

基于物理机理引导的数据驱动潮流计算方法

战鹏祥¹, 黄飞虎¹, 廖思睿¹, 彭舰¹, 徐文政¹, 李强², 张凌浩³

(1. 四川大学计算机学院, 四川省 成都市 610065;

2. 国网信息通信产业集团有限公司, 北京市 昌平区 102211;

3. 国网四川省电力公司电力科学研究院, 四川省 成都市 610000)

Data-driven Power Flow Calculation Method Guided by Physical Mechanism

ZHAN Pengxiang¹, HUANG Feihu¹, LIAO Sirui¹, PENG Jian¹, XU Wenzheng¹, LI Qiang², ZHANG Linghao³

(1. College of Computer Science, Sichuan University, Chengdu 610065, Sichuan Province, China;

2. State Grid Information & Telecommunication Group Co., Ltd., Changping District, Beijing 102211, China;

3. State Grid Sichuan Electric Power Research Institute, Chengdu 610000, Sichuan Province, China)

ABSTRACT: With the increase of uncertainty factors such as variability of renewable energy and load randomness in power systems, especially in $N-1$ contingency scenarios, efficient large-scale repetitive power flow calculation is becoming increasingly crucial for real-time security analysis. However, traditional power flow calculation methods based on physical mechanisms have higher computational costs and slower speeds, which can not meet the real-time risk assessment requirements. Data-driven power flow calculation methods have faster speed but rely heavily on data quality, and the prediction results need to be more consistent with physical mechanisms, making it challenging to apply to actual industrial scenarios. To address these issues, this paper introduces power system domain knowledge into data-driven models by constructing a deep learning model that complies with physical constraints, thereby improving the model's performance. It embeds the power system topology structure and physical formulas into the deep neural network structure through a gated mechanism and regularization strategy, enabling the model to adapt to changes in network topology in $N-1$ contingency scenarios. This paper conducts simulation experiments using the IEEE 14-node and IEEE 39-node systems with new energy access, investigating the model's performance in conventional and $N-1$ fault scenarios. The experimental results show that the proposed method has improved accuracy and compliance with physical constraints compared to traditional deep learning power flow calculation methods, and can effectively evaluate

the system's operating state under different fault conditions, verifying the effectiveness of the proposed method.

KEY WORDS: power flow calculation; data-driven; deep learning; physical mechanism guided; topology-gated

摘要: 随着电力系统可再生能源波动性、负荷随机性等不确定因素的增加,特别是在 $N-1$ 故障场景下,高效大规模重复潮流计算对于实时安全分析愈发重要。然而,基于物理机理的传统潮流计算方法计算成本较高,运算速度较慢,无法满足实时风险评估需求;数据驱动潮流计算方法运算速度较快,但严重依赖数据质量,预测结果与物理机理缺乏一致性,难以应用于实际工业场景。对此,该文在数据驱动模型上引入电力系统领域知识,构建符合物理约束的深度学习模型,提高了模型性能;采用门控机制和正则化策略,将电力系统拓扑结构和物理公式嵌入到深度神经网络结构,使模型能够适应 $N-1$ 故障场景下网络拓扑结构的变化。该文采用接入新能源的IEEE 14、IEEE 39以及IEEE 300节点系统进行仿真实验,在正常和 $N-1$ 故障场景中验证模型效果。实验结果表明,该文方法在误差精度和遵守物理约束的程度上,较传统深度学习潮流计算方法均有提升,可以有效地评估系统在不同故障情况下的运行状态,验证了所提方法的有效性。

关键词: 潮流计算; 数据驱动; 深度学习; 物理机理引导; 拓扑门控

DOI: 10.13335/j.1000-3673.pst.2024.0414

0 引言

潮流计算是确保电力系统稳定可靠运行的必要技术手段,用于计算电力系统中各节点电压、相角和功率等参数,以确定电力系统中各元件运行状态^[1]。目前,智能电网融合了可再生能源、分布式能源供应和电力市场化等变革性技术^[2-4],形成了动态、非线性、大规模的控制系統。然而,由于可再

基金项目: 四川省重点研发计划(2023YFG0112); 四川省重点实验室开放课题(SCITLAB-20001); 四川大学博士后交叉学科基金项目(10822041A2137)。

Project Supported by the Key R&D Program of Sichuan Province (2023YFG0112); Intelligent Terminal Key Laboratory of Sichuan Province (SCITLAB-20001); Post Doctoral Interdisciplinary Innovation Fund (10822041A2137).

生能源的高渗透率以及电动车数量持续增加等因素,电力系统的波动性和间歇性愈发明显^[5-8],给系统稳定性带来挑战,因此需要进行高效大规模重复潮流计算和实时安全分析,以保证系统的安全性和可靠性^[9]。尤其是在 $N-1$ 故障场景下,即系统中任何一个单一元件(如线路、变压器、发电机等)失效的情况,系统运营人员需要通过潮流计算评估故障或停运元件后系统的状态,确定是否存在过载或电压失调等问题,以采取相应措施保证系统安全和可靠运行。

潮流计算经典的解决方案是基于物理机理构造非线性方程组,并进行迭代求解^[1]。常用方法包括高斯-赛德尔迭代法^[10]、牛顿-拉夫逊迭代法^[11]以及相关改进算法^[12-14]等。高斯-赛德尔迭代法收敛速度取决于线性方程组的特性,容易出现收敛困难的问题。牛顿-拉夫逊迭代法是目前应用最广泛的潮流计算方法之一,通过对电力系统进行线性化处理,构造雅可比矩阵和迭代公式来逼近非线性方程组的解。这类基于物理机理的潮流计算方法属于数值方法,计算精度较高,但计算成本较大,计算速度较慢,尤其在大型电力系统中无法满足电力系统风险评估的实时性要求^[15]。

近年来,基于深度神经网络的潮流计算方法在电力系统分析和控制中得到了广泛探索,其强大的非线性拟合能力和数据特征挖掘能力备受关注。这些方法通常基于丰富的历史电力数据,以发掘有助于潮流预测的模式和规律。文献[16]基于潮流计算的特点选择基本特征向量,将深度学习应用于潮流判敛问题;文献[17]提出了数据驱动潮流计算异常误差改进策略,改善了深度学习存在部分潮流变量误差异常的问题;文献[18]从特征向量构造及学习策略设计两方面入手,建立了直流潮流的深度神经网络模型来挖掘直流潮流方程输入、输出间的复杂映射关系;文献[19]探究了深度学习在可变拓扑电网场景下进行潮流计算的应用;文献[20]提出了采用堆叠降噪自编码器的潮流计算方法,通过深度学习提取了拓扑状态离散的潮流模型非线性特征,模型计算量低,速度较快。该类数据驱动方法将计算负担前置到离线训练过程中,在推理阶段,模型仅需执行前向传播即可得到预测结果,显著提高了潮流计算的效率。

但是,由于它们是“黑盒模型”,其有效性严重依赖于训练数据的质量、数量和分布,缺乏对物理机理的理解,导致其预测结果与物理机理不一致,因此难以在实际工业场景下得到广泛应用^[21-24]。

对此,文献[25]和文献[26]提出了基于知识与数据的解决方案,能在一定程度上应对新能源波动对潮流计算的影响,提高预测结果与物理机理的一致性。但它们在 $N-1$ 故障场景下,需要针对每个故障场景重新训练模型,模型训练应用效率低,可用性不强。

为解决以上问题,本文提出一种基于物理机理引导的数据驱动潮流计算方法,即拓扑门控物理机理神经网络(topology-gated physics informed neural network, TGPINN)。TGPINN在神经网络架构的基础上融合了拓扑门控机制和物理机理,通过利用电力系统拓扑结构信息、物理约束以及历史数据,在提高计算效率的同时,保证了预测结果与物理定律的一致性,且仅需训练一套参数,即可预测 $N-1$ 故障场景下不同故障情况的潮流参数。主要贡献如下:

1) 引入电力系统领域知识,构建符合物理约束的深度学习模型。通过对电网拓扑特征和物理先验知识进行编码表征,缓解了数据驱动方法预测结果违背物理定律的问题。在IEEE14、IEEE39以及IEEE300节点系统上针对常规潮流场景和 $N-1$ 故障场景分别进行仿真实验,结果显示模型在保持与常规深度学习模型相似预测速度的前提下,预测结果更精确且更符合物理约束。

