

基于内嵌物理信息 GraphSAGE 模型的配电网最大供电能力计算

刘宝龙¹, 陈中¹, 王毅², 乔勇¹, 颜浩伟¹

(1. 东南大学 电气工程学院, 江苏 南京 210018;

2. 国网电力科学研究院有限公司 智能电网保护和运行控制国家重点实验室, 江苏 南京 211106)

摘要:针对配电网最大供电能力计算存在的物理约束难以满足、效率不足、拓扑适应性差等问题,提出一种基于内嵌物理信息图采样与聚合(GraphSAGE)模型的配电网最大供电能力计算方法,可以实现未见信息的生成嵌入,快速计算出多变场景下的配电网最大供电能力。将物理约束嵌入 GraphSAGE 模型,强制模型在训练过程中满足物理规律,提高模型可解释性并降低对数据集数量和质量的要求;通过边特征聚合和图自编码器预训练克服模型不能考虑边信息及节点特征丢失的缺点;在节点采样后,将多头注意力机制融入节点特征聚合过程中,提高模型的计算精度。算例以及对比实验结果表明,所提方法对新能源出力和配电网拓扑变化具有更强的适应能力。

关键词:图卷积网络;配电网;最大供电能力;物理信息;图注意力机制

中图分类号: TM73

文献标志码: A

DOI: 10.16081/j.epae.202511006

0 引言

随着新能源技术的不断发展,分布式新能源(distributed generation, DG)的接入逐渐成为提升配电网最大供电能力(total supply capability, TSC)的新途径。然而,由于特有的不确定性和波动性, DG 对配电网的最大供电能力计算产生了很大影响^[1]。此外,在配电网的实际运行过程中,其拓扑结构并非一成不变,这进一步给配电网最大供电能力的在线计算带来了挑战^[2]。在新型电力系统背景下需要考虑不同新能源出力以及配电网拓扑变化场景,快速计算出配电网最大供电能力,避免电力过载和电力短缺的情况发生,确保电力系统的可靠运行。

配电网最大供电能力指的是在特定供电区域内,配电网在满足 $N-1$ 安全准则的条件下,充分考虑网络实际运行状况时所能达到的最大负荷供应能力^[2-3]。现阶段对配电网最大供电能力的研究主要包括求解变压器容载比的方法、重复潮流法以及计及 $N-1$ 安全准则的配电网最大供电能力计算方法^[4]。

文献[5]提出一种考虑台区柔性互联、负荷多级转供的最大供电能力模型。文献[6]提出一种计及配电网重构和风光出力不确定性的配电网最大供电能力计算方法。文献[7]提出考虑主变互联关系和馈线互联关系的配电网最大供电能力计算方法。文献[8]在文献[6]和文献[7]的基础上,提出考虑多次

转供的配电网最大供电能力评估方法。文献[9]通过图计算方法挖掘转供路径并求解配电网最大供电能力。文献[10]在最大供电能力的基础上,提出最小供电能力的定义、数学模型、求解方法和应用方法。上述文献大多针对固定拓扑且采用优化算法进行计算,不能很好地实现新能源出力或拓扑变化情况下的配电网最大供电能力在线计算。图神经网络的迅速发展使得较为成熟的神经网络算法被扩展到图域中,从而实现了深度学习与图数据的有机结合^[11],且电网拓扑结构与图数据库具有天然的一致性,因此,图神经网络算法被越来越多地应用到电力系统中。文献[12]通过改进的图神经网络模型实现了潮流判敛及潮流分布计算。文献[13]将图注意力网络运用至配电网故障定位领域,获得了很好的效果。文献[14]提出一种改进的物理引导的图神经网络模型来预测非均匀风电场的发电功率输出。文献[15]提出一种基于消息传递图神经网络的状态估计模型。文献[16]提出一种基于图神经网络的配电网故障定位模型。然而,神经网络在电力系统中的应用存在对数据质量和数量要求高、模型可解释性差以及模型预测可能不满足物理规律和约束条件的问题。为解决这些问题,物理引导数据驱动以及物理信息神经网络方法被提出,这些方法充分利用了数据和物理信息,其核心是将物理信息直接嵌入神经网络中,确保在输出逼近实测数据的同时,约束网络在求解域内满足物理方程^[17-18]。由于配电网最大供电能力数据集获取难度较大,且各样本之间的差距很小,数据集质量难以得到保证,因此,在模型中加入物理信息,其本质是强迫模型在训练过程中满足

收稿日期:2024-10-11;修回日期:2025-06-12

在线出版日期:2025-11-13

基金项目:国家自然科学基金资助项目(52077035)

Project supported by the National Natural Science Foundation of China(52077035)

