

基于图神经网络的高效最优潮流模型简化方法

李忠行¹, 黄煜¹, 胡松林¹, 王毅²

¹ 南京邮电大学碳中和先进技术研究院 江苏南京

² 国网电力科学研究院有限公司 (南瑞集团有限公司) 江苏南京

【摘要】针对大规模输电网络最优潮流 (Optimal Power Flow, OPF) 计算中存在的计算复杂、约束冗余等问题, 提出一种基于图神经网络 (Graph Neural Network, GNN) 的高效最优潮流模型简化方法。首先, 基于支路潮流计算结果和载流率阈值 (如 90%) 定义关键支路, 并构建包含节点特征、边特征与邻接矩阵的电网图结构数据; 其次, 训练 GNN 模型实现关键支路状态预测, 识别电网中可能发生越限的支路集合; 最后, 以 GNN 预测得到的关键支路集合为基础, 构建约束显著减少的简化最优潮流 (Reduced Optimal Power Flow, ROPF) 模型。以自建 73 节点输电网络为算例进行仿真分析, 结果表明: GNN 模型在 90% 载流率阈值下的关键支路预测误差仅为 OPF 的 2.47%, ROPF 求解时间较 OPF 缩短 13.2%。

【关键词】最优潮流; 图神经网络; 关键支路; 模型简化; 载流率阈值

【收稿日期】2025 年 3 月 6 日

【出刊日期】2025 年 4 月 6 日

【DOI】10.12208/j.jeea.20250106

An efficient optimal power flow model reduction method based on graph neural networks

Zhongxing Li¹, Yu Huang¹, Songlin Hu¹, Yi Wang²

¹Institute of Advanced Technology for Carbon Neutrality, Nanjing University of Posts and Telecommunications, Nanjing, Jiangsu

²State Grid Electric Power Research Institute(NARI Group Corporation), Nanjing, Jiangsu

【Abstract】Addressing the challenges of computational complexity and redundant constraints in Optimal Power Flow (OPF) calculations for large-scale transmission networks, this paper proposes an efficient OPF model simplification method based on Graph Neural Networks (GNNs). First, critical branches are defined based on branch power flow calculation results and current carrying capacity thresholds (e.g., 90%), and power grid graph-structured data including node features, edge features, and adjacency matrices are constructed. Second, a GNN model is trained to predict the states of critical branches, identifying the set of branches in the power grid that are likely to violate limits. Finally, based on the critical branch set predicted by the GNN, a Reduced Optimal Power Flow (ROPF) model with significantly fewer constraints is formulated. Simulation analysis is conducted using a self-built 73-node transmission network. Results show that under the 90% loading threshold, the prediction error of key branches using the GNN model is only 2.47% compared to the original OPF, and the solution time of ROPF is reduced by 13.2%.

【Keywords】Optimal power flow; Graph neural network; Critical branches; Model reduction; Loading threshold

引言

在实现碳达峰、碳中和目标的背景下, 我国电力系统正在经历以风电、光伏等可再生能源为主体的快速转型, 电网运行的不确定性与复杂性日益显著^[1-2]。风能和光伏等新能源发电受天气条件影响剧

烈波动, 电网负荷特性亦随需求侧用能结构的变化呈现多样性特征, 这对传统确定性潮流调度优化方法的实时性与准确性提出了严峻挑战^[3-4]。

OPF 作为电网运行分析与经济调度的重要工具, 旨在优化发电资源配置, 在满足安全约束的同时实

作者简介: 李忠行 (2001-) 男, 硕士, 研究方向为电力系统运行优化调度; 黄煜 (1992-) 男, 副教授, 博士, 研究方向为电力调度自动化电网分析与控制研究。

现系统运行经济性最优, 广泛应用于电力市场调度与电网规划领域^[5]。传统 OPF 通常采用牛顿-拉夫逊法、内点法等精确求解方式, 虽然理论成熟、结果精确, 但计算负担较高, 在实时调度需求下显现出明显的不足^[6]。为提升大规模系统的实时求解效率, 业内也广泛采用直流潮流 (DC-OPF) 等线性化近似方法。尽管 DC-OPF 在潮流方程建模方面存在一定简化假设, 但其计算速度快、数值稳定性强, 已成为工程应用中新能源高渗透率场景下快速潮流计算的重要手段之一^[7]。