2) 设计了一种融合电力系统拓扑结构信息的门控神经网络。电力系统的拓扑结构提供了节点之间的依赖关系和信息传递路径。将拓扑信息作为门控信息,帮助深度学习更好地理解节点的上下文环境,使模型根据不同的拓扑信息决定输入信号的传递和处理方式,能够有效适应 $N-1$ 故障场景下网络拓扑变化,训练和应用效率高。

3) 提出了一种实现物理先验知识嵌入的正则化方法。该方法把基尔霍夫定律、欧姆定律等物理定律作为先验知识,将节点功率方程组转化为目标函数的正则项,以优化深度学习参数,从而使数据驱动潮流计算模型更加满足物理约束。利用正则项动态加权策略,随着训练轮数增加逐步提升正则项在目标函数中的权重,从而优化模型预测精度。

1 潮流计算问题分析

潮流计算旨在利用电力系统中的已知量求解未知量。在 $N-1$ 故障场景下,还需要模拟每个单一元件失效后的情况,并计算相应潮流分布。

1.1 数值求解法潮流计算缺陷分析

基于物理机理的潮流计算数值求解法将潮流分析问题转化成了非线性方程组的求解问题,其基本原理是利用基尔霍夫定律以及欧姆定律等电路

基本定理，表示节点电压、节点电流和功率之间的数学关系。以此构造节点电压方程，从而派生出节点功率平衡方程。

节点电压方程描述了电力系统各个节点间的电压关系。其公式可以表示为

$$U_i = \sum_{j=1}^N (Y_{ij} \times U_j), i=1,2,\dots,N \quad (1)$$

式中： U_i 表示节点*i*的复数电压； U_j 表示节点*j*的复数电压； Y_{ij} 表示节点*i*和节点*j*之间的导纳矩阵元素； N 表示系统节点数。

节点功率平衡方程^[19]描述了电力系统中各个节点的功率平衡关系，即节点注入的有功或无功功率之和等于节点吸收的有功或无功功率之和。将有功功率和无功功率分开描述，其公式可以表示为

$$P_i = P_i^G - P_i^D = U_i \sum_{j=1}^N U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}), i=1,2,\dots,N \quad (2)$$

$$Q_i = Q_i^G - Q_i^D = U_i \sum_{j=1}^N U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}), i=1,2,\dots,N \quad (3)$$

式中： P_i 和 Q_i 分别表示节点*i*的有功功率和无功功率； P_i^G 和 Q_i^G 分别表示节点*i*的发电机注入有功功率和无功功率； P_i^D 和 Q_i^D 分别表示节点*i*的负荷消耗的有功功率和无功功率； G_{ij} 和 B_{ij} 分别表示节点*i*和节点*j*之间的导纳矩阵元素的实部和虚部； U_i 和 θ_i 分别表示节点*i*的电压幅值和电压相角， $\theta_{ij} = \theta_i - \theta_j$ 表示节点*i*和节点*j*的相角之差； N 表示系统节点数。

基于上述公式，可以建立节点功率平衡方程组。由于求解非线性方程组的解析解是极其困难的，因此牛顿-拉夫逊等数值求解法采用逐次线性化迭代策略求解其数值解^[1,16]。虽然数值求解法基于物理机理且计算精度较高，但对于具有复杂拓扑结构的大规模电力系统，该方法的迭代求解过程会消耗大量计算资源，效率较低。

1.2 数据驱动法潮流计算缺陷分析

数据驱动的潮流计算方法^[16-18]实质上处理的是一个回归问题，利用深度神经网络(deep neural network, DNN)将电力系统初始状态信息直接映射到潮流计算结果，通过对节点特征进行线性组合和非线性变换，将潮流初值信息构造的输入特征 X 映射到输出特征 Y 。其前向传播公式可以表示为

$$H^l = g(W^l H^{l-1} + b^l) \quad (4)$$

式中： H^l 表示神经网络第*l*层的节点特征向量； H^0

即为输入特征向量 X ； W^l 表示第*l*-1层到第*l*层神经网络的权重矩阵； b^l 表示第*l*层的偏置向量； g 表示非线性激活函数。假设神经网络共包含*L*-1个隐藏层，那么对于第*L*-1层隐藏层到输出层 Y 的传播可以表示为

$$Y = W^L H^{L-1} + b^L \quad (5)$$

虽然数据驱动的潮流计算方法可以实现快速、准确的预测，但其未考虑底层物理机理，因此预测结果不能很好地满足节点功率平衡方程等物理约束。模型依赖于数据特征，如果训练数据受到质量或数量限制，将导致模型的预测结果产生较大偏差。此外，数据驱动方法仅采用均方误差作为评价指标，过于局限，无法精确反映模型可靠性。与基于物理机理的方法相比，数据驱动方法无法提供相关的物理量和参数解释，因此难以评估模型可信度。

2 引入电力系统领域知识的深度学习模型

本文将电力系统的拓扑结构信息和物理约束条件嵌入到DNN中，使神经网络在训练过程中能够有效地学习电力系统中的基尔霍夫定律、欧姆定律等物理机理，感知拓扑差异。通过正则项动态加权策略，进一步提高数据驱动潮流计算模型的预测精度，使其能够更好地满足电力系统的实际需求和约束条件。本文设计了拓扑门控物理机理神经网络(TGPINN)，如图1所示，其中各变量定义将在2.2、2.4说明。

2.1 拓扑门控机制

常规深度学习方法常常利用导纳矩阵来反映支路的开断情况和节点之间的关联关系，然而导纳矩阵相较于电源、负荷等连续型变量变化信息较少，容易出现共线性问题，给模型训练带来困难。由于*N*-1故障场景下网络拓扑结构的变化，当前结合知识的数据驱动方法针对不同电网拓扑需要训练不同模型，效率低下。应对网络拓扑结构变化，关键在于如何将拓扑结构进行表示学习，使其能够像电流、电压等数值特征一样，作为神经网络的输入。为此，本文设计了拓扑门控网络(topology-gated neural network, TGNN)。该网络不仅具备适应拓扑变化的能力，而且使神经网络能够充分地利用电力系统的拓扑结构，提升了对潮流计算的建模能力。

如图1中拓扑门控机制部分所示，TGNN通过潮流特征网络和拓扑特征网络两个分支，分别学习初始潮流信息和电网拓扑信息的特征表示。首先，为了表征电力系统中节点及输电线路的潮流分布，本文设计了潮流特征网络，用于表征节点电压幅值