物理约束,即使样本数量较少,也可以成功训练模型,使其能够准确计算出配电网最大供电能力。

综上所述,本文提出基于内嵌物理信息图采样与聚合(graph sample and aggregate, GraphSAGE)的配电网最大供电能力计算模型。首先,基于配电网拓扑结构与图数据的对应关系,构建包含DG的配电网最大供电能力数据集。然后,以GraphSAGE模型为核心,加入图自编码器预训练、边的特征以及多头图注意力机制,并且在损失函数中内嵌物理信息。最后,通过实验验证本文模型能够准确计算出某一拓扑及新能源出力情况下的配电网最大供电能力,具有较强的可扩展性、灵活性和泛化能力,能够适应配电网转供路径和新能源并网点的变化,且在小样本情况下具有更高的预测精度。

1 图数据建模与图神经网络

图数据是一种由节点和边组成的非欧氏空间下的数据类型,蕴含丰富的结构信息和关联信息^[19]。配电网图数据建模是指将配电网拓扑结构按照 $G=(V, E)$ 的格式生成图模型,其中 V 为节点集合, E 为边的集合。

文献[7-10]研究在满足 $N-1$ 安全准则情况下考虑负荷转供的配电网最大供电能力,基于此,本文主要研究极限状况下配电网所能承载的负荷量,并在计算过程中考虑DG出力及其与负荷需求间的相关性影响。

考虑DG出力,计算在满足 $N-1$ 安全准则下考虑负荷转供的配电网最大供电能力的目标函数为:

$$T_{sc} = \max \left(\sum_{r=1}^{N_r} R_r T_r + \sum_{t=1}^{N_D} \beta_t D_{Mt} \right) \quad (1)$$

式中: T_{sc} 为配电网最大供电能力; R_r 、 T_r 分别为主变 r 的额定容量和负载率; N_r 、 N_D 分别为主变节点和新能源节点数; D_{Mt} 为第 t 个DG的额定容量; β_t 为第 t 个DG的容量因子; $\beta_t D_{Mt}$ 为第 t 个DG的实际有功出力。

考虑DG接入对配电网最大供电能力的影响,约束条件如下。

1) 负荷转供等式约束为:

$$T_r R_r = T_{DGt} + \sum f_{ij} \quad (2)$$

式中: T_{DGt} 为主变 r 发生 $N-1$ 故障时,其供电区域内第 t 个DG可额外支撑的功率大小; f_{ij} 为主变 r 向主变 j 转移的负荷大小,包括站内转移负荷和站外转移负荷。

2) DG容量约束为:

$$T_{DGt} + \beta_t D_{Mt} \leq D_{Mt} \quad (3)$$

式(3)表示主变 r 发生 $N-1$ 故障时,负荷转移后供电区域内DG所带负荷大小不超过DG的容量。

3) 负荷转供后主变容量约束为:

$$f_{ij} + T_j R_j \leq k R_j + D_{Mt} \quad (4)$$

式中: k 为主变短时允许过载系数。

式(4)表示主变 r 发生故障,通过站内或站间联络线向主变 j 转供负荷时,主变 j 所带负荷不超过主变 r 额定容量的 k 倍和与其互联的DG可输出有功之和。

4) DG的 $N-1$ 安全约束为:

$$\beta_t D_{Mt} + T_r R_r \leq k R_r \quad (5)$$

式(5)表示当配电网中只有1个DG发生故障时,通过负荷转供,配电网仍然能够保证负荷稳定供电。

其余约束条件与文献[7-10]中基本相同,本文不再赘述。

根据上述公式,配电网最大供电能力计算图模型所需节点特征包括节点类型 T (变压器节点、新能源节点和负荷节点)、所属变电站编号 B 以及最大容量 C 。联络线边特征主要包括边类型 L (普通线路、站间联络线和站内联络线)、所属变电站编号 B 以及可通过最大容量 C 。设 $v_i \in V$ 表示配电网图中的第 i 个节点,其特征向量 $\mathbf{h}_{vi} = [T_i, B_i, C_i] \in \mathbf{R}^3$,其中 T_i 、 B_i 、 C_i 分别为第 i 个节点的节点类型、所属变电站编号和最大容量。所有节点特征向量构成节点特征矩阵 $\mathbf{X} = [\mathbf{h}_{v1}, \mathbf{h}_{v2}, \dots, \mathbf{h}_{vq}]$,其中 q 为节点数。节点之间的连接关系由2行 p 列边连接矩阵 $\mathbf{e}_{\text{index}} = [[a_{11}, a_{12}, \dots, a_{1p}]; [b_{21}, b_{22}, \dots, b_{2p}]]$ 表示,其中 a_{11} — a_{1p} 为边的起始节点, b_{21} — b_{2p} 为边的终止节点, p 为边的总数。边的特征向量 $\mathbf{h}_{ei} = [L_i, B_i, C_i] \in \mathbf{R}^3$,其中 L_i 为第 i 条边的类型,所有边特征可构成边特征矩阵 $\mathbf{e}_{\text{attr}} = [\mathbf{h}_{e1}, \mathbf{h}_{e2}, \dots, \mathbf{h}_{ep}]$ 。本文采用的配电网图模型如图1所示。