近年来, 随着深度学习技术的发展, 一些研究者尝试将机器学习方法引入 OPF 问题, 以提升模型求解效率与泛化能力。例如, 文献[8]采用多层感知机 (MLP) 直接拟合安全约束直流潮流解, 取得了较好的计算加速效果; 文献[9]提出基于卷积神经网络 (CNN) 框架的 OPF 解映射模型, 利用卷积结构增强对节点局部邻域特征的提取能力; 文献[10]将物理信息嵌入神经网络 (PINN) 用于 AC-OPF 问题中, 提高了模型物理可解释性与解的可行性。但这类方法通常以简单特征输入为主, 忽略了电网固有的拓扑结构信息, 预测精度受到明显制约^[11]。GNN 作为一种专门处理图结构数据的深度学习模型, 近年来在电网运行分析方面逐渐崭露头角^[12-13]。文献[14]率先引入 GNN 结构处理电网拓扑, 显著提升了潮流预测精度与拓扑自适应能力。随后, 文献[15]提出拓扑感知 GNN 模型, 结合电价与潮流局部特征, 进一步提升了 AC-OPF 预测精度与模型可迁移性。

然而, 目前已有的基于 GNN 的 OPF 研究多关注于直接预测完整潮流状态, 未充分挖掘 GNN 在模型约束简化方面的潜力。如何利用 GNN 准确识别电网中易超出支路热极限的支路集合, 从而减少 OPF 约束规模, 实现快速且准确的潮流计算, 仍然缺乏深入研究。

为此, 本文提出一种基于图神经网络的最优潮流模型简化方法。该方法利用 GNN 有效提取负荷特征、发电容量信息和网络拓扑关系, 精确预测输电网络中易超出支路热极限的关键支路, 仅针对这些支路施加潮流约束, 从而形成约束数量显著减少的简化 OPF 模型。本文在 Pycharm 平台搭建实验仿真环境, 以自建 73 节点输电网络为研究对象, 根据支路潮流与额定热极限的比例, 设定不同支路载流率阈值, 训练 GNN 模型动态筛选关键支路集合, 构建

ROPF 模型。仿真结果验证了本文所提出的 GNN 辅助简化 OPF 方法在保证接近原始完整模型计算精度的同时, 能够有效减少求解时间, 具备良好的工程应用价值, 适用于大规模电网场景下的最优潮流计算与实时调度需求。

1 OPF 模型简述

OPF 问题是电力系统运行优化与调度的重要基础工具, 旨在在满足安全约束的前提下, 优化发电资源配置, 实现系统经济运行目标。根据建模精度与应用场景不同, OPF 模型主要分为 AC-OPF 和 DC-OPF 两类。本文基于 DC-OPF 模型开展研究, 结合 GNN 实现关键约束筛选, 构建约束数量显著减少的简化模型, 以提升潮流计算效率。

1.1 AC-OPF 模型

AC-OPF 问题以发电运行成本最小化为目标, 考虑节点功率平衡、发电机出力范围、节点电压幅值约束及支路热极限约束条件, 其数学模型可表示为^[16]:

$$\min_{P_G, Q_G, V, \theta} \sum_{i \in G} (a_i P_{G,i}^2 + b_i P_{G,i} + c_i) \quad (1)$$

$$P_{G,i} - P_{D,i} = V_i \sum_{j=1}^N V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \quad (2)$$

$$Q_{G,i} - Q_{D,i} = V_i \sum_{j=1}^N V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \quad (3)$$

$$P_{G,i}^{\min} \leq P_{G,i} \leq P_{G,i}^{\max} \quad (4)$$

$$Q_{G,i}^{\min} \leq Q_{G,i} \leq Q_{G,i}^{\max} \quad (5)$$

$$V_i^{\min} \leq V_i \leq V_i^{\max} \quad (6)$$

$$|S_{ij}| \leq S_{ij}^{\max} \quad (7)$$

式中: G 为发电机集合; N 为节点集合; $P_{G,i}$, $Q_{G,i}$ 分别为节点 i 的有功、无功发电量; a_i , b_i , c_i 为对应机组的成本系数; $P_{D,i}$, $Q_{D,i}$ 为节点 i 的有功、无功负荷; V_i 为节点电压幅值; G_{ij} , B_{ij} , θ_{ij} 分别表示节点 i 、 j 间的电导、电纳与相角差。 $S_{ij}^{\max}$ 表示支路 ij 的热稳定极限。