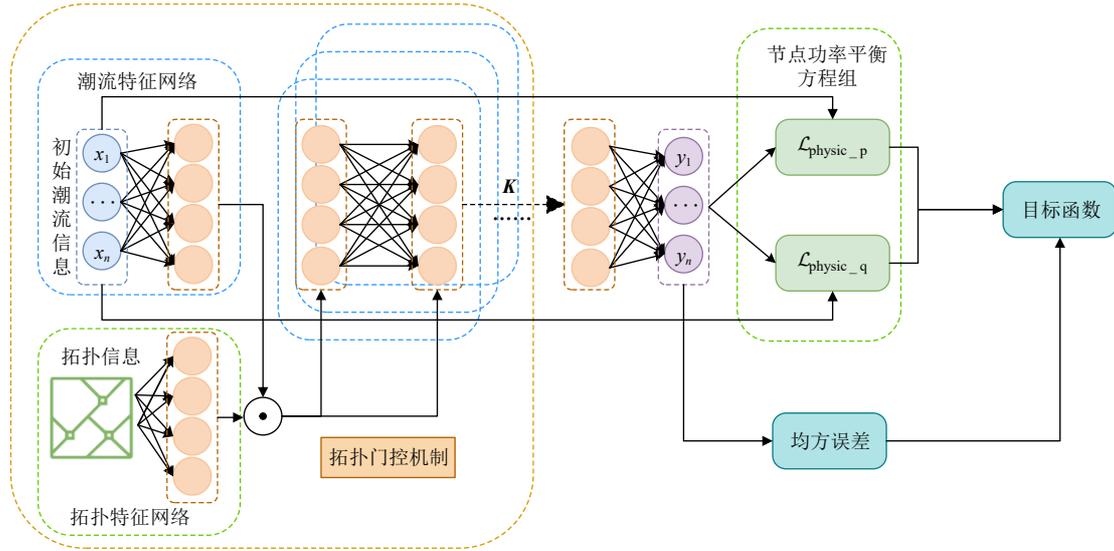


图 1 TGPINN 模型结构
Fig. 1 Structure of TGPINN

和相角以及有功和无功功率等数值信息。此外，电力系统拓扑结构提供了节点之间的依赖关系和信息传递路径，本文在数据预处理阶段收集了常规场景和 $N-1$ 故障场景的拓扑状态。利用拓扑特征网络，对拓扑信息进行特征提取与编码得到拓扑特征的向量表示。TGNN 的重点是利用门控机制，融合拓扑特征网络和潮流特征网络。在模型训练时，基于门控机制，拓扑特征被用来指导潮流特征网络调整其内部参数，以便在不同的故障拓扑结构下都能做出准确的潮流预测。将拓扑信息作为门控信息更有助于反映节点的上下文环境，使模型根据电力系统的拓扑结构调整信息传递和处理的方式，来进行潮流预测。TGNN 克服了需为每种网络拓扑结构独立训练模型参数的局限，更轻量。

基于拓扑信息的门控机制公式如下所示：

$$\mathbf{G}^k = g(\mathbf{W}^k \mathbf{G}^{k-1} + \mathbf{b}^k) \quad (6)$$

$$\mathbf{H}^l = g(g(\mathbf{W}^l \mathbf{H}^{l-1} + \mathbf{b}^l) \odot \mathbf{G}^k) \quad (7)$$

式中： \mathbf{G}^k 表示拓扑特征网络第 k 层的门控嵌入向量； \mathbf{G}^0 即为原始拓扑信息； \mathbf{W}^k 表示第 $k-1$ 层到第 k 层拓扑特征网络的权重矩阵； \mathbf{b}^k 表示第 k 层的偏置向量； g 表示非线性激活函数； \mathbf{H}^l 表示潮流特征网络第 l 层隐特征； \mathbf{W}^l 表示第 $l-1$ 层到第 l 层潮流特征网络的权重矩阵； \mathbf{b}^l 表示第 l 层的偏置向量；符号 \odot 表示哈达玛积，即对应位置逐元素相乘操作。

2.2 嵌入物理先验的正则化方法

TGNN 实现了电力系统状态信息与潮流计算结果之间的映射关系建模。然而，仅采用该结构，并不能保证预测结果很好地满足电力系统中的节点功率平衡等物理机理约束，这也是现有数据驱动

模型的主要缺点。

为了解决该问题，本文提出通过正则化的方式为模型添加底层物理机理约束。将物理方程式转化为正则项，加入目标函数，以限制神经网络参数的优化方向。利用这些方程式中蕴含的物理机理来指导 TGNN 的训练，得到 TGPINN 模型，使其遵守基尔霍夫定律、欧姆定律以及电网拓扑等约束条件，从而避免过拟合现象，提高模型准确性，减少对物理约束的违背。以上确保了预测结果不仅在精度上准确，而且符合物理一致性。

潮流计算物理方程式和深度学习损失函数在数学形式上存在两点共性，为实现正则化方法嵌入物理先验提供了启发：1) 迭代近似求解潮流计算方程式和深度学习逼近损失函数都属于数学优化问题。迭代法的求解目标是找到满足节点功率平衡方程组的物理变量，以准确描述物理现象的规律；深度学习的目标是最小化损失函数，以提高预测精度。2) 节点功率平衡方程和深度学习损失函数都是可微函数，因此都可以利用梯度下降法进行优化。

深度学习方法的输出包括各节点有功、无功功率以及电压幅值、相角等物理量，为了使得这些物理量尽可能满足节点功率平衡方程，本文提出了目标函数 \mathcal{L} ，其表达式如下：

$$\mathcal{L} = (1 - \alpha)\mathcal{L}_{\text{MSE}} + \alpha(\mathcal{L}_{\text{physic_p}} + \mathcal{L}_{\text{physic_q}}) \quad (8)$$

$$\mathcal{L}_{\text{physic_p}} = \frac{1}{n} \sum_{i=1}^n \mathcal{L}_{\text{physic_pi}} \quad (9)$$

$$\mathcal{L}_{\text{physic_q}} = \frac{1}{n} \sum_{i=1}^n \mathcal{L}_{\text{physic_qi}} \quad (10)$$

式中： $\mathcal{L}_{\text{physic_p}}$ 和 $\mathcal{L}_{\text{physic_q}}$ 分别表示模型预测结果中

系统各节点有功功率和无功功率违背节点功率平衡方程的平均程度； $\mathcal{L}_{\text{physic_pi}}$ 和 $\mathcal{L}_{\text{physic_qi}}$ 分别表示模型预测结果中节点*i*有功功率和无功功率违背节点功率平衡方程的程度； α 表示正则权重。对公式(2)和公式(3)所表示的节点功率平衡方程进行了移项、平方操作，可得到 $\mathcal{L}_{\text{physic_pi}}$ 和 $\mathcal{L}_{\text{physic_qi}}$ 的计算公式：

$$\mathcal{L}_{\text{physic_pi}} = [P_i^{G'} - P_i^D - U_i \sum_{j=1}^N U_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij})]^2, i=1,2,\dots,N \quad (11)$$

$$\mathcal{L}_{\text{physic_qi}} = [Q_i^{G'} - Q_i^D - U_i \sum_{j=1}^N U_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij})]^2, i=1,2,\dots,N \quad (12)$$

由于基尔霍夫定律和欧姆定理是节点功率平衡方程的推导基础，因此， $\mathcal{L}_{\text{physic_p}}$ 和 $\mathcal{L}_{\text{physic_q}}$ 也间接反映了模型对霍夫定律和欧姆定理的违背程度。此外，一些文献^[18-20]通过支路开断前后各支路有功功率之差 ΔP 或电压之差 ΔU 来表征拓扑结构，但显然该类方法只能用来表征支路开断导致的拓扑变化性，不能有效表征节点间的关联关系。上述式子包含了电力系统节点拓扑结构信息，将其作为正则项表征电力系统中各节点之间的连接关系。

2.3 动态加权训练策略

数据驱动模型的训练是一个数据拟合过程。通过对模型进行参数调整，减少预测误差，从而实现数据拟合。TGPINN模型的目标函数 \mathcal{L} 如公式(8)所示，均方误差损失项和物理正则项共同决定了模型参数更新的梯度。直接嵌入物理正则会导致模型预测准确度下降，因此本文采用动态调整权重的方式来优化模型训练。该训练策略的思路是：1) 在模型训练的初始阶段，利用均方误差(mean squared error, MSE)主导梯度下降算法反向传播；2) 当模型收敛到一个较好的初始参数时，不断提升正则项在目标函数中的权重，使其随训练轮数线性增长。其表达式描述为下式：

$$\alpha = \begin{cases} 0, & t \leq k \\ \alpha_{\max} t / T, & t > k \end{cases} \quad (13)$$

式中： α 表示物理正则项在目标函数中的权重； t 表示模型当前训练轮数； T 表示最大训练轮数； α_{\max} 表示 α 在训练过程中最大权重占比； k 表示训练轮数阈值。当 t 大于 k 时，赋予正则项权重。因为在训练初期物理约束的更新梯度与均方误差的更新梯度存在较大冲突，所以模型难以收敛。训练初期使用较小的正则项权重，使模型更多地关注数据特

征和模式，以便更快地拟合训练数据；而在训练后期，模型可能会出现过拟合的情况，此时增加正则项权重，使模型更加关注物理约束，以优化预测值域，提高物理机理一致性。在电力场景的实际应用中，可以根据需求调整动态加权策略的超参数，以实现预测准确性和物理一致性之间的最佳平衡。