目前广泛使用图卷积网络(graph convolutional network, GCN)、图注意力网络等图神经网络模型来处理配电网图模型这样结构不规则的非欧氏空间数据。

GCN通过卷积邻接矩阵聚合节点邻居特征,结合当前节点特征进行线性变换和非线性激活,逐层堆叠实现对图结构的深度学习,最终更新所有节点特征。单层GCN卷积操作的公式为:

$$f(\mathbf{X}^{(l)}, \mathbf{A}) = \sigma \left(\hat{\mathbf{D}}^{-\frac{1}{2}} \hat{\mathbf{A}} \hat{\mathbf{D}}^{-\frac{1}{2}} \mathbf{X}^{(l)} \mathbf{W}^{(l)} \right) \quad (6)$$

式中: $f(\mathbf{X}^{(l)}, \mathbf{A})$ 为第 l 层GCN的输出, $\mathbf{X}^{(l)}$ 为第 l 层输入的节点特征矩阵, $\mathbf{A}$ 为邻接矩阵; $\sigma(\cdot)$ 为激活函数; $\hat{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 为重构后的邻接矩阵, $\mathbf{I}$ 为单位矩阵; $\hat{\mathbf{D}}$ 为 $\hat{\mathbf{A}}$ 的度矩阵; $\mathbf{W}^{(l)}$ 为第 l 层网络参数矩阵。




图1 配电网图模型

Fig.1 Distribution network diagram model

2 基于内嵌物理信息 GraphSAGE 的配电网最大供电能力计算模型

传统的图神经网络模型将目标节点的所有邻居节点的特征进行聚合,并使用该聚合特征来更新目标节点的特征。这种方法只能学习单一固定拓扑的图数据特征。文献[20]提出的 GraphSAGE 模型通过对目标节点邻域内的邻居节点先采样后特征聚合的方式,实现了未见数据的生成嵌入,对拓扑变化具有更强的适应能力。因此,本文在 GraphSAGE 模型的基础上进行改进,提出配电网最大供电能力计算模型。

2.1 边特征聚合与预训练

大多图神经模型只能对节点特征进行数据传递,无法充分考虑到边特征的影响,因此,本文对 GraphSAGE 模型进行改进,将配电网中所有节点相邻的联络线边特征聚合到节点特征上,保证在后续操作时能够充分考虑边特征的影响。

第 i 个节点的特征为 h_{vi} ,将其邻边特征聚合到节点特征上的步骤如下。

1)遍历边连接矩阵 e_{index} ,获取包含第 i 个节点所有邻边的集合 $E(i)$ 。

2)根据邻边集合 $E(i)$ 和边特征矩阵 e_{attr} 获取第 i 个节点所有邻边的特征,并将其进行平均聚合,得到

邻边聚合特征 $h_{E(i)}$ 。

3)将节点特征 h_{vi} 与邻边聚合特征 $h_{E(i)}$ 合并成第 i 个节点新的特征 h'_{vi} ,即:

$$h'_{vi} = \text{CONCAT}(h_{vi}, h_{E(i)}) \quad (7)$$

式中:CONCAT($\cdot$)为特征向量拼接函数。

图2给出了将邻边特征聚合到节点特征上的示意图。




图2 边特征聚合

Fig.2 Edge feature aggregation

图自编码器主要包括编码器和解码器,其模型结构如附录A图A1所示^[21]。

将2次GCN层作为编码器,获取最优的节点特征表示,过程如下:

$$Z = \text{GCN}(X, A) \quad (8)$$

式中: Z 为编码器操作后的最优节点特征;GCN($\cdot$)表示图卷积操作,计算方法见式(6)。本文中邻接矩阵 A 来自边连接矩阵 e_{index} 。

将矩阵内积操作作为解码器来重构配电网图结构,即:

$$\hat{A} = \sigma(ZZ^T) \quad (9)$$

低维度特征表示重构出的邻接矩阵与原邻接矩阵越相似,说明获得了更优的特征表示,因此,本文图自编码器模型的优化目标为交叉熵损失函数,如式(10)所示。

$$\text{Loss}(A, \hat{A}) = -\frac{1}{M} \sum y \ln y' + (1-y) \ln(1-y') \quad (10)$$

式中:Loss($\cdot$)为损失函数; M 为 A 中的元素数量; y 为原始邻接矩阵 A 中某元素(0或1); y' 为重构后邻接矩阵 $\hat{A}$ 中对应的元素(0~1)。

在节点采样前,本文模型通过图自编码器的编码和解码过程,保留配电网图模型的核心特征,滤除冗余特征,从而避免了节点采样过程中可能出现的特征丢失情况。

2.2 节点采样

GraphSAGE 模型通过邻居节点采样减少特征聚合的计算复杂度,避免大规模图模型的计算负担和过拟合问题,同时增强模型泛化能力,使其更适用于大规模配电网最大供电能力计算,并更好地适应配电网拓扑变化。