1.2 DC-OPF 模型

DC-OPF 模型是对 AC-OPF 模型进行适当假设与简化后得到的一种近似潮流模型, 该模型的潮流方程简化为仅包含节点相角差和支路电纳的线性关系^[7]:

$$P_{G,i} - P_{D,i} = \sum_{j=1}^N B_{ij}^{DC} (\theta_i - \theta_j) \quad (8)$$

式中: B_{ij}^{DC} 为直流潮流模型下支路电纳; θ_i, θ_j 分别表示节点 i, j 的电压相角。

DC-OPF 模型在大规模电网的实时优化调度与市场分析中得到广泛应用, 其计算简单高效, 易于求解。然而, 在实际工程应用中, 特别是大规模电网系统中, 为保障系统安全性, 传统的 DC-OPF 通常需要考虑大量的支路热极限约束, 导致求解规模较大。事实上, 由于支路实际运行状况差异明显, 仅有部分支路在特定负荷条件下可能接近或超过支路热极限, 大量支路冗余约束的存在使模型复杂度和计算量显著增加。因此, 如何有效识别电网运行状态下的关键支路集合, 仅针对这些关键支路设置潮流约束, 以减少冗余约束规模, 成为提高 OPF 模型求解效率的重要研究课题之一。

2 基于图神经网络的 ROPF 模型构建

为减少模型求解复杂性并提高计算效率, 本文提出一种基于 GNN 的 ROPF 模型框架。该框架利用 GNN 对电网运行状态进行高效预测, 以动态识别可能出现越限风险的关键支路, 仅对这些关键支路设置潮流约束, 从而显著降低 OPF 求解规模。具体实现方式如下:

(1) 数据准备与标签定义

利用 DC-OPF 计算若干典型运行场景下的潮流数据, 并记录每条支路的潮流值, 根据每条支路的有功潮流定义支路状态标签 y_{ij} :

$$y_{ij} = \begin{cases} 1, & |P_{ij}| \geq \alpha \cdot P_{ij}^{\max} \\ 0, & |P_{ij}| < \alpha \cdot P_{ij}^{\max} \end{cases} \quad (9)$$

式中: P_{ij} 为支路 ij 的有功潮流, $P_{ij}^{\max}$ 为支路 ij 的额定热极限, α 为设定的支路载流率阈值。当 $y_{ij}=1$ 时, 表明支路 ij 上的潮流已达到额定热极限, 存在越限风险。

(2) GNN 输入特征设计

本文将电网建模为包含节点和边的图结构, 其中图拓扑通过邻接矩阵定义, 描述电网中节点间的连接关系。节点特征包括节点负荷、发电容量等信息, 边特征包括支路电抗、支路额定热极限等参数。通过 GNN 模型的图卷积过程, 结合邻接矩阵信息实现节点特征与边特征的有效交互与更新, 充分挖掘电网拓扑结构与运行状态之间的内在关联。

(3) GNN 模型训练与关键支路预测

采用图卷积神经网络进行监督学习, 以电网拓扑信息、节点负荷特征、支路特征作为模型输入, 以支路状态标签作为监督信号进行训练。训练过程中, 采用多分类交叉熵损失函数衡量模型预测结果与真实标签之间的差异。训练完成后, 给定任一运行工况下的特征输入 (包括节点负荷特征、发电机容量信息及支路参数特征), 模型可快速预测各支路的状态标签。定义预测状态标签为 1 的支路构成关键支路集合 $\mathbf{C}_{critical}$:

$$\mathbf{C}_{critical} = \{(i, j) | y_{ij} = 1\} \quad (10)$$

在 ROPF 模型构建过程中, 针对 GNN 预测得到的关键支路集合 $\mathbf{C}_{critical}$, 仅对该集合内的支路施加潮流约束, 即式 (7) 改进为:

$$|P_{ij}| \leq P_{ij}^{\max}, \forall (i, j) \in \mathbf{C}_{critical} \quad (11)$$

在完成关键支路判别后, 筛选出的关键支路集合被纳入 ROPF 模型的约束集, ROPF 问题采用 DC-OPF 模型进行求解, 最终获得优化结果, 整体流程如图 1 所示。

