-stage attention-based recurrent neural network is used to establish the data-driven power flow model, and the functional relationship between the variables in the three-phase power flow constraint is fitted. At the same time, a graph feature embedding method is proposed to embed the partially known topology information into the model to improve the fitting accuracy. Secondly, the three-phase unbalanced optimization model is reconstructed based on a trained data-driven power flow model. Finally, the conditional gradient descent method is used to analyze the model, and a modified IEEE 33-node distribution network is taken as an example to verify the effectiveness of the proposed method.

This work is supported by the National Natural Science Foundation of China (No. 51907114).

Key words: three-phase unbalance of distribution network; distributed photovoltaic; power flow model; data-driven; deep neural network

0 引言

为实现“双碳”目标, 我国正加快构建以新能

源为主体的新型电力系统, 分布式光伏是优化能源结构的主流新能源, 新型电力系统的构建必将促使分布式光伏以极高比例接入配电网^[1-2]。

大量非全相运行的分布式光伏接入后, 配电网非线性负荷和单相负荷的占比增加^[3]; 在低负载时, 光伏逆变器为防止过电压而引起电流回流现象, 导

基金项目: 国家自然科学基金项目资助(51907114); 上海市教育委员会“晨光计划”项目资助(19CG61)

致电网中性点偏移^[4]。这些都会进一步加剧配电网三相不平衡问题，给系统的电压质量、线损管理及设备运行安全性带来诸多挑战^[5]。因此，研究高比例光伏接入下配电网的三相不平衡优化问题具有重要意义。

目前，大多数三相不平衡优化方法以配电网物理模型为基础，需要已知拓扑结构和线路参数。首先，根据配电网物理模型建立潮流约束，感知系统运行状态；然后，基于状态感知建立优化目标函数；最后，通过智能优化算法求解目标函数^[6-8]。相应的优化措施可分为两类。一类措施是负荷侧控制，文献[9-10]以最小化换相次数和三相不平衡度为目标，通过调节负荷侧的自动换相装置合理分配线路容量，并有效降低线损、改善末端电压。另一类措施是系统侧控制，主要通过静止无功补偿器的调节^[11]、网络重构^[12]、光伏逆变器的出力控制^[13]等优化配电网，实现系统无功补偿与三相不平衡的综合治理。

然而，完整且实时的物理模型通常难以获取，因为配电网量测设备不足，无法获取全局的状态估计信息^[14]；大量分布式光伏接入下，配电网为协调光伏出力需要更加频繁地调整拓扑结构^[15]；此外，越来越多的分布式光伏产权归属于用户或代理商，配电网管理系统无法直接获取其实时量测数据^[16]，这些因素使得潮流约束的建立存在困难，以上基于物理模型的优化方法难以有效且广泛地应用到含高比例光伏的配电网中。

另一方面，随着智能终端电表的大规模部署，从用户侧可以获得海量历史量测数据^[17]，通过数据驱动技术对收集到的数据进行分析挖掘，可以不依赖物理模型指导配电网的优化运行。现有基于数据驱动的配电网优化方法主要分为负荷-决策匹配法和负荷-电压拟合法。负荷-决策匹配法采用熵权法^[18]、深度置信网络^[19]法等拟合负荷与优化策略之间的函数关系，即在给定负荷的条件下，输出相应的设备控制策略。文献[20]采用图神经网络的方法，在拟合时考虑网络拓扑结构，提供了更精确的设备调节方案。然而负荷与优化策略之间的函数关系没有物理理论的支撑，并且在建立数据驱动模型时需要给每个时间断面的负荷添加标签。负荷-电压拟合法通过前馈神经网络^[21]、卷积神经网络^[22]等对负荷和电压之间的函数关系进行挖掘，再调整资源出力对电网进行优化。然而现有研究多假设三相完全对称而忽略了三相不平衡问题，且未充分考虑潮流约束变量间的耦合特性，难以通过大量学习训练提高拟合精度。

针对以上问题，本文提出了基于数据潮流模型

的高比例光伏配电网三相不平衡优化方法。首先，定义三相潮流约束中节点功率与电压之间的函数关系，引入基于双阶段注意力机制的循环神经网络(dual-stage attention-based recurrent neural network, DA-RNN)算法，自适应地提取出节点之间电压-功率潮流耦合关系的权重因子，建立数据潮流模型，并通过图特征嵌入方法对已知的拓扑信息进行压缩编码，嵌入到数据潮流模型中以提高拟合精度；其次，基于数据潮流模型，考虑分布式光伏的出力约束，重建配电网三相不平衡优化模型，并利用条件梯度下降方法求解得到光伏逆变器的最优出力策略。最后，以修改的三相 IEEE33 节点网络为例，验证了本文方法的有效性。

1 问题描述

1.1 无精确物理模型参数的配电网

无精确物理模型参数的配电网架构如图 1 中的物理层所示，除了常规的用户节点之外，还有大量分布式光伏接入，对于难以获取精确模型的拓扑结构在图中用虚线表示。随着 AMI 高级量测体系的广泛应用，变压器和用户节点通常配置了智能量测装备，时刻都会生成海量的历史量测数据并上传到数据中心，如实时电压、电流、有功和无功功率等，在图 1 中以蓝色图标及箭头表示，这为数据驱动方法的应用提供了基础。

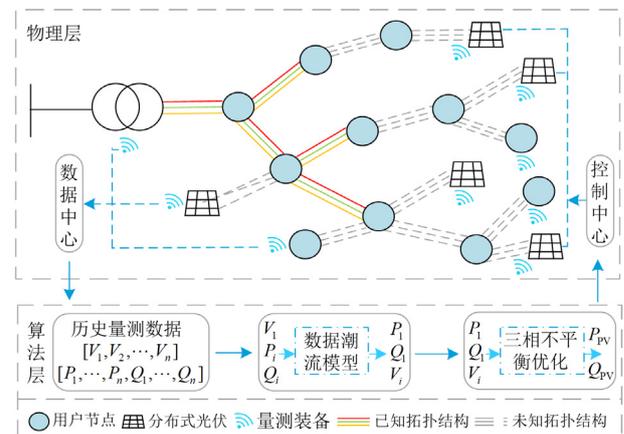


图 1 基于数据潮流模型的三相不平衡优化方法

Fig. 1 Three-phase unbalanced optimization method based on a data-driven power flow model

图 1 中的算法层描述了本方法的关键步骤：首先采集历史量测数据；其次挖掘潮流变量(即 P 、 Q 和 V)之间的函数关系，构建数据潮流模型；最后基于潮流模型实现系统状态至对应潮流结果的直接映射，求解优化模型得到最优光伏出力策略。本文方

法在网络拓扑结构以及线路参数不精确甚至缺失的场景下, 实现配电网的精确建模和智能感知, 从而调节光伏出力来优化配电网三相不平衡问题。

1.2 基于物理模型的配电网三相不平衡优化

1) 目标函数

配电网在三相负载不平衡工况运行时, 某一相的传输功率过高或偏低使该相的线路电压发生偏移甚至越限。电压中存在大量负序分量, 导致用电设备的损耗增加, 影响设备正常运行, 系统的安全运行受到干扰。基于此, 以电压三相不平衡度为目标函数建立优化模型。在配电网物理模型已知的条件下, 优化模型的目标函数为

$$\min F = \min \sum_{i=1}^n U_{\text{VUF},i} \quad (1)$$

$$U_{\text{VUF},i} = \frac{|V_{\text{neg},i}|}{|V_{\text{pos},i}|} = \frac{|V_i^a + \alpha^2 V_i^b + \alpha V_i^c|}{|V_i^a + \alpha V_i^b + \alpha^2 V_i^c|} \quad (2)$$