在节点采样过程中,遵循从内到外的顺序,以配电网中的每个节点为核心,可将整个配电网图结构划分成 K 层,即节点的 K 阶邻居节点。在第1轮采样过程中,根据边连接矩阵 e_{index} 获取每个节点的所有1阶邻居节点,然后从1阶邻居节点中随机采样 N_1 个节点,不足 N_1 个则使用所有1阶邻居节点。在第2轮采样过程中,获取每个节点的2阶邻居节点,随机采样 N_2 个节点,不足 N_2 个则使用所有2阶邻居节点。以此类推,这样位于第 l ($1 \leq l \leq K$)层的每个节点采样 N_l 个 K 阶邻居节点。

2.3 节点特征聚合

在后续公式中没有边特征,不会引起歧义,因此将节点特征 h_{vi} 直接写作 h_i 。在节点特征聚合过程中,整合采样邻居节点特征与自身特征,并通过自适应机制确保输出特征维度一致,同时多层聚合尽可能保留邻居特征,减少特征丢失。如附录A图A2所示,节点特征聚合遵循从外到内的原则,将第 K 层邻居节点特征聚合到对应的 $K-1$ 层邻居节点上,逐层聚合,最后聚合到中心节点上,具体节点聚合公式如附录A所示。

不同节点对配电网最大供电能力计算的影响程度是不同的,因此,本文参考图注意力神经网络,在邻居节点特征聚合过程中引入多头图注意力机制,即通过计算邻居节点的注意力系数,确定邻居节点对中心节点的影响程度大小。下面以 $K-1$ 层某节点 v 为例,采样出的 K 层邻居节点图注意力系数计算公式为:

$$\alpha_{ij} = \frac{\exp\left(\text{LeakyReLU}\left(\mathbf{a}\left(\mathbf{W}\mathbf{h}_i, \mathbf{W}\mathbf{h}_j\right)\right)\right)}{\sum_{K \in N(v)} \exp\left(\text{LeakyReLU}\left(\mathbf{a}\left(\mathbf{W}\mathbf{h}_i, \mathbf{W}\mathbf{h}_j\right)\right)\right)} \quad (11)$$

式中: α_{ij} 为注意力系数; $K \in N(v)$ 表示 K 是节点 v 的 K 层邻居节点; $\mathbf{W}$ 为学习权重矩阵; $\mathbf{a}$ 为可学习参数向量; $\text{LeakyReLU}(\cdot)$ 为非线性激活函数。

在根据式(11)计算出邻居节点的注意力系数后,将其纳入节点特征聚合过程中,得到新的节点特征聚合公式,即:

$$\mathbf{h}_{N(i)}^{K-1} = \text{Mean}\left(\mathbf{a}_{ij}^m \mathbf{h}_j^K, j \in N(i)\right) \quad (12)$$

$$\hat{\mathbf{h}}_v^{K-1} = \big\|_{m=1}^S \sigma\left[\mathbf{W}^K \text{CONCAT}\left(\mathbf{h}_{N(i)}^{K-1}, \mathbf{h}_v^{K-1}\right)\right] \quad (13)$$

式中: $\mathbf{h}_{N(i)}^{K-1}$ 为通过注意力机制聚合后的邻居节点特征; $\mathbf{h}_v^{K-1}$ 为节点自身特征; $\hat{\mathbf{h}}_v^{K-1}$ 为融合邻居节点特征后的节点特征; $\text{Mean}(\cdot)$ 为本文使用的平均聚合函数;“ $\|$ ”表示向量拼接; S 为注意力头数。加入多头注意力系数的特征聚合示意图如附录B图B1所示。

2.4 物理信息损失函数的构造

损失函数主要用于计算预测值与真实值之间的差异。平均百分比误差(mean absolute percentage

error, MAPE)作为一种常用的损失函数,公式如附录B所示。

然而,模型的计算性能往往受到数据集样本数量的影响,当样本较少时,预测精度可能达不到要求。增加样本数量不能完全解决该问题,且大部分情况下很难获取满足要求数量的样本。将神经网络模型与物理模型相结合,当模型进行训练时,约束模型搜索范围,在样本数量较少的情况下,使模型可以朝着符合物理可行性的方向收敛,从而保证收敛性和精度^[22]。物理信息模型化的方式主要有物理信息损失函数、物理信息初始化参数、基于物理信息的神经网络架构设计和混合物理-深度学习模型4种。本文主要采用物理信息损失函数的方式,将联络线容量约束、负荷转供后主变容量约束、DG容量约束和DG的 $N-1$ 安全约束这4种主要约束条件加入损失函数中,以确保模型在训练过程中的物理可行性。

1) 联络线容量约束损失为:

$$L_1 = \frac{1}{N} \sum_i \sum_j \left[\max\left(0, C_{ij\text{actual}} - C_{ij\text{rated}}\right) \right]^2 \quad (14)$$