3 图神经网络模型设计与训练

GNN 具备优秀的图结构数据处理能力, 能够有效提取电网拓扑结构与运行状态之间的深层关联特征。本文基于 Spektral 框架, 设计并训练了 GNN 模型用于关键支路筛选, 同时构建卷积神经网络 (Convolutional Neural Network, CNN) 和全连接神经网络 (Neural Network, NN) 模型作为对比, 评估 GNN 模型在处理电网数据中的性能优势。

3.1 图数据构建

针对如图 2 所示的 73 节点输电网络图结构及电网运行数据, 构建图结构数据, 包括节点特征矩阵、边特征矩阵与邻接矩阵, 作为 GNN 模型输入, 以全面表征电网的拓扑特性和运行特征。

(1) 节点特征设计

节点特征矩阵 X 包含以下 5 类特征: 节点有功负荷 $P_{D,i}$ 、节点上发电机的有功出力 $P_{G,i}$ 上下限、节点度数 D_i (连接该节点的支路数量)、节点类型 T_i (PQ 节点、PV 节点、平衡节点)。节点特征具体构造为:

$$X_i = [P_{D,i}, P_{G,i}^{\max}, P_{G,i}^{\min}, D_i, T_i] \quad (12)$$




图1 基于 GNN 的 ROPF 模型构建流程图




图2 73 节点网络图结构

(2) 边特征设计

边特征矩阵 E 描述输电支路特性, 包括以下 3 类特征: 支路电抗 X_{ij} 、支路额定热极限 $P_{ij}^{\max}$ 、并联支路数 N_p 。边特征具体构造为:

$$E_{\text{edge}} = [X_{ij}, P_{ij}^{\max}, N_p] \quad (13)$$

(3) 邻接矩阵定义

邻接矩阵 A 用于描述电网节点间的连接关系, 定义如下^[17]:

$$A_{ij} = \begin{cases} 1, & (i, j) \in E \\ 0, & (i, j) \notin E \end{cases} \quad (14)$$

式中: E 表示电网中所有支路组成的边集合, 若节点 i 和节点 j 之间存在支路连接, 则记为 1, 否则记为 0。

3.2 GNN 模型架构设计与训练过程

(1) 模型架构设计

本文在 GNN 模型构建中采用 Spektral 框架提供的 XENetConv (XENet Convolution Layer) 图卷积层, 该层基于边增强机制, 能够同时处理节点与边的特征信息, 并通过多次信息交互与聚合, 有效捕捉电网拓扑结构与运行状态之间的复杂关联关系^[18]。模型结构如图 3 所示, 具体结构如下:

1) 输入层: 包括节点特征矩阵 X 、边特征矩阵 E 和邻接矩阵 A ;

2) 图卷积层: 采用多层 XENetConv 层对节点和边特征进行特征更新:

$$X', E' = \text{XENetConv}(X, E, A) \quad (15)$$

3) 输出层: 通过全连接层 (Dense 层) 对更新后的边特征进行支路状态分类, 判断每条输电支路是否达到关键运行状态, 最终为 ROPF 模型提供关键约束支路判别结果。




图3 GNN 模型结构示意图

(2) 训练过程与参数设置

GNN 模型训练采用多分类交叉熵损失函数, 定义为^[19]:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C y_{i,c} \log(p_{i,c}) \quad (16)$$

式中, N 为样本总数, C 为类别数量, $y_{i,c}$ 为第 i 个样本真实标签的独热编码值, $p_{i,c}$ 为模型预测的类别概率。

仿真数据通过生成不同运行工况下的潮流样本,

并随机划分为训练集、验证集和测试集, 分别占总数据集的 80%、10% 和 10%。模型训练过程中, 采用学习率 0.001, 批量大小为 200, 训练轮次设置为 250 轮。为避免模型过拟合, 训练过程中引入提前终止策略, 当连续 100 轮训练过程中验证集损失未明显降低时, 提前停止训练过程。

3.3 CNN 与 NN 对比模型构建

为进一步验证本文所提出的 GNN 模型在关键支路识别任务上的性能优势, 本文构建了结构相似的 CNN 模型和 NN 模型作为对比模型, 以实现公平、严谨的性能对比分析。对比模型的结构设计力求与 GNN 模型尽可能相似, 但区别在于 CNN 与 NN 模型并未使用网络拓扑的邻接矩阵, 仅利用节点特征和边特征分别进行特征提取与融合。

CNN 模型结构方面, 分别对节点特征和边特征单独使用 4 层一维卷积进行特征提取和局部空间特征捕获, 然后将提取后的节点和边特征通过一个 Dense 层融合, 实现输电支路状态的分类预测, 以确定支路是否为 ROPF 模型中的关键约束支路。