式中: F 为三相不平衡度(voltage unbalance factor, VUF); n 为网络节点总数; $U_{\text{VUF},i}$ 为节点 i 的三相不平衡度; $V_{\text{neg},i}$ 、 $V_{\text{pos},i}$ 分别为节点 i 的负序、正序电压; V_i^a 、 V_i^b 、 V_i^c 分别为节点 i 的 a、b、c 三相电压; $\alpha = 1 \angle 120^\circ$ 。

2) 三相配电网潮流约束

$$P_i^p = P_{L,i}^p - P_{\text{PV},i}^p = \mu_i^p \sum_{j=1}^n \sum_{m=a}^c (G_{ij}^{pm} \mu_j^m - B_{ij}^{pm} \omega_j^m) + \quad (3)$$

$$\omega_i^p \sum_{j=1}^n \sum_{m=a}^c (G_{ij}^{pm} \omega_j^m + B_{ij}^{pm} \mu_j^m)$$

$$Q_i^p = Q_{L,i}^p - Q_{\text{PV},i}^p = \omega_i^p \sum_{j=1}^n \sum_{m=a}^c (G_{ij}^{pm} \mu_j^m - B_{ij}^{pm} \omega_j^m) + \quad (4)$$

$$\mu_i^p \sum_{j=1}^n \sum_{m=a}^c (G_{ij}^{pm} \omega_j^m + B_{ij}^{pm} \mu_j^m)$$

式中: P_i^p 、 Q_i^p 分别为节点 i 第 p 相注入的有功和无功功率; $P_{L,i}^p$ 、 $Q_{L,i}^p$ 分别为节点 i 第 p 相负载的有功和无功功率; $P_{\text{PV},i}^p$ 、 $Q_{\text{PV},i}^p$ 分别为节点 i 第 p 相光伏的有功和无功功率; μ_i^p 和 ω_i^p 分别为节点 i 第 p 相电压的实部和虚部; G_{ij}^{pm} 和 B_{ij}^{pm} 分别为节点导纳矩阵中节点 i 第 p 相与节点 j 第 m 相对应元素的实部和虚部。

3) 光伏出力约束

光伏逆变器输出的有功和无功满足以下约束关系。

$$P_{\text{PV}}^2 + Q_{\text{PV}}^2 \leq S_N^2 \quad (5)$$

式中: P_{PV} 、 Q_{PV} 分别为光伏逆变器的有功和无无功

率; S_N 为光伏逆变器的额定容量。光伏并网有功和无功功率的调度范围为

$$0 \leq P_{\text{PV},i}^p \leq P_{\text{PV},i}^{p,\max} \quad (6)$$

$$-Q_{\text{PV},i}^{p,\max} \leq Q_{\text{PV},i}^p \leq Q_{\text{PV},i}^{p,\max} \quad (7)$$

$$Q_{\text{PV},i}^{p,\max} = \sqrt{S_N^2 - (P_{\text{PV},i}^p)^2} \quad (8)$$

式中, $P_{\text{PV},i}^{p,\max}$ 、 $Q_{\text{PV},i}^{p,\max}$ 分别为节点 i 第 p 相光伏逆变器有功及无功功率的最大值。

4) 安全运行约束

$$V_i^{p,\min} \leq V_i^p \leq V_i^{p,\max} \quad (9)$$

$$U_{\text{VUF},i} \leq U_{\text{VUF},i}^{\max} \quad (10)$$

式中: $V_i^{p,\min}$ 、 $V_i^{p,\max}$ 分别为节点 i 第 p 相电压 V_i^p 的最小和最大允许值, 根据规定, 220 V 电压等级的偏差范围为标称电压的-10%~7%; $U_{\text{VUF},i}^{\max}$ 为三相不平衡度的最大允许值, 取 4% 时可以满足运行要求。

2 基于 DA-RNN 的配电网数据潮流模型

在无精确拓扑模型的场景下, 无法精确建立潮流约束条件, 从而难以求解上述优化模型。本节首先定义潮流约束中变量之间的函数关系, 然后通过 DA-RNN 建立数据潮流模型。

2.1 潮流约束中变量函数关系分析

对于含有 n 个节点的配电网, 其极坐标形式的潮流方程可列写为 $6n$ 个函数。节点注入功率 P 和 Q , 节点电压 V 和相角 δ 的函数关系可由式(11)表示。

$$\begin{cases} P_1^a = V_1^a \sum_{i=1}^n \sum_{p=a}^c V_i^p (G_{1i}^{ap} \cos \delta_{1i}^{ap} + B_{1i}^{ap} \sin \delta_{1i}^{ap}) \\ \vdots \\ P_n^c = V_n^c \sum_{i=1}^n \sum_{p=a}^c V_i^p (G_{ni}^{cp} \cos \delta_{ni}^{cp} + B_{ni}^{cp} \sin \delta_{ni}^{cp}) \\ Q_1^a = V_1^a \sum_{i=1}^n \sum_{p=a}^c V_i^p (G_{1i}^{ap} \sin \delta_{1i}^{ap} - B_{1i}^{ap} \cos \delta_{1i}^{ap}) \\ \vdots \\ Q_n^c = V_n^c \sum_{i=1}^n \sum_{p=a}^c V_i^p (G_{ni}^{cp} \sin \delta_{ni}^{cp} - B_{ni}^{cp} \cos \delta_{ni}^{cp}) \end{cases} \quad (11)$$

式中, δ_{ij}^{pm} 是节点 i 第 p 相与节点 j 第 m 相之间的相位差, $\delta_{ij}^{pm} = \delta_i^p - \delta_j^m$ (其他相位差同理)。优化节点电压三相不平衡度需要根据节点注入有功、无功功率推断节点电压幅值。根据式(11)可以推导出连续可微函数 g , 如式(12)所示。

$$g(V_1^a, V_1^b, V_1^c, \delta_1^a, \delta_1^b, \delta_1^c, P_2^a, \dots, P_n^c, Q_2^a, \dots, Q_n^c) = \quad (12)$$

$$[P_1^a, P_1^b, P_1^c, Q_1^a, Q_1^b, Q_1^c, V_2^a, \dots, V_n^c, \delta_2^a, \dots, \delta_n^c]$$

实际的相角数据通常难以获得, 因此上述函数

关系可以改写为 g^* ，如式(13)所示。

$$g^*(V_1^a, V_1^b, V_1^c, P_2^a, \dots, P_n^c, Q_2^a, \dots, Q_n^c) = [P_1^a, P_1^b, P_1^c, Q_1^a, Q_1^b, Q_1^c, V_2^a, \dots, V_n^c] \quad (13)$$

2.2 数据潮流模型

首先分析潮流变量间的关系特性。功率和电压作为时序数据，当前时刻的量测值受到历史时刻输入的影响，即存在时序依赖性；此外，节点变量之间存在潮流耦合关系，即电压不仅随本节点注入功率变化，还受到邻近节点功率波动的影响，各个节点之间的耦合程度存在差异。如图2所示，本文采用基于双阶段注意力机制的循环神经网络算法建立数据潮流模型，在输入侧和输出侧引入注意力机制，通过不断更新并赋予潮流变量一定的权重因子，使得神经网络随拓扑变化自适应地提取出潮流变量关系特性，实现拓扑频繁变动下具有快速适应性的潮流计算。