式中: L_1 为联络线容量约束损失; $C_{ij\text{actual}}$ 为联络线 ij 的实际转供功率; $C_{ij\text{rated}}$ 为联络线 ij 的容量。

2) 负荷转供后主变容量约束损失为:

$$L_2 = \frac{1}{N_r} \sum_r \left[\max\left(0, T_{r\text{actual}} - (kT_{r\text{rated}} + D_{r\text{output}})\right) \right]^2 \quad (15)$$

式中: L_2 为主变容量约束损失; N_r 为主变数量; $T_{r\text{actual}}$ 为主变 r 负荷转供后实际所带负荷; $T_{r\text{rated}}$ 为主变 r 的额定容量; $D_{r\text{output}}$ 为与主变 r 互联的DG可输出有功。

3) DG容量约束为:

$$L_3 = \frac{1}{N_t} \sum_t \left[\max\left(0, D_{t\text{actual}} - D_{t\text{capacity}}\right) \right]^2 \quad (16)$$

式中: L_3 为DG容量约束损失; N_t 为DG数量; $D_{t\text{actual}}$ 为负荷转供后第 t 个DG实际所带负荷; $D_{t\text{capacity}}$ 为第 t 个DG容量。

4) DG的 $N-1$ 安全约束为:

$$L_4 = \frac{1}{N_t} \sum_t \sum_r \left[\max\left(0, D_{t\text{load}} + M_{r\text{load}} - kM_{r\text{rated}}\right) \right]^2 \quad (17)$$

式中: L_4 为DG的 $N-1$ 安全约束损失; $D_{t\text{load}}$ 为第 t 个DG所带负荷; $M_{r\text{load}}$ 为与DG相连主变 r 所带负荷; $M_{r\text{rated}}$ 为与DG相连主变 r 的容量。

总的损失函数 L_C 表示上述函数加权之和,即:

$$L_C = \lambda_m M_{\text{APE}} + \lambda_1 L_1 + \lambda_2 L_2 + \lambda_3 L_3 + \lambda_4 L_4 \quad (18)$$

式中: M_{APE} 为MAPE,其计算公式如附录B式(B1)所示; $\lambda_m, \lambda_1 - \lambda_4$ 分别为各损失函数的比例。

本模型损失函数由两部分组成,第1部分强制对实验数据进行拟合,第2部分强制神经网络与物理知识保持一致。

2.5 配电网最大供电能力计算框架

基于改进 GraphSAGE 的配电网最大供电能力

计算模型如附录 B 图 B2 所示。该模型主要由四部分组成,分别为输入层、边特征聚合与图自编码器预训练层、基于多头图注意力机制改进的 GraphSAGE 层和全连接层。

利用本文模型计算配电网最大供电能力的流程如下:

1)考虑配电网拓扑及各节点和联络线特征,修改新能源节点并入数量和有功出力,构建配电网最大供电能力数据集,并将其划分为训练集、验证集和测试集;

2)在输入层将配电网拓扑结构转化成图数据输入模型中,每个节点和边有其相应特征向量,节点连接关系由边连接矩阵描述;

3)考虑配电网联络线对最大供电能力的影响,将与主变、新能源和负荷节点相邻的联络线特征聚合到节点特征上,然后利用图自编码器预训练层学习图的特征表示,提高模型性能;

4)在 GraphSAGE 层进行节点采样,并计算采样到的邻居节点的注意力系数,通过加入多头注意机制的节点特征聚合过程聚合节点特征;

5)将特征聚合后的全图特征输入全连接层,输出配电网最大供电能力计算结果。

3 算例分析

3.1 数据集生成

配电网图模型结构如图 1 所示,变压器、线路详细数据见文献[3],不同样本数据如附录 C 表 C1 所示。

在原始配电网拓扑结构上,随机在不同的节点上加入 DG 节点,接入的新能源节点总数控制在 1~5 个,并改变 DG 节点的有功出力,以模拟配电网中新能源节点的不断接入以及新能源出力不稳定性和波动性对配电网最大供电能力的影响。通过第 1 章中的配电网最大供电能力算法计算出 5000 种不同场景下的配电网最大供电能力,并生成样本集。将 5000 份样本按照 7:2:1 的比例划分成训练集、验证集和测试集。

3.2 参数设置

通过多次实验得到最优模型性能时,参数设置如附录 C 表 C2 所示。该参数只适用于本文的配电网图模型,对不同配电网图模型需要重新进行优化调参。

3.3 损失和精度对比实验

3.3.1 实验指标

选取 MAPE 和预测精度作为实验指标,预测精度 A_{cc} 计算公式为:

$$A_{cc} = 1 - M_{APE} \quad (19)$$

3.3.2 本文模型与传统图神经网络模型对比

分别采用 GCN 模型、传统的 GraphSAGE 模型和本文模型进行实验,并使用相同的样本进行训练,对比不同模型训练集损失和精度,分别如图 3 和附录 C 图 C1 所示。