NN 模型则采用标准的多层全连接神经网络结构, 与 CNN 结构相似, 也分别针对节点特征和边特征进行特征提取。节点特征与边特征分别经过 4 层全连接层 (ReLU 激活函数) 提取特征后, 再通过一个 Dense 层融合, 以实现支路状态的分类判断。

CNN 和 NN 模型的训练数据划分、训练参数设置、训练轮次以及提前终止策略均与 GNN 模型完全一致, 以确保实验的公平性与可比性。

4 算例分析

本节围绕图 1 所示的 GNN 辅助 ROPF 模型构建流程, 系统分析 GNN 模型训练效果、预测性能、ROPF 求解质量以及不同支路载流率阈值设置对整体性能的影响。

4.1 GNN 模型训练过程

为验证所提出 GNN 模型在关键支路识别任务中的有效性, 本文基于自建 73 节点输电系统^[20]构建算例场景, 生成样本总数为 20000, 样本覆盖不同的负荷扰动工况。每个样本均通过 DC-OPF 模型进行潮流计算, 结合支路的潮流结果与额定热极限, 按照支路载流率是否超过 95% 的阈值进行关键支路标签标注。数据集按照 8: 1: 1 的比例划分为训练集、验证集和测试集, 用于模型训练与泛化能力评估。实验过程中所有模型均在 Pycharm 仿真平台上完成, 硬件环境为

i5-9300H 处理器, GTX1650 显卡, 16GB 内存。

图 4 展示了 GNN 模型在训练集与验证集上的损失函数下降趋势, 图 5 展示了相应的分类准确率变化曲线。可以观察到, 随着训练轮次的增加, 模型损失逐渐收敛, 准确率持续提升, 最终在验证集上表现稳定, 表明所提出的 GNN 模型具有良好的训练稳定性与识别能力, 为后续的关键支路筛选与 ROPF 模型构建奠定了基础。




图 4 GNN 模型训练与验证集交叉熵损失随轮次变化的曲线图




图 5 GNN 模型训练与验证集准确率随轮次变化的曲线图

4.2 ROPF 模型求解结果对比分析

为进一步验证所提出的基于 GNN 的 ROPF 模型在实际算例中的有效性, 本节针对 2000 个测试集样本, 利用训练完成的 GNN 模型进行关键支路状态预测, 并与样本的真实状态标签进行逐一对比分析。

首先, 统计了每个测试样本中 GNN 模型预测错误的支路数量分布情况, 如图 6 所示。由图中可见, 大部分测试样本预测错误的支路数量在 1~7 条之间。

进一步分析模型预测误差的具体类型, 将预测错误分为误报 (将非关键支路误判为关键支路) 与漏报 (将关键支路误判为非关键支路) 两种类别, 并统计每条支路在所有测试样本中的误报和漏报次数, 结果如图 7 所示。




图6 GNN模型在测试样本中的预测错误支路数量分布

接下来, 基于图7中GNN模型的预测结果, 进一步构建约束简化的ROPF模型。具体而言, 对于每个测试样本, 仅选取预测状态标签为1的支路(即图7中橙色条形所示的误报与正确识别的关键支路), 作为ROPF模型中所需施加潮流约束的关键支路集合, 其他支路不设置约束, 以此构建简化后的OPF问题并进行求解。




图7 各支路的误报与漏报次数统计结果

图8展示了采用上述简化模型进行ROPF求解后, 各支路在2000个测试样本中的越限次数统计情况。从图中可以发现, 部分支路在求解结果中频繁出现越限现象, 而这部分支路却并未被GNN模型成功识别并纳入约束集合, 说明存在关键支路被漏判的情况。

为了进一步明确造成求解误差的根源, 图9对比了ROPF模型中出现越限的支路与GNN模型预测中的漏报支路分布情况。对比结果表明, 图8中出现越限的支路与图7中蓝色条形(漏报)高度吻合, 说明ROPF模型中的潮流约束缺失主要源自

