第 52 卷 第 4 期：1880-1890 高电压技术 Vol.52, No.4: 1880-1890
2026 年 4 月 30 日 High Voltage Engineering April 30, 2026
DOI: 10.13336/j.1003-6520.hve.20250422

融合物理信息和 GraphSAGE 模型的配电网状态估计方法

颜浩伟[1]，陈　中[1]，闪　鑫[2]，田　江[3]
（1. 东南大学电气工程学院，南京 210018；2. 南瑞集团有限公司(国网电力科学研究院有限公司)，南京 211106；3. 国网江苏省电力有限公司苏州供电分公司，苏州 215004）

摘　要：数据驱动型配电网状态估计算法存在物理解释性差、小样本下估计精度低、收敛性能差等不足，为此，该文提出了一种融合物理信息与 GraphSAGE 模型的配电网状态估计方法。首先，由于配电网线路参数对电压幅值与相角起决定性作用，因此在节点特征聚合过程中融入多维边特征信息，增强模型对电网特性的表征能力；其次，结合多头图注意力机制，动态分配不同邻居节点的重要性权重，既能在节点采样时关注更重要的节点、提高模型训练效率，又能使模型突破依赖固定邻接矩阵的局限性；进一步，将物理约束嵌入 GraphSAGE 模型，强制模型在训练过程中遵循物理规律，提升了模型的可解释性和收敛速度；最后，在 IEEE 118 节点配电网系统中进行了仿真实验，并与其他神经网络算法进行对比，结果表明该算法在大型配电网和小样本下具有更优的估计效果。
关键词：配电网状态估计；图神经网络；图采样与聚合；物理信息；图注意力机制

Distribution Network State Estimation Method Based on GraphSAGE Model Embedded with Physical Information

YAN Haowei[1], CHEN Zhong[1], SHAN Xin[2], TIAN Jiang[3]
(1. School of Electrical Engineering, Southeast University, Nanjing 210018, China;
2. NARI Group Corporation(State Grid Electric Power Research Institute), Nanjing 211106, China;
3. Suzhou Power Supply Company of State Grid Jiangsu Electric Power Company, Suzhou 215004, China)

Abstract：The data-driven distribution network state estimation algorithm has shortcomings such as poor physical interpretability, low estimation accuracy under small samples, and poor convergence performance. Therefore, this paper proposes a distribution network state estimation method that integrates physical information and the GraphSAGE model. Firstly, in view of the characteristic that the line parameters of the distribution network play a decisive role in the voltage amplitude and phase, multi-dimensional edge feature information is integrated in the process of node feature aggregation to enhance the model's ability to represent the characteristics of the power grid. Secondly, combined with the multi-head graph attention mechanism, the importance weights of different neighboring nodes are dynamically allocated,which can not only focus on more important nodes during node sampling to improve the training efficiency of the model, but also enable the model to rely on the limitations of the fixed adjacency matrix. Furthermore, physical constraints are embedded into the GraphSAGE model, and the model is forced to follow physical laws during the training process, which improves the interpretability and convergence speed of the model. Finally, simulation experiments were carried out in the IEEE 118-node distribution network system and compared with other neural network algorithms. The results show that this algorithm has better estimation effects in large-scale distribution networks and small samples.
Key words：distribution network state estimation; graph neural network; graph sample and aggregate; physical information; graph attention mechanism

0　引言

在“双碳”战略目标驱动下，现代配电网呈现快速发展态势，其拓扑结构变化日趋频繁，导致系统运行不确定性增大，使配电网安全稳定面临多重考验[1-2]。基于多源量测数据的配电网状态估计技术，通过融合处理实时监测信息精确辨识电网运行工况，为配电自动化系统提供高精度的态势感知信息，

基金资助项目：国家自然科学基金(52077035)。
Project supported by National Natural Science Foundation of China (52077035).

对构建新型电力系统安全防线起关键支撑作用[3-4]。

当前针对配电网状态估计已开展了一系列研究，大致可分为物理驱动方法与数据驱动方法[5-6]。其中，基于物理驱动模型的状态估计方法通常依据电网中物理规律，通过构建精确数学模型来描述电网运行状态。文献[7]提出复数域最小二乘法求解状态估计问题；文献[8]考虑系统运行的不确定性和量测误差的未知性，结合区间约束传播的改进 Krawczyk-Moore 算法求解区间状态估计模型；文献[9]引入事件触发机制代替传统量测数据的周期性采样，针对配电网实时状态感知问题，提出了基于鲁棒集合卡尔曼滤波的配电网三相动态状态估计方法。上述基于物理建模方法大多能取得较为精准的状态估计结果，然而该类方法通常依赖于大量的先验知识和精确的参数设置，当面对实际运行工况下存在的复杂多变场景以及各种数据缺失时，其模型计算复杂度会进一步增加，但模型适应性却会显著降低[10]。