2.4 TGPINN 模型训练流程

TGPINN的训练由物理先验融合和数据驱动两部分组成。物理先验用于描述电力系统的物理性质和约束条件，如图2蓝色部分所示。数据驱动用于学习潮流问题的非线性映射关系并预测结果。其中，数据准备如图2绿色部分所示，训练流程如图2橙色部分所示。

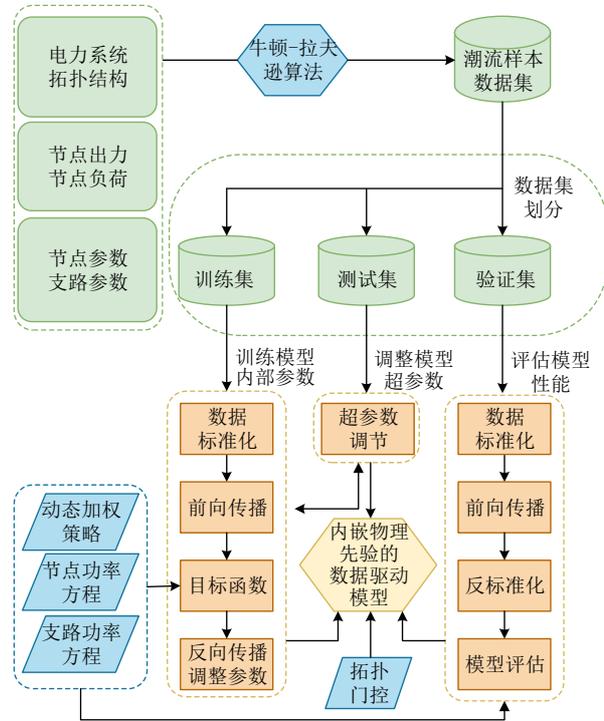


图2 TGPINN 训练流程

Fig. 2 Training process of TGPINN

1) 数据准备。

采用牛顿-拉夫逊算法生成潮流样本数据集，并对数据进行预处理，去除不收敛样本，确保数据的完整性和准确性。数据集分为训练集、验证集和测试集。训练集用于模型训练，更新模型权重和偏置。验证集用于调整模型学习率、正则化系数等超参数。测试集用来评估模型性能，以验证其在实际应用中的效果。

2) 模型结构。

根据电力系统的物理特性，将节点功率方程组以正则化的方式嵌入到神经网络的目标函数中，使得模型预测结果符合电力系统的物理规律。利用门控机制将电力系统拓扑信息纳入模型的计算过程，

使神经网络能够拟合拓扑信息来推断节点间关系,适应 $N-1$ 故障场景下不同的电网拓扑结构。在训练过程中采用动态加权策略,实时调整正则项权重,以改善模型训练效果。

3) 模型训练。

对于 n 个母线节点的电网系统,选取潮流计算所需潮流初值信息,即各个母线节点的初始发电机注入有功功率 P^G 和无功功率 Q^G 以及有功负载 P^D 和无功负载 Q^D ,来构造数据驱动模型的输入特征向量 $\mathbf{x}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n]$,第 i 个母线节点的输入特征 $\mathbf{x}_i=[P_i^G, Q_i^G, P_i^D, Q_i^D]$,利用电网拓扑信息构造反映拓扑变化的支路开断信息向量 \mathbf{G}^0 ,作为拓扑特征网络的输入特征。拓扑门控网络的最大层数设置为 \mathbf{K} 。选取各母线潮流平衡时的节点电压幅值 \mathbf{U} 和相角 $\boldsymbol{\theta}$ 、发电机注入有功功率 $P^{G'}$ 和无功功率 $Q^{G'}$ 构造数据驱动模型的输出特征向量 $\mathbf{y}=[\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n]$,第 i 个母线节点的输出特征 $\mathbf{y}_i=[U_i, \theta_i, P_i^{G'}, Q_i^{G'}]$ 。各支路的流入、流出有功功率 P^{from} 、 P^{to} 和流入、流出无功功率 Q^{from} 、 Q^{to} 通过支路功率方程快速求解得到。利用支路功率方程,将模型预测结果中的节点电压和相角信息转化为支路有功功率和无功功率信息。支路功率方程式如下:

$$P_{ij} = (U_i^2 - U_i U_j)(G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}), \quad i=1,2,\dots,N \quad (14)$$

$$Q_{ij} = (U_i^2 - U_i U_j)(G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}), \quad i=1,2,\dots,N \quad (15)$$

式中: P_{ij} 表示从节点 i 到节点 j 的有功功率,即 P_i^{from} 和 P_j^{to} ; Q_{ij} 表示从节点 i 到节点 j 的无功功率,即 Q_i^{from} 和 Q_j^{to} ; U_i 和 U_j 分别表示节点 i 和节点 j 的电压幅值; G_{ij} 和 B_{ij} 分别表示支路的电导和电纳; θ_{ij} 表示节点 i 和节点 j 之间的相角差。

电力系统潮流样本中包含有各母线电压幅值、相角初值,负载的有功和无功功率,发电机节点的有功和无功出力等诸多电气量,量纲不统一,数值范围上有较大差异。因此,本文采用 z-score 方法进行数据标准化,将不同尺度的数据映射到相同尺度的标准正态分布,具体如下:

$$z = \frac{x-u}{\sigma} \quad (16)$$

式中: x 是原始数据的值; u 是原始数据的均值; σ 是原始数据集的标准差。标准化后的数值 z 表示原始数据相对于均值的偏离程度,通过对 z 值进行数据比较和分析,减少数据异常值对分析结果的影响。

本文用均方误差(mean squared error, MSE)作为目标函数中的损失项,衡量预测结果与实际结果之间的差异,其数学表达式为

$$L_{\text{MSE}} = \frac{1}{M_{\text{train}}} \sum_{i=1}^{M_{\text{train}}} (Y_i - \hat{Y}_i)^2 \quad (17)$$

式中: M_{train} 表示训练集样本数量; Y_i 表示第 i 个潮流样本的实际结果; \hat{Y}_i 表示神经网络对第 i 个潮流样本的预测结果。

对于深度神经网络的优化策略,本文采用 Adam 算法^[27]。Adam 是一种自适应学习率优化算法,它结合梯度的一阶矩估计和二阶矩估计调整每个参数的学习率,使得梯度较大的参数具有较小的学习率,而梯度较小的参数具有较大的学习率,能避免梯度消失或爆炸的问题。此外,Adam 算法使用动量项来加速参数更新速度,使模型更快收敛。因为在计算梯度的平方时使用了偏差校正,所以 Adam 算法具有更强的自适应性,能够更好地适应优化问题。其公式如下:

首先,定义 t 为当前迭代的次数, l 为学习率, β_1 和 β_2 为两个衰减系数(一般设置为 0.9 和 0.999), ε 为一个很小的数(一般设置为 10^{-8})。然后,对于每个参数 $\boldsymbol{\theta}$,计算该参数的一阶矩估计 \mathbf{m}_t 和二阶矩估计 \mathbf{v}_t :

$$\mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1 - \beta_1) \mathbf{g}_t \quad (18)$$

$$\mathbf{v}_t = \beta_2 \mathbf{v}_{t-1} + (1 - \beta_2) \mathbf{g}_t^2 \quad (19)$$

式中 \mathbf{g}_t 为参数 $\boldsymbol{\theta}$ 在当前批次上的梯度,对 \mathbf{m}_t 和 \mathbf{v}_t 进行偏差修正:

$$\hat{\mathbf{m}}_t = \frac{\mathbf{m}_t}{(1 - \beta_1^t)} \quad (20)$$

$$\hat{\mathbf{v}}_t = \frac{\mathbf{v}_t}{(1 - \beta_2^t)} \quad (21)$$

最后,根据以上计算结果,更新参数 $\boldsymbol{\theta}$:

$$\boldsymbol{\theta}_t = \boldsymbol{\theta}_{t-1} - \frac{l \hat{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{v}}_t} + \varepsilon} \quad (22)$$