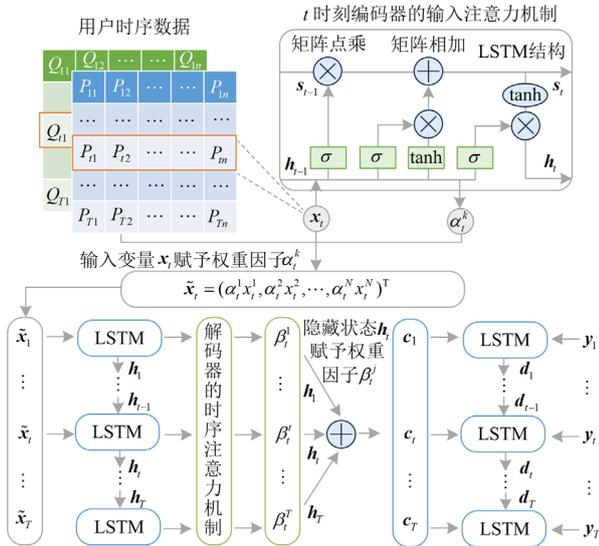


图2 基于 DA-RNN 的数据潮流模型

Fig. 2 Data-driven power flow model based on DA-RNN

1) 基于输入注意力机制的编码器

在编码阶段， h_t 为编码器在 t 时刻的隐藏状态， x_t 为当前时刻输入，为了自适应地选取每个时刻相关的输入特征，在输入侧引入注意力机制，即对于 t 时刻的第 k 个输入变量 x_t^k 赋予注意力权重 α_t^k 。

$$h_t = f(h_{t-1}, x_t) \quad (14)$$

$$x_t = [V_{1,t}^a, V_{1,t}^b, V_{1,t}^c, P_{2,t}^a, \dots, P_{n,t}^c, Q_{2,t}^a, \dots, Q_{n,t}^c]^T \quad (15)$$

$$\tilde{x}_t = (\alpha_t^1 x_t^1, \alpha_t^2 x_t^2, \dots, \alpha_t^N x_t^N)^T \quad (16)$$

为了更好地捕捉时间序列的长期依赖性，本文选用长短期记忆网络 (long short-term memory network, LSTM) 作为激活函数 f 。图2 右上角为 LSTM 结构， N 为 x_t 变量总数， $N = 3(2n-1)$ ， s_t 为

记忆单元，用来保存当前时刻的状态， σ 为 sigmoid 函数， α_t^k 的更新公式为

$$x^k = (x_1^k, x_2^k, \dots, x_T^k)^T \quad (17)$$

$$e_t^k = v_c^T \tanh(W_c [h_{t-1}; s_{t-1}] + U_c x^k) \quad (18)$$

$$\alpha_t^k = \text{softmax}(e_t^k) / \sum_{i=1}^N \text{softmax}(e_t^i) \quad (19)$$

式中： $[h_{t-1}; s_{t-1}]$ 是 h_{t-1} 和 s_{t-1} 拼接而成的矩阵； v_c 、 W_c 、 U_c 是网络参数。

2) 基于时序注意力机制的解码器

传统的编码-解码模型中，所有时刻输出的文本向量均相同，无法体现编码器隐藏状态 h_t 对各个时刻输出影响的差异。DA-RNN 则在不同时刻采用不同的文本向量，基于历史时刻解码器的隐藏状态 d_{t-1} 和记忆单元 m_{t-1} 来计算 t 时刻的文本向量 c_t 。

$$l_t^0 = v_d^T \tanh(W_d [d_{t-1}; m_{t-1}] + U_d h_0), 1 \leq t_0 \leq T \quad (20)$$

$$\beta_t^0 = \text{softmax}(l_t^0) / \sum_{t_0=1}^T \text{softmax}(l_{t_0}^0) \quad (21)$$

$$c_t = \sum_{t_0=1}^T \beta_{t_0}^0 h_{t_0} \quad (22)$$

式中：权重因子 $\beta_{t_0}^0$ 表示 t 时刻编码器隐藏状态对 t_0 时刻输出预测的重要性； v_d 、 W_d 、 U_d 是网络参数。解码器隐藏状态由式(23)得到。

$$d_t = f(y_{t-1}, c_{t-1}, d_{t-1}) \quad (23)$$

3) 基于 DA-RNN 的数据潮流模型

学习得到解码器的隐藏量 h_t 和文本向量 c_t ，再使用一个全连接层作回归得到最终的输出，即可建立当前时刻输入与输出之间的关系。

$$G(x_t) = v_y^T (W_y [d_t; c_t] + b_w) + b_v \quad (24)$$

式中， x_t 是 $3(2n-1)$ 维向量，由某时刻的首端变压器节点三相幅值以及其余节点三相注入有功、无功组成； v_y 、 W_y 、 b_w 、 b_v 是通过以均方差为损失函数的标准反向传播学习到的参数，其损失函数为式(25)。

$$L_{\text{oss}}(G(x_t), y_t^*) = (G(x_t) - y_t^*)^2 \quad (25)$$

$$y_t^* = [P_{1,t}^a, P_{1,t}^b, P_{1,t}^c, Q_{1,t}^a, Q_{1,t}^b, Q_{1,t}^c, V_{2,t}^a, \dots, V_{n,t}^c]^T \quad (26)$$

式中， y_t^* 是同一个时间断面下潮流数据的真实值，其为 $3(n+1)$ 维向量，由首端变压器节点三相注入有功、无功以及其余节点三相电压幅值组成。

2.3 图特征嵌入

上述数据潮流模型默认了网络拓扑是完全未知的，但是在部分网络拓扑已知的场景中，如果不考虑部分已知的拓扑信息可能会造成信息资源的浪费。图特征嵌入分为以下3个步骤。

1) 将已知的拓扑结构信息用带权重邻接矩阵 A

表示(不考虑首端节点), 矩阵的行和列代表配电网中的负载节点, 矩阵中元素代表连接节点之间线路的权重, 根据构建的数据潮流模型特性, 本文采用阻抗表示各个节点之间的连通性权重。

$$\mathbf{A} = \begin{pmatrix} \mathbf{A}^a & \mathbf{A}^{ab} & \mathbf{A}^{ac} \\ \mathbf{A}^{ab} & \mathbf{A}^b & \mathbf{A}^{bc} \\ \mathbf{A}^{ac} & \mathbf{A}^{bc} & \mathbf{A}^c \end{pmatrix} \quad (27)$$

$$\mathbf{A}^p = \begin{pmatrix} R_{22}^p + jX_{22}^p & \cdots & R_{2n}^p + jX_{2n}^p \\ \vdots & & \vdots \\ R_{n2}^p + jX_{n2}^p & \cdots & R_{nn}^p + jX_{nn}^p \end{pmatrix} \quad (28)$$

$$\mathbf{A}^{pm} = \begin{pmatrix} R_{22}^{pm} + jX_{22}^{pm} & \cdots & R_{2n}^{pm} + jX_{2n}^{pm} \\ \vdots & & \vdots \\ R_{n2}^{pm} + jX_{n2}^{pm} & \cdots & R_{nn}^{pm} + jX_{nn}^{pm} \end{pmatrix} \quad (29)$$

式中: R_{ij}^p 和 X_{ij}^p 分别为节点 i 、 j 之间第 p 相的电阻和电抗; R_{ij}^{pm} 和 X_{ij}^{pm} 分别为节点 i 第 p 相和节点 j 第 m 相之间的互电阻和互电抗, 若节点 i, j 之间无线路连接或者 $i = j$ 时, 其值为 0。