另一方面，基于数据驱动的配电网状态估计借助人工智能算法，通过对大量历史数据的学习和训练，捕捉电网运行中隐含的规律和特征。文献[11]将图注意力网络(graph attention network, GAT)与全景波形结合，深入挖掘故障行波全景波形与网络拓扑结构、故障位置的关联信息；文献[12]在考虑负荷时空特性以及不健全量测的场景下，提出了基于时空特征图卷积网络的配电网状态估计算法；文献[13]提出了一种改进图卷积网络的物理-数据融合配电网状态估计方法，实现了配电网量测信息不足条件下的高精度状态估计。然而，单纯基于数据驱动的异常检测方法往往缺乏对电网固有物理属性的深刻理解，并容易受到数据质量和数量的影响，当数据过少时难以确保检测结果的稳定性和可信度[14]。

为了融合物理驱动和数据驱动的优点，本文提出了一种融合物理信息和 GraphSAGE 模型的配电网状态估计方法。首先根据配电网信息与图数据的对应关系，进行配电网状态估计图数据建模，构建多运行场景下的图数据集；然后，构建以 GraphSAGE 为核心的图神经网络框架，引入多头图注意力机制实现邻居特征优化聚合，并基于电网运行约束将物理方程融入损失函数，强制模型输出符合实际系统的预测；最后，通过仿真实验验证，本文模型在大型配电网拓扑变化未知情况下可在毫秒级时间内实现状态量精准估计，在小样本下也能一定程度弥补数据缺失的不足。相较传统方法，所提模型展现出显著的动态适应能力、多场景泛化特性以及拓扑结构扩展优势，为新型电力系统状态感知提供创新解决方案。

1　配电网状态估计与图神经网络

在传统图神经网络中，电力系统网架可抽象为数学中的图结构，由节点和边组成，母线为节点，输电线路为边[15]。例如，图 G 可记为 $G=(V, E)$，其中 $V=\{V_1, V_2, \cdots, V_N\}$为节点集合，$E=\{E_1, E_2, \cdots, E_N\}$为边集合，$N$ 为节点数，M 为边数。若节点 V_i 和 V_j 直接相连，则存在边 $E_k=(V_i, V_j)$。

图神经网络(graph neural network, GNN)在图结构上构建[16]，其输入量包括节点特征 $\boldsymbol{X}$ 和图结构特征 $\boldsymbol{A}$。其中 $\boldsymbol{X}\in\mathbb{R}^{N\times D}$，矩阵每一行对应于一个节点的 D 维特征，在状态估计中节点特征为节点电压、节点电压相角、节点注入有功功率和无功功率的 4 维向量；$\boldsymbol{A}=\left[a_{ij}\right]\in\mathbb{R}^{N\times N}$ 为图的邻接节点，若节点 V_i 和 V_j 直接相连，则 $a_{ij}=1$，否则 $a_{ij}=0$，即：

$$\boldsymbol{A}=\begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix} \tag{1}$$

式中：$a_{ij}=0$或$1, \forall i, j\le N$。由于电力系统本身的连接特点，邻接矩阵 $\boldsymbol{A}$ 通常高度稀疏。

定义度矩阵为 $\boldsymbol{D}=\mathrm{diag}\left(d_1, d_2, \cdots, d_n\right)$，$d_i=\sum a_{ij}$ 为节点 i 的度，即：

$$\boldsymbol{D}=\begin{bmatrix} d_1 & & & \\ & d_2 & & \\ & & \ddots & \\ & & & d_n \end{bmatrix} \tag{2}$$

进一步定义标准化邻接矩阵 $\tilde{\boldsymbol{A}}$ 如式(3)所示，即根据节点的度对邻接矩阵进行标准化。

$$\tilde{\boldsymbol{A}}=\boldsymbol{D}^{-\frac{1}{2}}\boldsymbol{A}\boldsymbol{D}^{-\frac{1}{2}}=\begin{bmatrix} \dfrac{a_{11}}{\sqrt{d_1 d_1}} & \dfrac{a_{12}}{\sqrt{d_1 d_2}} & \cdots & \dfrac{a_{1n}}{\sqrt{d_1 d_n}} \\ \dfrac{a_{21}}{\sqrt{d_2 d_1}} & \dfrac{a_{22}}{\sqrt{d_2 d_2}} & \cdots & \dfrac{a_{2n}}{\sqrt{d_2 d_n}} \\ \vdots & \vdots & & \vdots \\ \dfrac{a_{n1}}{\sqrt{d_n d_1}} & \dfrac{a_{n2}}{\sqrt{d_n d_2}} & \cdots & \dfrac{a_{nn}}{\sqrt{d_n d_n}} \end{bmatrix} \tag{3}$$