图3 训练集损失

Fig.3 Loss of training set

实验结果表明:GCN 模型在迭代次数较少时因未能充分学习全局特征而导致损失和精度波动较大,曲线在迭代次数超过 100 后趋于平稳;传统 GraphSAGE 模型因节点采样而导致特征丢失,训练精度略低于 GCN 且波动较大;本文模型通过引入图自编码器预训练和多头图注意力机制,关注重要节点特征,并结合内嵌物理信息,克服了 GraphSAGE 的缺陷,在损失和精度上均优于 GCN,且波动显著减小。

在每次迭代训练过程中,使用训练后的模型计算验证集中各样本的配电网最大供电能力,绘制对应的损失和精度随迭代次数变化的曲线,分别如图 4 和附录 C 图 C2 所示。在各模型训练完成后,得到各模型测试集损失和精度对比,如附录 C 表 C3 所示。图 4 和图 C2 的验证集实验结果与训练集实验结果基本相同。表 C3 进一步证明了本文模型在损失和精度方面优于 GCN 模型和 GraphSAGE 模型。




图4 验证集损失

Fig.4 Loss of verification set

3.4 适应能力对比实验

3.3 节的实验表明,GraphSAGE 模型在损失和精度上并未优于 GCN 模型,但本文通过对 GraphSAGE

的改进提升了其性能。GraphSAGE的核心优势在于其拓扑适应能力和泛化性,通过部分邻居节点特征聚合更新中心节点特征,即使仅知部分节点信息,也能生成整个配电网的节点特征表示。本文模型进一步加入物理信息约束,增强了对拓扑变化的适应能力。本节重点验证GCN、GraphSAGE和本文模型在新能源并网节点增多或拓扑变化时,能否精确计算配电网最大供电能力。

3.4.1 对新能源并网节点增加的适应能力对比

随着新能源并网节点的增加,传统优化算法难以适应配电网拓扑的变化,而本文模型可以有效地解决这一问题。基于3.1节的配电网最大供电能力数据集构建方法,在原有新能源节点的基础上增加节点数,GCN、GraphSAGE和本文模型的预测精度分别为91.72%、92.48%和96.26%。

不难看出,当增加新能源并网节点时,各模型预测精度均下降,GCN下降幅度较大,GraphSAGE模型可适应能力和拓展能力更强,本文对GraphSAGE模型进行改进,进一步提升了其优势。

3.4.2 对配电网拓扑变化的适应能力对比

配电网的拓扑结构并非一成不变,会因多种因素而发生变化。与3.4.1节相同,拓扑变化必然导致传统优化算法失效,本节设计实验测试GCN、GraphSAGE和本文模型对拓扑变化的适应能力。

固定新能源并网节点数和节点位置,在第11、17、27个负荷节点上各并入1个新能源节点,如图1所示。考虑故障或网络拓扑重构情况,更改配电网站间联络线,对比各模型拓扑变化情况下的最大供电能力预测精度。配电网拓扑变化情景如下:情景1,断开第27个节点和第29个节点之间的站间联络线;情景2,在第41个节点和第46个节点之间增加站间联络线;情景3,更改第27个节点和第29个节点以及第28个节点和第36个节点之间的站间联络线,将第27个节点与第36个节点连接,将第28个节点与第29个节点连接。

上面3种拓扑变化主要包括站间联络线的增加和减少以及节点之间站间联络线的变更。图5给出了各模型对拓扑变化情景的预测精度对比。




图5 对配电网拓扑变化情景的预测精度对比

Fig.5 Comparison of prediction accuracy of distribution network topology change scenarios

由图5可知:断开原配电网拓扑中的站间联络线或者增加站间联络线对各模型预测精度的影响不大,3个模型预测精度均能保持在90%以上;配电网原拓扑中站间联络线发生变更且两节点站间联络线互换,对各模型预测精度影响很大,GCN和GraphSAGE模型的预测精度下降到80%多。

GCN模型和GraphSAGE模型在原拓扑情况下的预测精度相差不大,但是当配电网拓扑变化时,GCN模型预测精度下降幅度明显高于GraphSAGE模型,其主要原因在于GCN在面对全新的配电网拓扑时,仍然按照原来的拓扑进行识别。本文模型对GraphSAGE模型进行改进,当配电网拓扑变化时,本文模型可以自动调节节点间的注意力系数,使得模型对配电网拓扑变化的适应能力进一步提升。