2) 将矩阵 \mathbf{A} 与节点注入功率向量 \mathbf{X} 相乘

$$\mathbf{A}\mathbf{X} = \begin{pmatrix} \mathbf{A}^a & \mathbf{A}^{ab} & \mathbf{A}^{ac} \\ \mathbf{A}^{ab} & \mathbf{A}^b & \mathbf{A}^{bc} \\ \mathbf{A}^{ac} & \mathbf{A}^{bc} & \mathbf{A}^c \end{pmatrix} \begin{pmatrix} P_2^a + jQ_2^a \\ \vdots \\ P_n^c + jQ_n^c \end{pmatrix} \quad (30)$$

3) 将得到的 $3(n-1)$ 维向量中的非零元素加入到模型的输入中

$$\mathbf{x} \leftarrow [\mathbf{x}, \mathbf{r}, \mathbf{i}] \quad (31)$$

$$\mathbf{r} = \text{real}(\text{nonzero}(\mathbf{A}\mathbf{X}))^T \quad (32)$$

$$\mathbf{i} = \text{imag}(\text{nonzero}(\mathbf{A}\mathbf{X}))^T \quad (33)$$

式中, $\text{nonzero}()$ 为取非零元素操作。

3 基于数据潮流模型的三相不平衡优化

3.1 重建优化模型

将三相潮流约束替换为训练完成的数据潮流模型, 在目标函数中综合考虑三相不平衡度和分布式光伏弃光率, 配电网不平衡优化模型可重建为以下形式。

1) 目标函数

$$\min F = \min \left(\lambda_1 \frac{F_1}{F_1^*} + \lambda_2 \frac{F_2}{F_2^*} \right) \quad (34)$$

$$F_1 = \sum_{i=1}^n U_{\text{VUF},i} \quad (35)$$

$$U_{\text{VUF},i} = \frac{|V_{\text{neg},i}|}{|V_{\text{pos},i}|} \cong \frac{|V_i^a + \alpha^2 V_i^b + \alpha V_i^c|}{|V_{i,N}^p|} \quad (36)$$

$$F_2 = \frac{E_{\text{cut}}}{E_N} = \frac{\int_0^T P_{\text{PV,cut}}(t) dt}{\int_0^T P_{\text{PV,N}}(t) dt} \quad (37)$$

式中: F_1 为三相不平衡度; $V_{i,N}^p$ 为节点 i 第 p 相的额定电压, 在实际运行中, 正序电压幅值远大于负序电压幅值, 其模长约等于该节点电压幅值, 因此, 可对 F_1 作上述凸化处理; F_2 为光伏弃光率, 定义为规定时间尺度内 DG 弃电量 E_{cut} 与理论发电量 E_N 的比值; $P_{\text{PV,cut}}$ 和 $P_{\text{PV,N}}$ 分别为弃电功率与理论发电功率; F_1^* 、 F_2^* 为仅以三相不平衡度、弃光率为单一目标函数时取得的最优值; λ_1 、 λ_2 为二者的权重因子。

2) 数据潮流模型

$$\mathbf{y} = G(\mathbf{x} + \boldsymbol{\varepsilon}) \quad (38)$$

$$\mathbf{x} = [V_1^a, V_1^b, V_1^c, P_{L,2}^a, \dots, P_{L,n}^c, Q_{L,2}^a, \dots, Q_{L,n}^c, \mathbf{r}, \mathbf{i}]^T \quad (39)$$

$$\boldsymbol{\varepsilon} = [\mathbf{0}, P_{\text{PV},2}^a, \dots, P_{\text{PV},n}^c, Q_{\text{PV},2}^a, \dots, Q_{\text{PV},n}^c, \mathbf{0}]^T \quad (40)$$

式中: $G(\cdot)$ 是 2.2 节所建立的数据潮流模型; $\boldsymbol{\varepsilon}$ 为优化变量组成的向量, $\mathbf{0}$ 为 0 元素向量, 不参加优化。

3) 约束条件

约束条件与 1.2 节相同。

3.2 基于条件梯度下降的模型求解方法

求解优化模型时, 优化变量带有约束限制, 因此本文采用条件梯度(conditional gradient method, GM)方法处理优化变量的约束问题。该方法在每次迭代中得到最优下降方向, 再与上一步的迭代点凸组合得到下一步的迭代点, 保证每一步的迭代点都在约束范围内。优化变量 $\boldsymbol{\varepsilon}$ 的更新过程为

$$\boldsymbol{\gamma}_{itr} = \arg \min_{\boldsymbol{\varepsilon} \in \mathbf{C}} \langle \nabla F(\mathbf{x} + \boldsymbol{\varepsilon}_{itr}), \boldsymbol{\varepsilon} \rangle \quad (41)$$

$$\boldsymbol{\varepsilon}_{itr+1} = (1 - \eta_{itr}) \boldsymbol{\varepsilon}_{itr} + \eta_{itr} \boldsymbol{\gamma}_{itr} \quad (42)$$

式中: \mathbf{C} 是优化变量的约束范围集合; itr 是迭代次数; ∇ 是梯度算子; $\langle \cdot, \cdot \rangle$ 是向量内积; $\arg \min$ 表示函数取得最小值的参数值; $\boldsymbol{\gamma}_{itr}$ 是用于确定迭代方向的导航点; 步长 η_{itr} 常取 $2/(itr+1)$, 步长可以控制每个迭代向量与边界向量之间的距离以实现更合适的下降。 $\boldsymbol{\gamma}_{itr}$ 、 $\boldsymbol{\varepsilon}_{itr} \in \mathbf{C}$, 二者凸组合后得到新的优化变量仍在约束范围 \mathbf{C} 内。

基于数据潮流模型的高比例光伏配电网三相不平衡优化流程图如图 3 所示。

4 算例分析

4.1 算例原始参数

本文在修改后的 IEEE33 节点网络上进行仿真以验证所提方法的有效性。如图 4 所示, 节点 0 为变压器节点, 选择该节点作为平衡节点。基准电压为 12.66 kV, 功率基准值为 100 MVA。三相线路阻

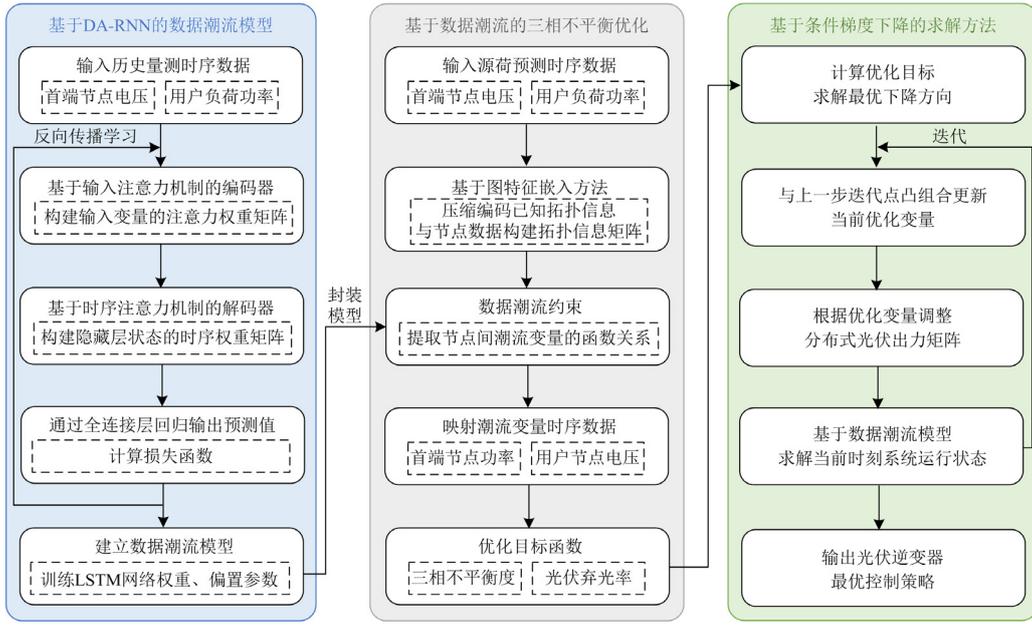


图 3 基于数据潮流模型的高比例光伏配电网三相不平衡优化流程图

Fig. 3 Flow chart of three-phase unbalanced optimization of a distribution network with a high proportion distributed photovoltaic based on a data-driven power flow model