3 算例分析

本文在接入新能源的 IEEE14、IEEE39 以及 IEEE300 系统上进行仿真实验,验证了所提方法的有效性。

3.1 算例说明

算例 1 为 IEEE14 节点系统^[28],包含 14 个节点、5 个发电机以及 20 条支路,在节点 2、3 上接入光伏电站,在节点 6 接入风电场。算例 2 为 IEEE39 节点系统^[29],包含 39 个节点、10 个发电机以及 46 条支路,在节点 16、17 及 18 接入风电场,节点 23

及 24 接入光伏电站。算例 3 为 IEEE300 节点系统^[30]，包含 300 个节点、69 个发电机以及 411 条支路，分别在 10 个不同的节点上接入了光伏电站和风电场。为了模拟可再生能源的高渗透以及负荷的波动性，本文利用 Matpower 工具包的牛顿-拉夫逊算法生成训练数据。假设发电功率和负荷功率满足正态分布，均值设定为标准测试系统给定值，负荷标准差为均值的 20%，新能源渗透率为 10%。为了模拟 $N-1$ 故障场景，逐一断开每条支路，进行潮流计算获取故障后的系统状态，生成相应的训练数据。在未出现系统故障的常规潮流计算场景下，为每个算例生成 2 万个潮流样本。在 $N-1$ 故障场景下，为每个算例生成 20 万个潮流样本。将数据随机拆分为训练集、验证集和测试集，设置其比例为 7:1:2。

本文对以下方法进行了仿真实验，以验证本文所提出方法的有效性。

1) M0, 牛拉法, 作为验证标准。

2) M1, 基于常规 DNN 的数据驱动潮流计算模型。

3) M2, 在 M1 的基础上, 以正则化方式嵌入节点功率平衡方程作为物理先验。

4) M3, 在 M2 的基础上, 引入正则项动态加权训练策略。

5) M4, 以各支路功率之差作为拓扑结构特征向量的 DNN 潮流模型。

6) M5, 在 M1 的基础上, 引入拓扑门控机制。

7) M6, 在 M2 的基础上, 引入拓扑门控机制。

8) M7, 在 M6 的基础上, 引入正则项动态加权训练策略。

以上方法中, M0 用于数据集生成, 作为验证标准, M1 作为常规潮流场景下对比模型, M4 作为 $N-1$ 故障场景下对比模型。M5 是 TGNN, M6 是 TGPINN, 结构如图 1 所示。M7 是采用正则项动态

加权训练策略的 TGPINN。针对不同算例, 潮流模型训练参数具体如表 1 所示。本文所有算例均在 Intel(R)Core(TM)i7-8700K CPU@3.70GHz 16GB RAM 的硬件环境下测试。

为了比较不同方法的性能, 采用以下指标衡量潮流计算精度。利用公式(17)衡量模型预测结果和真实结果间的拟合程度; 用公式(11)和公式(12)衡量模型有功功率和无功功率违背节点功率平衡方程的程度。

训练采用相对较小的批次, 每个批次包含 200 条数据。相比使用较大批次, 会使模型训练更加稳定, 减少过拟合风险。此外, 小批次的训练适合在资源受限或低算力的环境中使用, 这符合电力场景实际需求。模型采用相对误差以及有功、无功约束违背率作为模型的评价指标。

模型在测试集上预测结果的相对平均误差 (relative mean error, RME)的计算公式如下:

$$R_{ME} = \frac{\sum_{i=1}^{M_{test}} |Y_i - \hat{Y}_i|}{\sum_{i=1}^{M_{test}} |Y_i|} \times 100\% \quad (23)$$

式中: M_{test} 表示测试集样本数量。

模型在测试集上预测结果的有功约束违背率 r_p 、无功约束违背率 r_Q 的计算公式如下:

$$r_p = \frac{\sum_{i=1}^{M_{test}} |P_i - \hat{P}_i|}{\sum_{i=1}^{M_{test}} |P_i|} \times 100\% \quad (24)$$

$$r_Q = \frac{\sum_{i=1}^{M_{test}} |Q_i - \hat{Q}_i|}{\sum_{i=1}^{M_{test}} |Q_i|} \times 100\% \quad (25)$$

式中: P_i 、 Q_i 分别表示由发电机注入功率和负荷功率计算得到的第 i 个潮流样本的有功功率和无功功率, 即 $P_i^{G'} - P_i^D$ 、 $Q_i^{G'} - Q_i^D$; \hat{P}_i 、 \hat{Q}_i 分别表示由电压幅值和相角计算得到的第 i 个潮流样本的有功功率和无功功率, 见公式(2)、(3)第二行, 其中电压幅值和相角是神经网络输出的预测值。

3.2 算例说明

3.2.1 模型性能对比

表 2 是常规场景下潮流预测实验结果。从实验结果来看, 在算例 1 的常规潮流预测场景下, M6 的相对误差为 0.081%, M1 的相对误差为 0.083%, 两者的预测精度相近; 但在有功约束和无功约束的违背情况下, M6 的有功约束违背率为 0.023%, 无

表 1 模型参数
Table 1 Model parameters

场景	算例	模型	模型层级结构
常规潮流	算例 1	M1, M2, M3	[56, 256, 256, 56]
		M5, M6, M7	[[56, 20],[256,256],[256,256],56]
	算例 2	M1, M2, M3	[156,256,256,156]
		M5, M6, M7	[[156, 46],[256,256],[256,256],156]
	算例 3	M1	[1200,256,256,1200]
		M6, M7	[[1200, 80],[256,256],[256,256],1200]
$N-1$ 故障	算例 1	M4	[96, 256, 256, 56]
		M5, M6, M7	[[56, 20],[256,256],[256,256],56]
	算例 2	M4	[248,256,256,156]
		M5, M6, M7	[[156, 46],[256,256],[256,256],156]
	算例 3	M4	[1200,256,256,1200]
		M6, M7	[[1200,80],[256,256],[256,256],1200]

表2 常规场景下 M1、M6 和 M7 的潮流预测结果
Table 2 Power flow prediction results of M1, M6 and M7 in conventional scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例 1	M1	0.083	0.226	2.080
	M6	0.081	0.023	0.037
	M7	0.080	0.021	0.034
算例 2	M1	0.297	1.257	3.817
	M6	0.310	1.059	0.799
	M7	0.260	0.715	0.641
算例 3	M1	2.073	12.224	15.459
	M6	2.071	7.991	8.214
	M7	2.018	7.812	6.722

有功约束违背率为 0.037%，远低于 M1 的 0.226% 和 2.080%。M7 的相对误差为 0.080%，M7 的有功约束违背率和无功功率违背率分别为 0.021% 和 0.034%，取得了更优的结果。在算例 2 的常规预测场景中，M6 的相对误差为 0.310%，略差于 M1 的 0.297%；而采用了正则项动态加权策略的 M7 相对误差为 0.260%，优于 M1 的 0.297%，且 M7 的有功约束违背率为 0.715%，无功约束违背率为 0.641%，远优于 M1 的 1.257% 和 3.817%。在算例 3 的常规预测场景中，M6 的相对误差为 2.071%，有功约束和无功约束违背情况为 7.991%、8.214%，均优于 M1 的 2.073%、12.224% 和 15.459%；M7 的相对误差为 2.018%，有功约束和无功约束违背情况为 7.812%、6.722%，取得了更优的效果。

说明常规潮流预测场景下 TGPINN 在物理一致性方面可以取得更好的表现，且采用正则项动态加权训练策略的 TGPINN 可以取得更好的表现。

表 3 是 N-1 场景下潮流预测实验结果。在算例 1 的 N-1 故障场景下，M6 的相对误差为 0.174%，略优于 M4 的相对误差 0.186%，但在有功约束和无功约束的违背情况上，M6 的有功约束违背率为 0.157%，无功约束违背率为 0.171%，远低于 M4 的 1.119% 和 2.618%。说明 TGPINN 在保证物理机

表3 N-1 故障场景下 M4、M6 和 M7 的潮流预测结果
Table 3 Power flow prediction results of M4, M6 and M7 in N-1 fault scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例 1	M4	0.186	1.119	2.618
	M6	0.174	0.157	0.171
	M7	0.168	0.098	0.123
算例 2	M4	0.296	11.644	12.055
	M6	0.280	0.682	1.985
	M7	0.138	0.690	1.518
算例 3	M4	7.432	20.910	18.241
	M6	7.156	8.580	10.769
	M7	6.892	8.077	8.193