3.5 内嵌物理信息前后对比

在应用本文模型进行配电网最大供电能力在线计算的过程中,实际的配电网拓扑通常规模很大,使得构建配电网最大供电能力数据集会异常困难且工作量巨大。为此,本节减少训练样本数,对比各模型在小样本情况下对最大供电能力计算结果的准确率。设置对比模型A—D,分别表示GCN模型、GraphSAGE模型、本文改进的GraphSAGE模型(损失函数未内嵌物理信息)、本文改进的GraphSAGE模型(损失函数内嵌物理信息)。分别利用1500、1000、500份样本对4种模型进行训练,训练完成后,用测试集进行测试,预测精度对比结果如表1所示。

表1 不同数量样本下各模型预测精度对比

Table 1 Comparison of forecasting accuracy of each model under different numbers of samples

样本数	预测精度 / %			
	模型A	模型B	模型C	模型D
500	85.35	84.56	88.96	93.59
1000	88.54	89.75	92.67	94.85
1500	92.24	93.57	95.24	96.64

在训练样本减少的情况下,4种模型预测精度均有不同程度的下降。根据模型C和模型D的对比,损失函数内嵌物理信息使得模型在小样本情况下的预测精度更高,这主要是由于内嵌物理信息可以为模型提供强大的约束和指导,帮助模型更好地理解数据背后的物理本质,使模型只在符合物理信息的情况下进行搜索,避免模型在有限的数据上过度拟合或产生不合理的预测结果,即使在训练样本数只有500的情况下,模型D的预测精度仍然可以达到93.59%。

3.6 计算速度对比

通过3.1节中随机接入新能源节点以及改变新能源有功出力的方式,生成1000份与数据集不同的实验样本。分别采用本文算法和第1章的传统优化

算法对配电网最大供电能力进行计算,2种算法的计算时间分别为33.81430 s和3.28459 s。

在对本文模型进行大量样本训练后,运用该模型对1000种不同场景下的配电网最大供电能力进行计算,其用时仅为传统优化算法的1/10,因此,采用本文算法计算配电网最大供电能力,更能满足实时性要求。

4 结论

本文构建配电网最大供电能力数据集,并利用改进的 GraphSAGE 建立配电网最大供电能力计算模型,通过对比实验得到如下结论。

1) GraphSAGE 模型节点采样和节点特征聚合方式与 GCN 模型不同,通过逐步聚合邻居信息能够捕捉图的局部和全局特征,因此当配电网拓扑发生微小变化时,本文模型仍能较准确地计算出最大供电能力。

2) 本文模型通过加入图自编码器预训练和多头注意力机制的节点特征聚合对 GraphSAGE 模型进行改进,使得配电网最大供电能力计算精度得到提升。

3) 将物理信息融入 GraphSAGE 模型,使结果更加符合现实物理常识,在原理层面提高了模型的鲁棒性、可信性及可解释性。通过调整物理信息损失函数和传统损失函数的权重,使得模型兼顾了在小样本情况下的预测精度和收敛性能,降低了模型训练要求,可行性强。

4) 本文模型在配电网新能源节点增多和转供联络线变化情况下,均能较为精确地预测出配电网最大供电能力,更符合配电网实际情况与未来新能源并网的趋势。

本文模型仅能适应配电网拓扑的小变化,且未考虑主变功率反送和电压越限的情况,后续笔者会考虑将物理信息嵌入模型,设计一种能够适应多约束规模化配电网的最大供电能力计算模型。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 戴玉臣,徐伟,华文,等. 计及源网荷交互影响的区域电网热稳安全供电区间计算方法[J]. 电力自动化设备,2023,43(2):178-183.
- [2] 陈雪明. 基于供电单元的配电网多场景负荷转供研究[D]. 南京:东南大学,2022.
- [3] 肖峻,谷文卓,郭晓丹,等. 配电系统供电能力模型[J]. 电力系统自动化,2011,35(24):47-52.
- [4] 郭焱林,刘俊勇,魏震波,等. 配电网供电能力研究综述[J]. 电力自动化设备,2018,38(1):33-43.
- [5] 祖国强,郝子源,黄旭,等. 考虑低压台区柔性互联的配电网最大供电能力[J]. 电力系统自动化,2023,47(7):84-93.
- [6] 李沛然. 计及风光不确定性的主动配电网供电能力评估[D]. 贵阳:贵州大学,2021.
- [7] 何汉文,伍肇龙,容慧娴,等. 基于转供通道关联矩阵的配电网供电能力评估方法[J]. 广东电力,2019,32(8):92-100.
- [8] 朱嘉麒,董树锋,徐成司,等. 考虑多次转供的配电网最大供电能力评估方法[J]. 电网技术,2019,43(7):2275-2282.
- [9] 党建,闫运江,贾嵘,等. 基于图计算的配电网最大供电能力评估研究[J]. 电网技术,2022,46(3):1039-1049.
- [10] 肖峻,蔡仲伟. 配电网的最小供电能力:定义、模型、求解和应用[J]. 电力自动化设备,2024,44(2):34-41.
- [11] 刘忠雨,李彦霖,周洋. 深入浅出图神经网络[M]. 北京:机械工业出版社,2020:96-138.
- [12] 李骁皓,梁志坚,刘敏,等. 基于图多任务学习的潮流分析模型[J]. 南方电网技术,2023,17(11):33-40.
- [13] 李佳伟,王小君,和敬涵,等. 基于图注意力网络的配电网故障定位方法[J]. 电网技术,2021,45(6):2113-2121.
- [14] 刘德澳,董明刚,叶威,等. 基于图神经网络的非均匀风电场功率预测方法[J]. 太阳能学报,2023,44(11):279-286.
- [15] 黄蔓云,郭镜玮,臧海祥,等. 基于消息传递图神经网络的电力