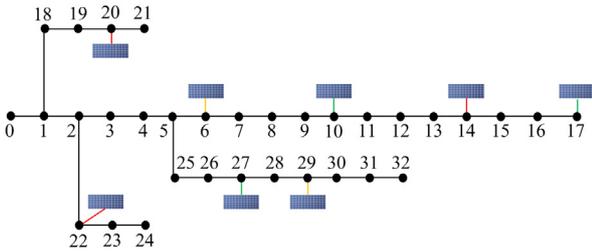


图 4 IEEE33 节点网络

Fig. 4 The IEEE33-node network

抗各不相同，且各相阻抗之间的差距控制在 15% 以内。分布式光伏在节点 6、10、14、17、20、22、27、29 单相接入，红、绿、橙分别表示接入 a、b、c 相序，单相光伏发电额定功率为 1500 kW，逆变器容量为光伏额定容量的 1.1 倍。

本文用潮流计算结果代替电力系统实测。采用蒙特卡罗方法随机生成潮流数据，其中 80% 为训练数据集，20% 为测试数据集。每个样本包括 32 个节点三相的注入有功、无功功率以及首端节点的三相电压幅值(1×195 维向量)，每个标签包括 32 个节点三相的电压幅值以及首端节点三相的注入有功、无功功率(1×102 维向量)。DA-RNN 编码器和解码器的隐藏层数均为 32，每个隐藏层有 150 个神经元，时间步长为 10，学习率为 0.001，每批样本个数为 16，迭代 2000 次。所有仿真均在一台配置有 2.11 GHz Intel Core i7 处理器及 8G 内存的电脑上

完成。

4.2 基于 DA-RNN 的数据潮流模型训练结果

为了验证模型的有效性，本文以均方根误差 E_{RMSE} (root mean square error, RMSE)、相关系数 r (coefficient of association) 作为模型训练评估指标。

$$E_{RMSE} = \sqrt{\frac{1}{N_y} \sum_{i=1}^{N_y} (y_i^* - y_i)^2} \quad (43)$$

$$r = \frac{\sum_{i=1}^{N_y} (y_i^* - \bar{y}^*)(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{N_y} (y_i^* - \bar{y}^*)^2 \sum_{i=1}^{N_y} (y_i - \bar{y})^2}} \quad (44)$$

式中： N_y 为测试集样本数目； y_i^* 和 y_i 分别为实际数据和预测数据的第 i 个元素； \bar{y}^* 和 \bar{y} 分别为实际数据与预测数据的均值。 E_{RMSE} 越趋近于 0 且 r 越趋近于 1，则模型预测误差越小，函数拟合效果越好。

基于样本测试集，将 DA-RNN 与基于注意力机制的循环神经网络(attention-based encoder-decoder network, Attention RNN)、反向传播神经网络(back propagation neural network, BPNN)进行对比。保持结构参数相同，对比不同隐藏层数设置下的拟合效果，如图 5 所示。

由图 5 可知，随着隐藏层深度的增加，BPNN 与 Attention RNN 依靠简单的堆叠隐藏层难以提升拟合效果，DA-RNN 则凭借着解码-编码的双阶段

注意力机制在拟合性能上始终保持优势。此外, 在参数变动时, DA-RNN 具有更好的鲁棒性。

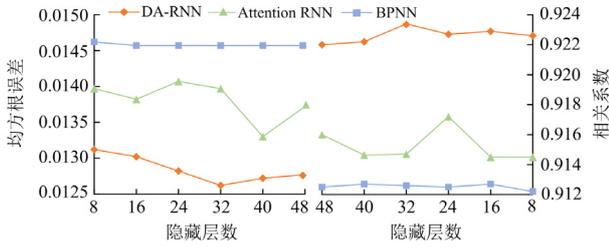


图 5 不同算法的拟合效果

Fig. 5 Diagram of different algorithm fitting effect

4.3 基于数据潮流模型的配电网三相不平衡优化仿真结果

本文针对拓扑信息完全未知和拓扑信息部分已知的两种场景, 分别构建基于数据潮流的配电网三相不平衡优化模型。由于多目标优化中的权重因子通常根据运行情况和实际控制需求主观设定^[23-24], 且本文重点关注三相不平衡问题, 因此 F_1 选取较高权重 λ_1 为 0.7, 弃光率 F_2 选取较低权重 λ_2 为 0.3。

1) 拓扑信息完全未知时的优化模型结果

在拓扑信息完全未知的场景下, 对基于数据潮流模型的配电网三相不平衡优化模型进行求解验证, 模型目标函数值随迭代次数的变化情况如图 6 所示。目标函数在迭代 1000 次时停止下降, 说明此时模型已经接近收敛, 并且在测试集上的拟合误差小于 0.01, 能够满足工程需求。

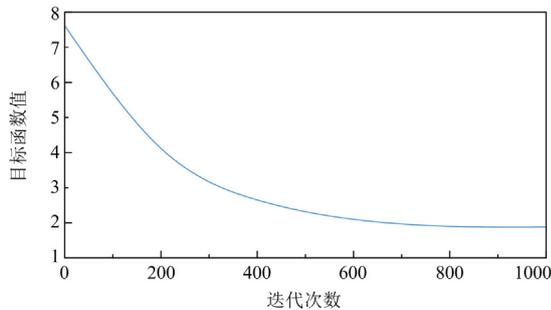


图 6 随迭代次数变化的目标函数值

Fig. 6 Value of the objective function varying with number of iterations

分析不同控制策略下的三相不平衡度和弃光率, 其中基于物理模型的三相不平衡优化方法需要已知完整且精确的拓扑结构以及线路参数(与本文方法采用同样的目标函数、约束条件以及光伏逆变器控制手段)。由图 7 可知, 分布式光伏接入后, 系统三相不平衡问题加剧, 加入控制策略后, 三相不平衡问题得到缓解。本文方法与基于物理模型的方法在三相不平衡优化上的效果较为接近, 每一时刻的

不平衡度均限制在 2% 以内, 满足运行要求; 表 1 列出了不同控制策略下的分布式光伏消纳率, 基于物理模型的方法与本文方法均使系统的消纳率提高 8%~10%, 但本文方法无须依赖配电网物理模型, 能够更好地适用于高比例光伏接入下物理结构多变和运行控制复杂的配电网。