理一致性方面，有显著效果。M7 取得了更优的预测效果，相对误差为 0.168%，有功功率和无功功率的违背情况为 0.098% 和 0.123%。进一步体现了动态加权策略的有效性。在算例 2 的 N-1 故障场景中，M6 的各项指标都优于 M4，且 M7 取得了更优异的预测效果，相对误差为 0.138%，有功约束和无功约束违背情况为 0.690%、1.518%，远优于 M4 的 0.296%、11.644%、12.055%。在算例 3 的 N-1 故障场景中，M6 的各项指标同样都优于 M4；M7 取得了最优预测效果，相对误差为 6.892%，有功约束和无功约束违背情况为 8.077%、8.193%，远优于 M4 的 7.432%、20.910% 和 18.241%。

以上说明正则项动态加权策略对 TGPINN 的提升效果显著，在预测精度和物理机理一致性方面，均优于传统以各支路功率之差作为拓扑结构特征向量的 DNN 潮流模型。

此外，如图 3、4 所示，相比于常规数据驱动方法 M1，TGPINN 对各节点电压预测误差分布更为均衡。常规数据驱动方法在预测节点电压时只依

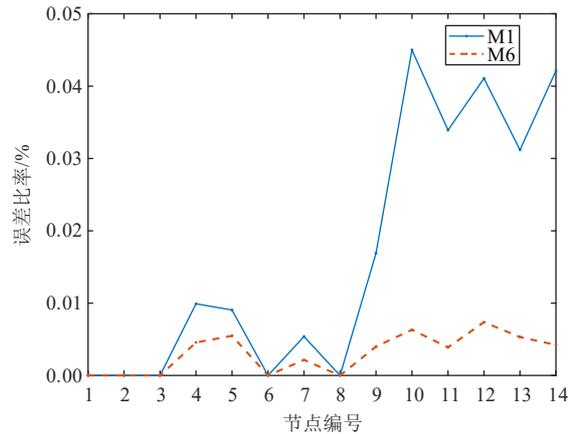


图3 算例 1 中各节点电压幅值统计误差
Fig. 3 Statistical error of voltage amplitude for each node in Example 1

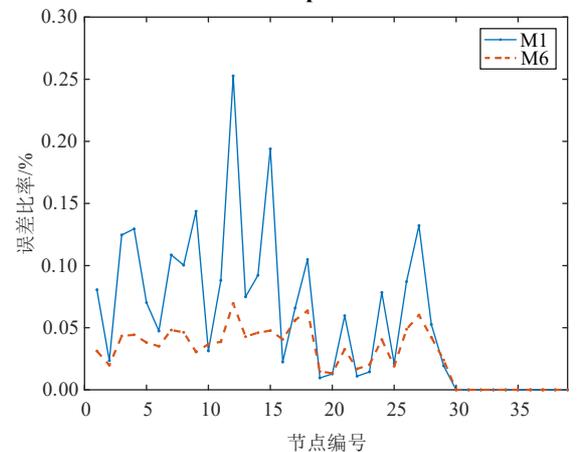


图4 算例 2 中各节点电压幅值统计误差
Fig. 4 Statistical error of voltage amplitude for each node in Example 2

赖历史数据的统计特征和模式，无法捕捉到拓扑结构和电力系统的物理规律，因此部分节点的预测误差较大。相比之下，TGPIIN 结合拓扑信息和物理约束，通过建模节点间关系和电力系统物理法则来进行潮流预测，能够更好地表征节点之间的相互作用，能提供更均衡、更准确的预测。

3.2.2 消融实验

本文模型的主要创新有：1) 正则化方式嵌入物理机理；2) 正则项动态加权训练策略；3) 拓扑门控机制，以实现拓扑信息的融合。本节将验证以上创新点的有效性。

1) 物理正则项有效性。

在常规潮流预测场景下，将 M2 与 M1 进行比较，结果如表 4 所示。在算例 1 中，M2 的相对误差为 0.085%，M1 的相对误差为 0.083%，二者预测精度表现相似，但是 M2 的有功违背率为 0.021%，无功违背率为 0.045%，远优于 M1 的 0.226% 和 2.080%。在算例 2 中，M2 的相对误差为 0.375%，略差于 M1 的相对误差 0.297%，但是 M2 的有功违背率却是 0.632%，无功违背率为 0.771%，远优于 M1 的 1.257% 和 3.817%。

综上，采用正则化方式嵌入物理先验的方法有明显效果，能够使模型更加符合基尔霍夫定律以及欧姆定律等物理约束。

表 4 常规场景下 M1 和 M2 潮流预测结果
Table 4 Power flow prediction results of M1 and M2 in conventional scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例 1	M1	0.083	0.226	2.080
	M2	0.085	0.021	0.045
算例 2	M1	0.297	1.257	3.817
	M2	0.375	0.632	0.771

2) 正则项动态加权策略有效性。

M3 在 M2 的基础上引入了正则项动态加权训练策略，这种策略进一步优化了模型的训练过程。结果如表 5 所示。

算例 1 中，M2 的相对误差、有功约束违背率以及无功约束违背率分别为 0.085%、0.021% 和

表 5 常规场景下 M2 和 M3 潮流预测结果
Table 5 Power flow prediction results of M2 and M3 in conventional scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例 1	M2	0.085	0.021	0.045
	M3	0.083	0.027	0.054
算例 2	M2	0.375	0.632	0.771
	M3	0.310	0.404	0.583

0.045%；M3 的相对误差、有功约束违背率以及无功约束违背率分别为 0.083%、0.027% 和 0.054%。以上说明在一般规模电力系统场景下 M3 与 M2 预测精度相似。算例 2 中，M3 的相对误差、有功约束违背率以及无功约束违背率分别为 0.310%、0.404% 和 0.583%，在较大程度上优于 M2 的 0.375%、0.632% 和 0.771%。以上说明在较大规模的电力系统场景下，M3 相对于 M2 在物理先验的符合程度上有一定提升。

图 5、图 6 和图 7 分别展示了均方误差损失、有功约束和无功约束违背情况在算例 2 验证集上的变化过程。其中，M3 所采用的动态加权策略如公式(13)所示，训练轮数阈值参数 k 设为 1000。在训练初期，M3 的正则项权重为 0，仅通过 MSE 主导梯度下降算法，在各项指标上均与 M1 相近，均方误差优于 M2，在有功约束和无功约束的遵守方面表现不及 M2。当训练轮数达到 1000 轮时，随着训练轮数的增加，M3 正则项的权重逐步提高，在使均方误差维持在与 M1 相近的水平的同时，逐渐减少了有功和无功约束的违背情况，最终使其表现接