GNN模型的漏报行为。




图8 ROPF模型求解中各支路越限次数统计




图9 GNN模型漏报支路与ROPF模型越限支路对比

4.3 不同支路载流率阈值下的模型对比实验

为进一步验证GNN模型在不同支路载流率阈值条件下的关键支路识别能力及ROPF模型求解性能, 本文分别以70%、75%、80%、85%、90%和95%六个典型载流率阈值为基础, 进行了系统的对比实验。同时, 为了公平对比GNN模型与传统机器学习模型的性能, 本文选取了CNN与NN作为参照模型, 并在同等实验条件下评估了三类模型的表现, 重点关注预测误差与ROPF模型求解时间两个关键性能指标, 如图10所示。

从图10可以看出, 三种模型的预测误差均随支路载流率阈值的升高而有所增加。这是因为随着阈值提高, 支路的载流上限放宽, 部分原本处于越限状态的支路在高阈值条件下被视为正常, 导致被标记为关键支路的样本数量明显减少, 样本类别分布出现不均。此时模型在训练过程中更倾向于预测为非关键支路, 导致对关键支路的识别准确率下降, 整体预测误差随之升高。尽管如此, GNN模型在各

个阈值设定下始终保持最低的预测误差, 说明其在结构感知与特征提取方面具备更强的表达能力。同时由于关键支路数量减少, 模型约束规模缩小, 计

算复杂度下降, 使得 ROPF 模型求解时间均随着阈值提升而减少, 且 GNN 模型在所有阈值条件下均表现出最低的平均求解时间。




图 10 不同模型在不同支路载流率阈值下的关键支路预测百分比误差和 ROPF 模型求解时间

表 1 GNN 模型在不同支路载流率阈值下的 ROPF 测试样本性能指标比较

模型	时间/s	百分比误差/%	约束支路条数
OPF	314.72	-	108
ROPF	70%	1.53	32
	75%	2.24	27
	80%	2.09	24
	85%	2.39	21
	90%	2.47	18
	95%	2.92	16

为了更清晰地对比 GNN 模型在不同载流率阈值设定下的性能表现, 表 1 给出了使用 GNN 模型预测的 2000 个 ROPF 测试样本的平均求解时间、百分比误差以及约束支路条数等关键性能指标。百分比误差定义为 ROPF 模型与完整 OPF 模型的目标函数偏差率, 计算公式为:

$$\frac{|C_{\text{OPF}} - C_{\text{ROPF}}|}{C_{\text{OPF}}} \times 100\% \quad (17)$$

式中, C_{OPF} 和 C_{ROPF} 分别为在 OPF 和 ROPF 模型下的期望最小化成本。从表中数据可见, 完整的 OPF 模型 (即未进行约束简化) 约束支路总数为 108 条, 求解时间为 314.72 秒; 而基于 GNN 模型预测的 ROPF 模型显著减少了约束支路数量, 例如在 70% 载流率阈值下约束支路为 32 条, 求解时间缩短至 282.41 秒。随着阈值提升至 95%, 约束支路减少到

16 条, 平均求解时间降至 270.32 秒, 但预测误差也提升到 2.92%。尽管计算效率大幅提高, 但误差提升意味着部分关键支路可能未被有效识别, 需在实际应用时根据对精度和计算效率的权衡需求谨慎选择载流率阈值。

5 结论

本文针对大规模输电网络 OPF 计算问题, 提出了一种基于 GNN 的高效 OPF 模型简化方法, 通过 GNN 精准识别关键支路, 显著降低了模型约束规模并提升了计算效率。以自建 73 节点输电网络为算例进行仿真验证, 获得以下主要结论:

(1) 提出了基于支路载流率阈值定义关键支路的方法, 构建了考虑电网拓扑结构、节点特征和支路特征的图结构数据集, 通过 GNN 模型实现关键支路状态的高效预测。与传统 CNN 和 NN 模型相比, GNN 模型在关键支路预测误差上明显更低, 在 70%、

75%、80%的典型阈值条件下预测误差分别低至1.53%、2.24%和2.09%,体现出良好的预测准确性。

(2) 基于 GNN 模型预测的关键支路集合, 构建了约束显著减少的简化 ROPF 模型。在 2000 组测试样本中, 与完整 OPF 模型相比, ROPF 模型求解时间明显缩短, 如在 95%的阈值下, 约束支路数减少至 16 条, 求解时间降低至 270.32 s, 较完整 OPF 模型的 314.72 s 缩短约 14.1%, 有效提升计算效率。

(3) 不同载流率阈值的对比分析表明, 阈值越高, ROPF 模型约束数量和计算时间越少, 但关键支路预测误差相应增加。实际应用中, 应根据具体需求对计算效率与预测精度的权衡进行合理阈值选择, 为电网优化调度提供了明确的参数选择依据。