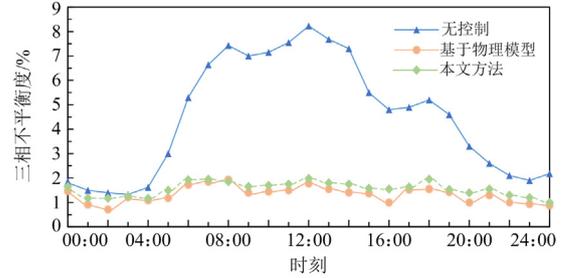


图 7 不同控制策略下的三相不平衡度

Fig. 7 Three-phase unbalance under different control strategies

表 1 不同控制策略下的分布式光伏消纳率

Table 1 PV absorption rate under different control strategies

光伏设备	消纳率		
	无控制	基于物理模型方法	本文方法
PV1	80.12	87.38	86.53
PV2	75.39	84.65	82.42
PV3	68.89	75.23	75.78
PV4	70.26	77.49	76.32
PV5	71.65	78.82	77.51

配电网三相不平衡问题会增大系统线路损耗和电压波动范围。分布式光伏并网电压偏移率最大值如图 8 所示, 在高比例光伏接入下, 本文方法可以有效降低电压偏移率, 使各节点电压幅值更接近于额定电压。由表 2 可知, 本文方法与基于物理模型方法都使得各相有功、无功损耗大幅度降低。因此, 所提方法可有效改善网络三相不平衡问题, 降低电压负序分量造成的不良影响, 提升系统电压品质。

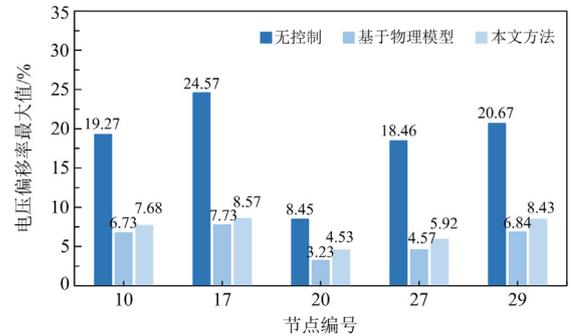


图 8 不同控制策略下的节点电压偏移率最大值

Fig. 8 Maximum node voltage offset under different control strategies

表 2 不同控制策略下的有功、无功损耗
Table 2 Active and reactive power loss under different control strategies

		优化策略	无控制	基于物理模型	本文方法
有功损耗/MW	A 相		0.835	0.518	0.573
	B 相		0.746	0.451	0.513
	C 相		0.648	0.434	0.479
无功损耗/Mvar	A 相		0.571	0.332	0.385
	B 相		0.505	0.327	0.396
	C 相		0.441	0.264	0.277

2) 拓扑信息部分已知时的优化模型结果

在图 4 所示的算例系统中，设置不同比例的已知拓扑信息，对各场景下的优化过程使用经过 1000 次迭代的数据潮流模型，以验证已知部分拓扑结构对优化模型鲁棒性的提升效果。

模型在不同场景下的三相不平衡度和光伏消纳率如图 9、表 3 所示。相比于无拓扑信息，在已知 30%、50%、70%和 100%的拓扑信息场景下，各时间点的三相不平衡度明显下降，各设备的光伏消纳率也有所增加，这说明随着已知拓扑信息比例的增加，基于数据潮流模型的三相不平衡优化方法的性能有所提升。

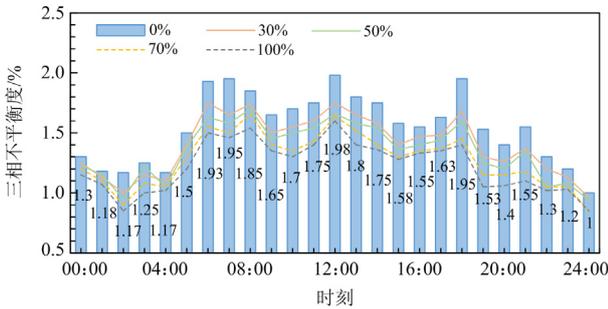


图 9 已知不同比例拓扑下优化后的三相不平衡度
Fig. 9 Three-phase unbalance after optimization in different topology scales

表 3 不同信息拓扑下的分布式光伏消纳率

Table 3 Distributed PV absorption rate in different topology scales

拓扑	消纳率 %				
	0	30	50	70	10
PV1	86.53	86.88	87.21	87.35	87.38
PV2	82.42	82.67	83.06	84.54	84.65
PV3	75.78	76.23	76.59	76.65	76.68
PV4	76.32	76.48	76.63	77.12	77.49
PV5	77.51	77.64	77.83	78.59	78.82

由图 10 和表 4 可知，在已知 30%~50%拓扑信息的场景下，节点电压偏移率相较于无拓扑信息场景有较为明显的下降，有功、无功损耗也显著减少；

在已知 70%~100%拓扑信息场景下，相较于无拓扑信息场景，节点电压偏移问题得到有效改善，有功、无功损耗有略微的下降，说明已知部分拓扑结构能够提升优化模型的鲁棒性。

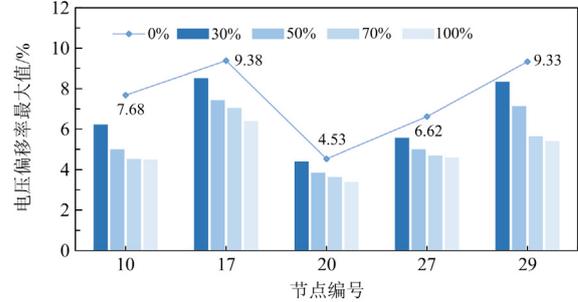


图 10 已知不同比例拓扑下优化后的电压偏移率最大值
Fig. 10 Maximum node voltage offset after optimization in different topology scales

表 4 已知不同比例拓扑下优化后的有功无功损耗
Table 4 Active and reactive power loss after optimization in different topology scales

已知拓扑信息比例		有功损耗/MW	无功损耗/Mvar
0%	A 相	0.573	0.385
	B 相	0.513	0.396
	C 相	0.479	0.277
30%	A 相	0.481	0.315
	B 相	0.484	0.327
	C 相	0.308	0.215
50%	A 相	0.456	0.296
	B 相	0.419	0.274
	C 相	0.286	0.206
70%	A 相	0.432	0.297
	B 相	0.378	0.253
	C 相	0.281	0.206
100%	A 相	0.415	0.281
	B 相	0.371	0.245
	C 相	0.269	0.207

4.4 不同光伏渗透率下优化模型仿真结果

为了验证本文方法在不同分布式光伏渗透率下的适应能力，在原有基础上于节点 3 和节点 12 增加光伏接入点，并适当缩放原始数据，使得光伏渗透率不断增加，分别是 10%、20%、30%和 40%。其中，将渗透率为 10%的样本用来训练数据潮流模型，并验证模型对于不同分布式光伏渗透率的适应能力。

不同渗透率下的三相不平衡度和各项指标均值如图 11、表 5 所示，其中：随着分布式光伏渗透率

的增加, 三相不平衡优化效果略有下降, 但仍满足运行要求; 系统在初始阶段可以有效吸纳光伏, 消纳率有所增加, 当光伏渗透率较高时, 消纳率受到电网灵活性和调节能力的限制而有所下降。此外, 分布式光伏充足的无功调节功率, 对于节点电压幅值具有一定的提升作用, 使得整个配电网的电压偏移下降。渗透率的增加也使得网络有功损耗逐渐降低。因此, 本文所提模型具有较强的鲁棒性, 能够适应分布式光伏在不同渗透率下的三相不平衡优化任务。