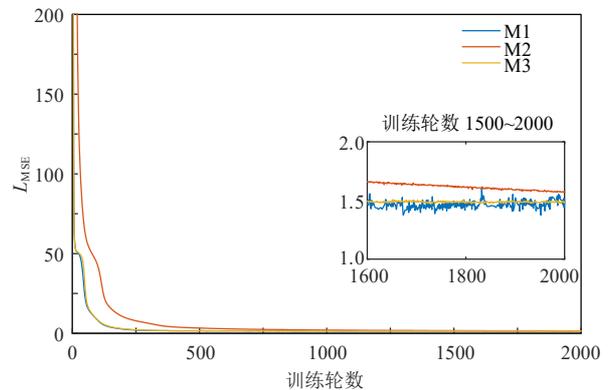


图 5 训练过程中均方误差损失对比

Fig. 5 Comparison of mean squared error loss during training

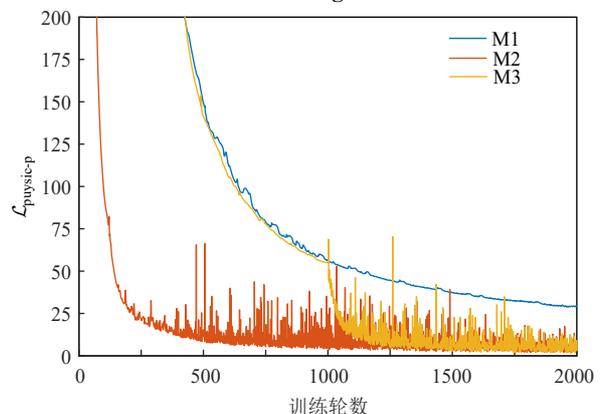


图 6 训练过程中有功约束违背情况对比

Fig. 6 Comparison of active power constraint violation during training

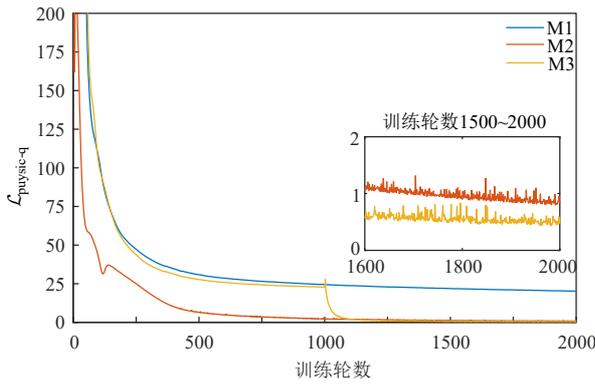


图7 训练过程中无功约束违背情况对比

Fig. 7 Comparison of reactive power constraint violation during training

近甚至超越了M2。

综上，正则项动态加权策略可以进一步提高潮流计算模型的准确性和稳定性。

3) 拓扑门控网络有效性。

如表6所示，在常规潮流预测场景下，算例1中M5的相对误差、有功约束违背率和无功约束违背率分别为0.091%、0.283%和1.912%，与M1的0.083%、0.226%、2.080%表现相近。算例2中M5的相对误差、有功约束违背率和无功约束违背率分别为0.268%、1.836%和2.947%，也与M1的0.297%、1.257%和3.817%表现相近。以上说明在常规场景下仅仅使用融合拓扑信息的门控网络架构不会产生优势。

表6 常规场景下M1和M5潮流预测结果

Table 6 Power flow prediction results of M1 and M5 in conventional scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例1	M1	0.083	0.226	2.080
	M5	0.091	0.283	1.912
算例2	M1	0.297	1.257	3.817
	M5	0.268	1.836	2.947

如表7所示，在N-1故障场景下，算例1中M5的相对误差为0.173%，有功约束违背率和无功约束违背率分别为0.296%和1.926%，均优于M4的0.186%、1.119%和2.618%。算例2中M5的相对误差为0.112%，有功约束违背率和无功约束违背率分别为5.137%和8.149%，均优于M4的0.296%、11.644%和2.055%。以上说明N-1场景下融合拓扑信息的门控网络TGNN在预测准确性和物理机理一致性上都表现出了更好的性能。TGNN在处理复杂系统和N-1故障场景时表现更出色，门控网络能够通过学习拓扑结构的关键特征，更好地适应不同负荷水平、发电变化以及支路状态的不确定性，实现对复杂系统的建模，且不需要针对每一故障情况

表7 N-1场景下M4和M5潮流预测结果

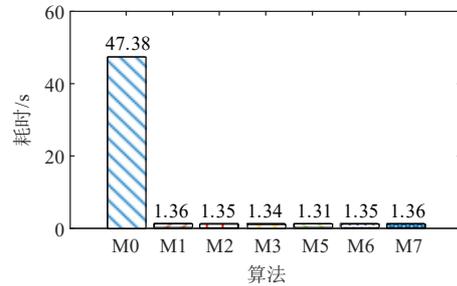
Table 7 Power flow prediction results of M4 and M5 in N-1 fault scenarios

算例	算法	相对平均误差/%	有功约束违背率/%	无功约束违背率/%
算例1	M4	0.186	1.119	2.618
	M5	0.173	0.296	1.926
算例2	M4	0.296	11.644	12.055
	M5	0.112	5.137	8.149

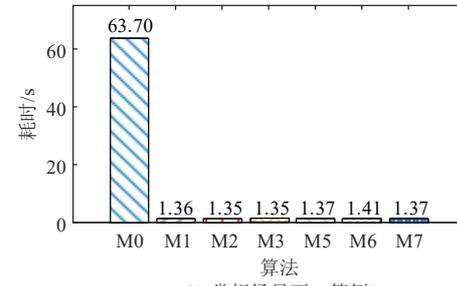
分别重新训练模型。

3.2.3 执行速度对比

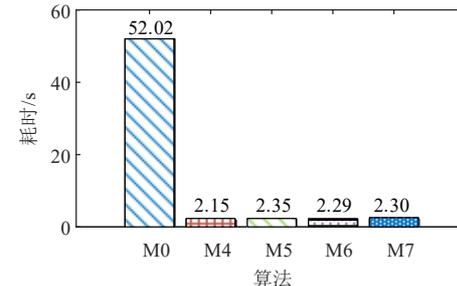
为了比较直观地体现TGPINN的执行速度，本节在两种场景、两个算例下，分别统计了每个模型处理10000组潮流数据样本的计算耗时，结果如图8所示。横轴分别对应牛拉法(M0)以及传统数据



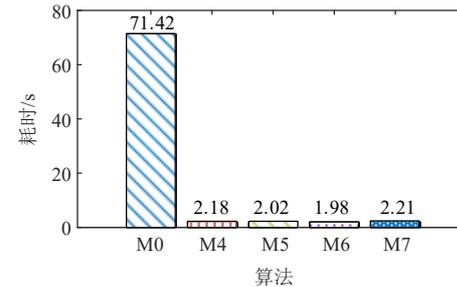
(a) 常规场景下，算例1



(b) 常规场景下，算例2



(c) N-1故障场景下，算例1



(d) N-1故障场景下，算例2

图8 预测速度对比

Fig. 8 Comparison of prediction speed

驱动方法 M1、M4，知识与数据驱动方法 M2、M3、M5—M7。结果显示，本文方法与常规数据驱动方法计算速度相近，但远优于牛顿-拉夫逊方法。此外，相比于常规数据驱动算法(M1、M4)，TGPINN 保持了相近的预测速度，但显著提升了模型精度和物理机理一致性。

4 结论与展望

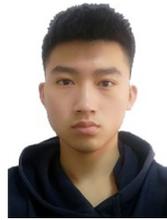
通过在数据驱动的深度学习模型中引入电力系统领域的知识，本文构建了一个具备物理常识的深度学习模型(TGPINN)。该模型既能高效地进行预测，又能缓解数据驱动潮流计算方法与物理定律相悖的问题。通过引入正则化技术，将物理先验知识嵌入深度神经网络的结构中，使得数据驱动的潮流计算模型更好地符合物理规则的约束。同时，采用门控神经网络架构，使得模型根据不同的拓扑信息决定输入信号的传递和处理方式，以适应 $N-1$ 故障场景下不同的电网拓扑结构。此外，本文还设计了一种动态正则项加权策略，以优化模型的预测精度。

未来，可以考虑采用图神经网络来更好地表示电力系统节点之间的拓扑信息，并在图神经网络的训练过程中融入物理先验知识。这样能更全面地捕捉电力系统的复杂拓扑关系，提高模型的预测能力。同时，还会进一步研究物理先验知识的建模和嵌入方法，探索更加高效的正则化策略和学习算法以提高模型的性能和可解释性，并在更大规模和更复杂的电力系统中进行验证，实现更加准确和高效的电力系统运行与调度。