- 系统状态估计[J]. 电网技术, 2023, 47(11): 4396-4409.
- HUANG Manyun, GUO Jingwei, ZANG Haixiang, et al. State estimation of power system based on a message passing neural network[J]. Power System Technology, 2023, 47(11): 4396-4409.
- [16] 张雷, 李晓影, 张沛, 等. 基于组合神经网络的配电网故障定位方法[J]. 电力系统及其自动化学报, 2023, 35(9): 87-94.
- ZHANG Lei, LI Xiaoying, ZHANG Pei, et al. Fault location method for distribution network based on combined neural network[J]. Proceedings of the CSU-EPSC, 2023, 35(9): 87-94.
- [17] 周芷汀, 李辉, 郑杰, 等. 物理信息与时空图数据联合驱动的海上风电并网系统频率响应预测[J]. 电力自动化设备, 2025, 45(12): 82-90.
- ZHOU Zhiting, LI Hui, ZHENG Jie, et al. Frequency response prediction of offshore wind-integrated power system driven by physics-informed spatiotemporal graph learning[J]. Electric Power Automation Equipment, 2025, 45(12): 82-90.
- [18] 林苑, 赵晋斌, 孙明琦, 等. 新型电力系统下基于物理信息LSTM网络的电力变压器状态评估方法[J]. 电力系统保护与控制, 2025, 53(14): 133-141.
- LIN Yuan, ZHAO Jinbin, SUN Mingqi, et al. Power transformer condition assessment method based on physics-informed LSTM network in the context of new power systems[J]. Power System Protection and Control, 2025, 53(14): 133-141.
- [19] 刘金波, 郭庆来, 张靖, 等. 机理数据融合驱动的图神经网络状态估计方法[J/OL]. 电力系统自动化. [2026-01-08]. <https://link.cnki.net/urlid/32.1180.TP.20251120.1140.002>.
- [20] HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, USA: Curran Associates Inc., 2017: 1025-1035.
- [21] 杨智超. 基于图自编码的配电网小电流接地故障区段定位方法[D]. 北京: 北京交通大学, 2023.
- YANG Zhichao. Location method of small current ground fault section in distribution network based on graph autoencoder[D]. Beijing: Beijing Jiaotong University, 2023.
- [22] HUANG B, WANG J H. Applications of physics-informed neural networks in power systems—a review[J]. IEEE Transactions on Power Systems, 2023, 38(1): 572-588.

作者简介:

刘宝龙(2000—), 男, 硕士研究生, 主要研究方向为人工智能在电力系统中的应用(**E-mail**: lb1602326211@163.com);

陈中(1975—), 男, 教授, 博士研究生导师, 通信作者, 主要研究方向为电力系统规划运行与控制、人工智能在电力系统中的应用(**E-mail**: zhongchen@seu.edu.cn)。

(编辑 王锦秀)

Maximum power supply capacity calculation of distribution network based on GraphSAGE model embedded with physical information

LIU Baolong¹, CHEN Zhong¹, WANG Yi², QIAO Yong¹, YAN Haowei¹

(1. School of Electrical Engineering, Southeast University, Nanjing 210018, China;

2. State Key Laboratory of Smart Grid Protection and Control of State Grid Electric Power Research Institute Co., Ltd., Nanjing 211106, China)

Abstract: Aiming at the problems of the calculation of the maximum power supply capacity of distribution network, such as hardly satisfied physical constraints, inefficiency, and poor topological adaptability, a maximum power supply capacity calculation method of distribution network is proposed based on a physics information embedded graph sample and aggregate(GraphSAGE) model, which can realize the generation and embedding of unseen information and quickly calculate the maximum power supply capacity of distribution network under varying scenarios. The physical constraints are embedded into the GraphSAGE model, which enforces the model to satisfy the physical laws during the training, improves the model interpretability and reduces the requirement on dataset number and quality. The shortages of unable considering the edge information in the model and node feature loss are overcome by edge feature aggregation and graph autoencoder pretraining. A multi-head attention mechanism is integrated into the node feature aggregation process after node sampling, which improves the model calculation accuracy. The results of the example and comparative experiment show that the proposed method has superior adaptability to renewable energy output and topology change of distribution network.

Key words: graph convolutional network; distribution network; total supply capability; physical information; graph attention mechanism