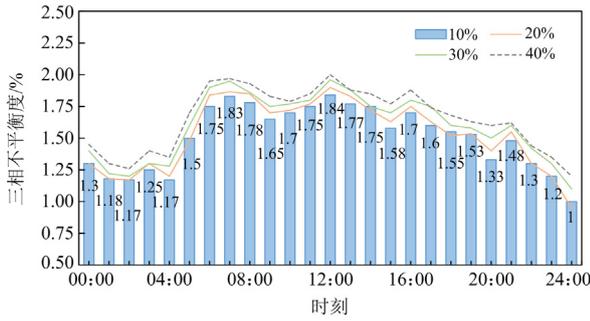


图 11 不同渗透率下优化后的三相不平衡度

Fig. 11 Three-phase unbalance after optimization with different permeability

表 5 不同渗透率下的各项指标值

Table 5 Indicators with different permeability

渗透率/%	电压偏移率均值/%	光伏消纳率/%	有功损耗/MW
10	4.41	80.31	0.523
20	3.67	82.24	0.414
30	3.45	82.16	0.372
40	3.27	81.53	0.356

4.5 光伏不同并网方式下优化模型仿真结果

为了研究单相、三相异构光伏调控能力对优化效果的影响, 在算例中改变各节点分布式光伏并网方式, 设置 3 种光伏接入场景分析不同类型光伏的调控能力差异。场景 1: 如图 4 所示; 场景 2: 在场景 1 的基础上, 将节点 6、14、22、27 的光伏设置为三相并网方式, 每一相可单独调节出力; 场景 3: 将所有光伏接入点均设置为三相并网方式。

图 12 为不同并网方式下的三相不平衡度优化效果。加入控制策略后, 3 种场景下的系统三相不平衡度显著下降, 每一时刻的不平衡度均限制在 2% 以内, 满足运行要求。在 10:00—14:00 时段内, 光照较强且光伏调控能力增大, 场景 1、2、3 的最大三相不平衡度比优化前分别下降了 75.84%、78.62%、80.21%, 说明所提策略在光伏不同并网方式下均可有效改善三相不平衡问题。优化模型在不

同并网方式下的节点电压均值如图 13 所示, 3 种场景下优化后的电压幅值明显上升, 各节点电压均提升至正常电压范围内。

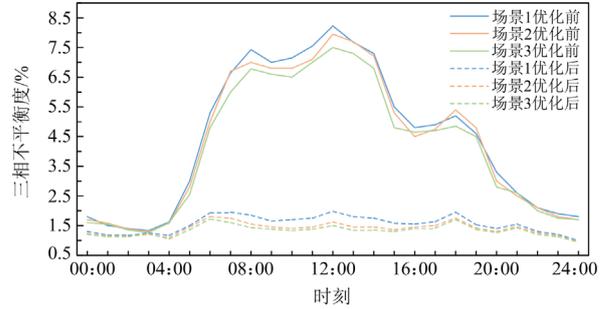


图 12 不同并网方式下优化前后的三相不平衡度

Fig. 12 Three-phase unbalance before and after optimization with different grid connection methods

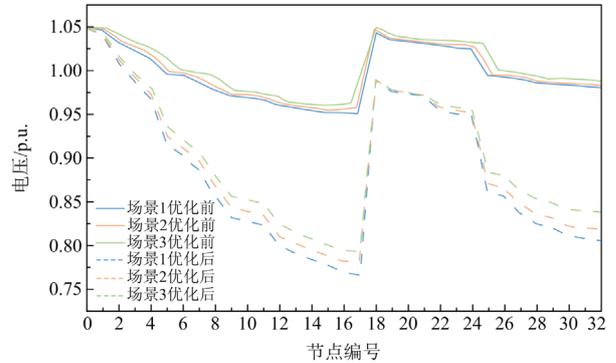


图 13 不同并网方式下优化前后的节点电压

Fig. 13 Node voltages before and after optimization with different grid connection methods

不同并网方式下的各项指标值如表 6 所示。加入控制策略后, 3 种场景下的电压偏移率和三相有功损耗均值均有所下降。场景 1 和 2 经过优化后的光伏消纳率提升效果明显, 而当光伏渗透率较高时, 消纳率受到系统灵活调节能力的制约, 导致场景 3 的光伏消纳率变化不大。因此, 所提策略在光伏不

表 6 不同并网方式下优化前后的各项指标值

Table 6 Indicators before and after optimization with different grid connection methods

不同并网方式	电压偏移率均值/%	有功损耗/MW	光伏消纳率/%	
场景 1	优化前	11.94	0.816	74.26
	优化后	3.52	0.521	81.31
场景 2	优化前	9.37	0.732	79.45
	优化后	2.74	0.425	83.24
场景 3	优化前	8.65	0.627	80.78
	优化后	2.53	0.378	81.57

同并网方式下均可有效应用, 在系统中适当配置单相-三相并网点并充分利用光伏逆变器的并网控制, 可以有效优化三相不平衡问题、降低电压偏差率、减少网络损耗以及改善系统整体运行状态。

5 结论

本文针对大规模光伏接入下配电网无法精确建立拓扑模型的问题, 提出了一种基于数据潮流模型的高比例光伏配电网三相不平衡优化方法。以IEEE33节点配电网为例进行仿真测试, 验证了本文所提方法的有效性, 得到以下结论。

1) 基于数据潮流的优化方法通过分析终端节点的历史量测数据, 挖掘负载节点间的潮流映射关系, 实现对配电网的智能感知与优化运行。仿真结果表明, 本文方法与基于物理模型的方法在三相不平衡优化上的效果较为接近, 各时刻的不平衡度均限制在 2%以内。但本文方法克服了网络建模精度对基于物理模型的优化方法的限制, 适用于物理结构多变和运行控制复杂的含光伏配电网。

2) 对比不同隐藏层数设置下的模型训练结果, BPNN 与 Attention RNN 依靠简单的堆叠隐藏层难以提升拟合效果, DA-RNN 通过引入双阶段注意力机制充分考虑了节点变量的时序依赖特性和潮流耦合特性, 具有更精确的拟合效果。

3) 通过图特征嵌入方法对已知的拓扑信息进行压缩编码, 并嵌入到数据潮流模型中可以提高模型的拟合精度, 使电压偏移率和网络损耗最大下降了 48.65%和 26.34%, 更有效地降低系统电压波动和提高系统运行经济性。