参考文献

- [1] GLOVER J D, SARMA M S, OVERBYE T J. Power system analysis and design[M]. Stamford: Cengage Learning, 2012.
- [2] 康重庆, 杜尔顺, 郭鸿业, 等. 新型电力系统的六要素分析[J]. 电网技术, 2023, 47(5): 1741-1750.
KANG Chongqing, DU Ershun, GUO Hongye, et al. Primary exploration of six essential factors in new power system[J]. Power System Technology, 2023, 47(5): 1741-1750(in Chinese).
- [3] 张文浩. 含高比例分布式光伏配电系统源网荷储互动运行策略研究[D]. 北京: 北京交通大学, 2023.
- [4] 李懿鑫, 李正烁, 刘聪聪. 考虑光伏与电价不确定性的综合能源生产单元自调度报价策略研究[J]. 电网技术, 2023, 47(7): 2713-2722.
LI Yixin, LI Zhengshuo, LIU Congcong. Self-scheduling offering strategy of integrated energy production unit considering uncertainty of photovoltaic and electricity prices[J]. Power System Technology, 2023, 47(7): 2713-2722(in Chinese).
- [5] 张衡, 程浩忠, 柳璐, 等. 基于点估计法随机潮流的输电网多阶段规划研究[J]. 电网技术, 2018, 42(10): 3204-3210.
ZHANG Heng, CHENG Haozhong, LIU Lu, et al. Research on multistage transmission network expansion planning using point estimation method based on stochastic power flow[J]. Power System Technology, 2018, 42(10): 3204-3210(in Chinese).
- [6] 李亚辉, 孙媛媛, 王庆岩, 等. 基于源荷谐波耦合模型的数据驱动概率谐波潮流计算[J/OL]. 中国电机工程学报, 2023: 1-12. [2024-03-14]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231220.1508.004.html>.
LI Yahui, SUN Yuanyuan, WANG Qingyan, et al. Data-driven probabilistic harmonic power flow calculation based on source and load harmonic coupling model[J/OL]. Proceedings of the CSEE, 2023: 1-12. [2024-03-14]. <http://kns.cnki.net/kcms/detail/11.2107.TM.20231220.1508.004.html>(in Chinese).
- [7] LIAO Wenlong, 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, 2022, 10(2): 345-360.
- [8] 康思佳. 电动汽车无序充电对电网的影响研究[J]. 电工材料, 2023(6): 34-37.
KANG Sijia. Research on the impact of electric vehicle disorderly charging on the power grid[J]. Electrical Engineering Materials, 2023(6): 34-37(in Chinese).
- [9] MOYA C, LIN Guang. DAE-PINN: a physics-informed neural network model for simulating differential algebraic equations with application to power networks[J]. Neural Computing and Applications, 2023, 35(5): 3789-3804.
- [10] TINNEY W F, HART C E. Power flow solution by Newton's method [J]. IEEE Transactions on Power Apparatus and Systems, 1967, PAS-86(11): 1449-1460.
- [11] KULWORAWANICHPONG T. Simplified newton-raphson power-flow solution method[J]. International Journal of Electrical Power & Energy Systems, 2010, 32(6): 551-558.
- [12] 高珮文, 刘毅力, 刘书玉. 基于改进牛顿法的潮流及短路计算分析[J]. 国外电子测量技术, 2022, 41(8): 54-60.
GAO Peiwen, LIU Yili, LIU Shuyu. Calculation and analysis of power flow short circuit based on improved Newton Method[J]. Foreign Electronic Measurement Technology, 2022, 41(8): 54-60(in Chinese).
- [13] 王睿, 孙秋野, 胡伟, 等. 面向“碳达峰、碳中和”的新型电力系统的潮流计算[J]. 全球能源互联网, 2022, 5(5): 439-446.
WANG Rui, SUN Qiuye, HU Wei, et al. Power Flow Calculation of New Power System for Carbon Peaking and Carbon Neutralization[J]. Journal of Global Energy Interconnection, 2022, 5(5): 439-446(in Chinese).
- [14] 冯卓诚, 姜彤, 万凯遥, 等. 基于节点电压方程拆解的交替迭代潮流算法[J]. 电网技术, 2023, 47(4): 1675-1681.
FENG Zhuocheng, JIANG Tong, WAN Kaiyao, et al. An alternating iterative power flow algorithm based on bus voltage equation decomposition[J]. Power System Technology, 2023, 47(4): 1675-1681(in Chinese).
- [15] DONON B, CLÉMENT R, DONNOT B, et al. Neural networks for power flow: graph neural solver[J]. Electric Power Systems Research, 2020, 189: 106547.
- [16] 马丁, 沈沉, 陈颖, 等. 深度学习应用于潮流计算收敛问题的可行性研究[J]. 南方电网技术, 2020, 14(2): 46-54.
MA Ding, SHEN Chen, CHEN Ying, et al. Feasibility study on the convergence criterion of power flow calculation based on deep learning [J]. Southern Power System Technology, 2020, 14(2): 46-54(in Chinese).
- [17] 雷江龙, 余娟, 向明旭, 等. 基于深度神经网络的数据驱动潮流计算异常误差改进策略[J]. 电力系统自动化, 2022, 46(1): 76-84.
LEI Jianglong, YU Juan, XIANG Mingxu, et al. Improvement strategy for abnormal error of data-driven power flow calculation

- based on deep neural network[J]. Automation of Electric Power Systems, 2022, 46(1): 76-84(in Chinese).
- [18] 杨燕, 杨知方, 余娟, 等. 基于深度学习的含不确定性 $N-1$ 安全校核方法[J]. 中国电机工程学报, 2021, 41(8): 2716-2724.
YANG Yan, YANG Zhifang, YU Juan, et al. Fast analysis of $N-1$ contingency screening with uncertainty scenarios based on deep learning[J]. Proceedings of the CSEE, 2021, 41(8): 2716-2724(in Chinese).
- [19] 叶倩莹. 基于深度神经网络的可变拓扑电网潮流计算方法研究[D]. 杭州: 浙江大学, 2019.
- [20] XIANG Mingxu, YU Juan, YANG Zhifang, et al. Probabilistic power flow with topology changes based on deep neural network[J]. International Journal of Electrical Power & Energy Systems, 2020, 117: 105650.
- [21] GUPTA H D, SHENG V S. A roadmap to domain knowledge integration in machine learning[C]//2020 IEEE International Conference on Knowledge Graph (ICKG). Nanjing: IEEE, 2020: 145-151.
- [22] CHEN Yuntian, ZHANG Dongxiao. Integration of knowledge and data in machine learning[J/OL]. [2024-03-14]. <https://arxiv.org/abs/2202.10337>.
- [23] DAW A, KARPATNE A, WATKINS W, et al. Knowledge Guided Machine Learning[M]. Boca Raton: Chapman and Hall/CRC, 2022: 353-372.
- [24] JEDDI A B, SHAFIEEZADEH A. A physics-informed graph attention-based approach for power flow analysis[C]//2021 20th IEEE International Conference on Machine Learning and Applications (ICMLA). Pasadena: IEEE, 2021: 1634-1640.
- [25] 杨梅, 刘俊勇, 刘挺坚, 等. 节点图和边图切换卷积驱动的快速静态安全分析方法[J]. 电网技术, 2021, 45(6): 2070-2079.
YANG Mei, LIU Junyong, LIU Tingjian, et al. Switching convolution of node graph and line graph-driven method for fast static security analysis[J]. Power System Technology, 2021, 45(6): 2070-2079(in Chinese).
- [26] NELLIKATH R, CHATZIVASILEIADIS S. Physics-informed neural networks for AC optimal power flow[J]. Electric Power Systems Research, 2022, 212: 108412.
- [27] KINGMA D P, BA J. Adam: a method for stochastic optimization [C]//3rd International Conference on Learning Representations. San Diego: ICLR, 2015.
- [28] IYAMBO P K, TZONEVA R. Transient stability analysis of the IEEE 14-bus electric power system[C]//AFRICON 2007. Windhoek: IEEE, 2007: 1-9.
- [29] BHATT G, AFFLJULLA S. Analysis of large scale PV penetration impact on IEEE 39-Bus power system[C]//2017 IEEE 58th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCon). Riga: IEEE, 2017: 1-6.
- [30] LU M, LO T H. Voltage stability assessment for load-shedding distribution[C]//2023 IEEE Conference on Energy Conversion (CENCON). Kuching: IEEE, 2023: 165-169.



战鹏祥

在线出版日期: 2024-06-06。

收稿日期: 2024-03-18。

作者简介:

战鹏祥(2001), 男, 硕士研究生, 研究方向为深度学习、数据挖掘及其在电力系统中的应用,
E-mail: 2022223040046@stu.scu.edu.cn;

黄飞虎(1990), 男, 博士, 讲师, 通信作者, 研究方向为电力系统优化与运行分析、人工智能,
E-mail: huangfh@scu.edu.cn。

(责任编辑 徐梅)