参考文献

- [1] 鲁宗相, 李昊, 乔颖. 从灵活性平衡视角的高比例可再生能源电力系统形态演化分析[J]. 全球能源互联网, 2021, 4(01): 12-18.
- [2] 徐潇源, 王晗, 严正, 等. 能源转型背景下电力系统不确定性及应对方法综述[J]. 电力系统自动化, 2021, 45(16): 2-13.
- [3] 王晗, 徐潇源, 严正, 等. 随机源-荷影响下配电网运行不确定性量化理论方法与应用展望[J]. 全球能源互联网, 2022, 5(03): 230-241.
- [4] 方晓涛, 严正, 王晗, 等. 考虑源-荷随机-模糊特征的配电网潮流不确定性量化方法[J]. 中国电机工程学报, 2022, 42(20): 7509-7524.
- [5] 郝广涛, 韩学山, 梁军, 等. 传统电力系统和高比例可再生能源电力系统调度与控制方法综述[J]. 电力系统及其自动化学报, 2020, 32(09): 10-19.
- [6] 陈思宇, 柴庆宣, 李延松, 等. 综合能源系统潮流及最优潮流计算模型与方法综述[J]. 热力发电, 2020, 49(07): 1-12+20.
- [7] 卫志农, 裴蕾, 陈胜, 等. 高比例新能源交直流混合配电网优化运行与安全分析研究综述[J]. 电力自动化设备, 2021, 41(09): 85-94.
- [8] Pan X, Zhao T, Chen M, et al. Deepopf: A deep neural network approach for security-constrained dc optimal power flow[J]. IEEE Transactions on Power Systems, 2020, 36(3): 1725-1735.
- [9] Yang K, Gao W, Fan R. Optimal power flow estimation using one-dimensional convolutional neural network[C]// 2021 North American Power Symposium (NAPS). IEEE, 2021: 1-6.
- [10] Nellikkath R, Chatzivasileiadis S. Physics-informed neural networks for ac optimal power flow[J]. Electric Power Systems Research, 2022, 212: 108412.
- [11] López-Cardona Á, Bernárdez G, Barlet-Ros P, et al. Proximal policy optimization with graph neural networks for optimal power flow[J]. arXiv preprint arXiv: 2212.12470, 2022.
- [12] Wu H, Wang M, Xu Z, et al. Graph attention enabled convolutional network for distribution system probabilistic power flow[J]. IEEE Transactions on Industry Applications, 2022, 58(6): 7068-7078.
- [13] Liao W, Bak-Jensen B, Pillai J R, et al. A review of graph neural networks and their applications in power systems[J]. Journal of Modern Power Systems and Clean Energy, 2021, 10(2): 345-360.
- [14] Donon B, Donnot B, Guyon I, et al. Graph neural solver for power systems[C]//2019 international joint conference on neural networks (ijcnn). IEEE, 2019: 1-8.
- [15] Liu S, Wu C, Zhu H. Topology-aware graph neural networks for learning feasible and adaptive AC-OPF solutions[J]. IEEE Transactions on Power Systems, 2022, 38(6): 5660-5670.
- [16] Zimmerman R D, Murillo-Sánchez C E, Thomas R J. MATPOWER: Steady-state operations, planning, and analysis tools for power systems research and education[J]. IEEE Transactions on power systems, 2010, 26(1): 12-19.
- [17] 侯磊, 刘金环, 于旭, 等. 图神经网络研究综述[J]. 计算机科学, 2024, 51(06): 282-298.
- [18] Grattarola D, Alippi C. Graph neural networks in tensorflow and keras with spektral [application notes][J]. IEEE Computational Intelligence Magazine, 2021, 16(1): 99-106.
- [19] Yaoshiang H, Samuel W. The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling[J]. IEEE Access, 2020, 8: 84806-84813.

- [20] Grigg C, Wong P, Albrecht P, et al. The IEEE reliability test system-1996. A report prepared by the reliability test system task force of the application of probability methods subcommittee [J]. IEEE Transactions on power systems, 1999, 14(3): 1010-1020.

版权声明: ©2025 作者与开放获取期刊研究中心(OAJRC)所有。本文章按照知识共享署名许可条款发表。

<https://creativecommons.org/licenses/by/4.0/>



OPEN ACCESS