参考文献

- [1] ERDIWANSYA H, MAHIDI N, HUSIN H, et al. A critical review of the integration of renewable energy sources with various technologies[J]. *Protection and Control of Modern Power Systems*, 2021, 6(1): 37-54.
- [2] 杜晓东, 赵建利, 刘科研, 等. 基于数字孪生的光伏高比例配电网过载风险预警方法[J]. *电力系统保护与控制*, 2022, 50(9): 136-144.
DU Xiaodong, ZHAO Jianli, LIU Keyan, et al. Digital twin early warning method study for overload risk of distribution network with a high proportion of photovoltaic access[J]. *Power System Protection and Control*, 2022, 50(9): 136-144.
- [3] 陈家超, 李钦豪, 唐渊, 等. 考虑光伏选相投切的低压配电网三相平衡优化[J]. *电力自动化设备*, 2022, 42(4): 71-78.
CHEN Jiachao, LI Qin hao, TANG Yuan, et al. Three-phase balance optimization of low-voltage distribution network considering photovoltaic phase selection and switching[J]. *Electric Power Automation Equipment*, 2022, 42(4): 71-78.
- [4] WANG Shengyi, DU Liang, FAN Xiaoyuan, et al. Deep reinforcement scheduling of energy storage systems for real-time voltage regulation in unbalanced LV networks with high PV penetration[J]. *IEEE Transactions on Sustainable Energy*, 2021, 12(4): 2342-2352.
- [5] 杜晓东, 曾四鸣, 刘科研, 等. 基于云模型的配电网运行画像数字孪生构建方法[J]. *电力系统保护与控制*, 2022, 50(10): 104-113.
DU Xiaodong, ZENG Siming, LIU Keyan, et al. Construction of portraits for a distribution network with digital twins based on a cloud model[J]. *Power System Protection and Control*, 2022, 50(10): 104-113.
- [6] HAMID Z, MEHRDAD N S, MIADREZA S, et al. Optimal scheduling of an active distribution system considering distributed energy resources, demand response aggregators and electrical energy storage[J]. *Applied Energy*, 2022, 314.
- [7] 魏剑啸, 粟忠来, 杨波, 等. 配电台区无功功率及三相不平衡电容调节的研究[J]. *电力系统保护与控制*, 2019, 47(16): 71-79.
WEI Jianxiao, SU Zhonglai, YANG Bo, et al. Study on reactive power and three-phase unbalance regulated by capacitor in distribution network[J]. *Power System Protection and Control*, 2019, 47(16): 71-79.
- [8] LIU Haotian, WU Wenchuan. Two-stage deep reinforcement learning for inverter-based volt-var control in active distribution networks[J]. *IEEE Transactions on Smart Grid*, 2021, 12(3): 2037-2047.
- [9] 苏海锋, 赵可为, 李岩, 等. 规模化电动汽车三相负荷平衡充电选线装置与仿真分析[J]. *电力自动化设备*, 2018, 38(6): 103-108.
SU Haifeng, ZHAO Kewei, LI Yan, et al. Three-phase load balancing charging line selection device and simulation analysis of large-scale electric vehicle[J]. *Electric Power Automation Equipment*, 2018, 38(6): 103-108.
- [10] CAI Mengmeng, YANG Rui, ZHANG Yingchen. Iteration-based linearized distribution-level locational marginal price for three-phase unbalanced distribution systems[J]. *IEEE Transactions on Smart Grid*, 2021, 12(6): 4886-4896.
- [11] 苏向敬, 刘一航, 张知宇, 等. 计及源荷不确定影响的三相不平衡配电网两阶段优化[J]. *电力系统保护与控制*, 2022, 50(23): 94-103.
SU Xiangjing, LIU Yihang, ZHANG Zhiyu, et al. Two-stage optimization of unbalanced distribution networks considering impacts of DG and load uncertainties[J]. *Power System Protection and Control*, 2022, 50(23): 94-103.
- [12] 唐冬来, 郝建维, 刘荣刚, 等. 基于动态规划的配电网

- 区三相负荷不平衡治理方法[J]. 电力系统保护与控制, 2020, 48(21): 58-66.
- TANG Donglai, HAO Jianwei, LIU Ronggang, et al. Control method of three phase load imbalance in a distribution station area based on dynamic programming[J]. Power System Protection and Control, 2020, 48(21): 58-66.
- [13] 卢姬, 常俊晓, 张云阁, 等. 考虑 DG 不确定性的主动配电网两阶段无功机会约束优化方法[J]. 电力系统保护与控制, 2021, 49(21): 28-35.
- LU Ji, CHANG Junxiao, ZHANG Yunge, et al. Two stage reactive power chance constrained optimization method for active distribution network considering DG uncertainty[J]. Power System Protection and Control, 2021, 49(21): 28-35.
- [14] 寇凌峰, 吴鸣, 李洋, 等. 主动配电网分布式有功无功优化调控方法[J]. 中国电机工程学报, 2020, 40(6): 1856-1865.
- KOU Lingfeng, WU Ming, LI Yang, et al. Optimization and control method of distributed active and reactive power in active distribution network[J]. Proceedings of the CSEE, 2020, 40(6): 1856-1865.
- [15] 潘思蓉, 刘友波, 唐志远, 等. 含深度学习代理模型的有源配电网电压无功控制进化算法[J]. 电力系统保护与控制, 2022, 50(17): 97-106.
- PAN Sirong, LIU Youbo, TANG Zhiyuan, et al. An evolutionary algorithm for volt/var control in an active distribution network with a deep learning surrogate mode[J]. Power System Protection and Control, 2022, 50(17): 97-106.
- [16] 徐博涵, 向月, 潘力, 等. 基于深度强化学习的含高比例可再生能源配电网就地分散式电压管控方法[J]. 电力系统保护与控制, 2022, 50(22): 100-109.
- XU Bohan, XIANG Yue, PAN Li, et al. Local decentralized voltage management of a distribution network with a high proportion of renewable energy based on deep reinforcement learning[J]. Power System Protection and Control, 2022, 50(22): 100-109.
- [17] XU Hanchen, DOMÍNGUEZ-GARCÍA A D, VEERAVALLI V V, et al. Data-driven voltage regulation in radial power distribution systems[J]. IEEE Transactions on Power Systems, 2020, 35(3): 2133-2143.
- [18] LIU Haotian, WU Wenchuan. Two-stage deep reinforcement learning for inverter-based volt-var control in active distribution networks[J]. IEEE Transactions on Smart Grid, 2021, 12(3): 2037-2047.
- [19] ZHANG Ying, WANG Xinan, WANG Jianhui, et al. Deep reinforcement learning based volt-var optimization in smart distribution systems[J]. IEEE Transactions on Smart Grid, 2021, 12(1): 361-371.
- [20] 廖文龙, 于贇, 王煜森, 等. 基于图卷积网络的配电网无功优化[J]. 电网技术, 2021, 45(6): 2150-2160.
- LIAO Wenlong, YU Yun, WANG Yusen, et al. Reactive power optimization of distribution network based on graph convolutional network[J]. Power System Technology, 2021, 45(6): 2150-2160.
- [21] 顾洁, 孟璐, 朱瞳彤, 等. 数据驱动的无精确建模含源配电网无功运行优化[J]. 电力自动化设备, 2021, 41(1): 1-11.
- GU Jie, MENG Lu, ZHU Tongtong, et al. Data-driven optimization for reactive power operation in source distribution network without accurate modeling[J]. Electric Power Automation Equipment, 2021, 41(1): 1-11.
- [22] 张宇精, 乔颖, 鲁宗相, 等. 含高比例分布式电源接入的低感知度配电网电压控制方法[J]. 电网技术, 2019, 43(5): 1528-1535.
- ZHANG Yujing, QIAO Ying, LU Zongxiang, et al. Voltage control for partially visible distribution networks with high DG penetration[J]. Power System Technology, 2019, 43(5): 1528-1535.
- [23] 蔡永翔, 唐巍, 张博, 等. 适应高比例户用光伏的中低压配电网集中-分布式协调控制[J]. 中国电机工程学报, 2020, 40(15): 4843-4854.
- CAI Yongxiang, TANG Wei, ZHANG Bo, et al. Centralized distributed multi-objective coordinated control for MV and LV distribution networks adapting to high-proportion residential PV units[J]. Proceedings of the CSEE, 2020, 40(15): 4843-4854.
- [24] 刘文颖, 文晶, 谢昶, 等. 考虑风电消纳的电力系统源荷协调多目标优化方法[J]. 中国电机工程学报, 2015, 35(5): 1079-1088.
- LIU Wenyong, WEN Jing, XIE Chang, et al. Multi-objective optimal method considering wind power accommodation based on source-load coordination[J]. Proceedings of the CSEE, 2015, 35(5): 1079-1088.

收稿日期: 2023-09-12; 修回日期: 2024-01-25

作者简介:

高雪寒(1998—), 女, 硕士研究生, 研究方向为配电网运行规划与态势感知。E-mail: 17717957324@163.com

(编辑 姜新丽)