一般地，图神经网络核心思想是通过消息传递机制利用相邻节点的空间关联性进行特征聚合，进而更新中心节点的特征[17]。这一过程进行多轮迭代

使各节点能够有效捕获更远距离的特征，最终每个节点的特征将包含邻居以及更多节点的信息。假设节点 V_i 的特征表示为 $\boldsymbol{h}_i \in \mathbb{R}^K$，并记 V_i 的邻居节点集合为 $N(i)$，则特征聚合和更新可表示为：

$$\boldsymbol{h}_i' = f_\theta\left(\boldsymbol{h}_i, f_\eta\left(\left\{\boldsymbol{h}_j \middle| j \in N(i)\right\}\right)\right) \tag{4}$$

式中：$f_\eta(\cdot)$ 和 $f_\theta(\cdot)$ 分别为聚合和更新过程。例如，对于图卷积网络(graph convolutional network, GCN)模型，第 l 层的消息传递方式为：

$$\boldsymbol{H}^{(l+1)} = \sigma\left(\tilde{\boldsymbol{A}}\boldsymbol{H}^{(l)}\boldsymbol{W}^{(l)}\right) = \sigma\left(\boldsymbol{D}^{-\frac{1}{2}}\boldsymbol{A}\boldsymbol{D}^{-\frac{1}{2}}\boldsymbol{H}^{(l)}\boldsymbol{W}^{(l)}\right) \tag{5}$$

式中：$\boldsymbol{W}^{(l)}$ 为第 l 层可训练的参数；$\boldsymbol{H}^{(l)}$ 为第 l 层各节点特征；$\sigma(\cdot)$ 为非线性激活函数；$\boldsymbol{H}^{(l+1)}$ 为计算得到的第 l+1 层特征。

可以看出，GCN 对所有邻接节点都是依据由拓扑确定的相同且固定权重(即标准化邻接矩阵 $\tilde{\boldsymbol{A}}$)进行消息传递，未考虑实际应用中不同邻接节点的重要性差异及不同场景下的重要性变化，限制了图神经网络的表达能力[18]。实际上在不同潮流方式下电网节点间联系紧密程度可能并不相同，因而常规图神经网络并不能完全适应电力系统安全稳定分析应用场景。

2 融合物理信息和改进 GraphSAGE 模型的配电网状态估计方法

图卷积神经网络的训练过程依赖全图拓扑连接矩阵，其模型性能与拓扑结构密切相关，通常仅适用于静态拓扑结构的节点特征学习。针对这一局限性，文献[19]创新性地提出基于邻居节点采样的 GraphSAGE 模型，更适用于未知拓扑构的学习，本文引入该模型，对于拓扑多变的配网具有更强的适应性。该模型具有迁移能力的节点嵌入生成机制，采用固定深度邻域搜索算法实现层次化特征提取，结合可学习的非线性聚合函数，形成与拓扑结构无关的节点表征表达式，不仅满足海量图数据处理需求，更能在分布式计算环境下保持计算复杂度可控，为配网状态估计动态图结构场景下的归纳式学习提供了途径。

2.1 边特征聚合

目前 GraphSAGE 模型在特征聚合过程中仅考虑节点特征的空间关系[20]，即在进行特征聚合操作时只能对目标节点的邻居节点特征进行聚合，无法对与目标节点相连的边特征进行有效利用。而配电网状态估计中线路参数对电压幅值与相位起决定性作用，因此本文对 GraphSAGE 模型进行进一步改进，将配电网中所有节点相邻的边特征聚合到节点特征之上，确保在后续操作时能够充分考虑边特征的影响。

设节点 i 的特征为 $\boldsymbol{h}_{\mathrm{v}(i)}$，与其邻接的边特征聚合到节点特征上的步骤如下：

1）通过扫描边连接矩阵 $\boldsymbol{A}$ 获取与节点 i 相关联的所有边构成集合 $E(i)$。

2）根据集合 $E(i)$从边特征矩阵 $\boldsymbol{E}$ 中获取对应边的特征表示，并运用平均聚合对这些特征进行整合，生成邻边聚合特征 $\boldsymbol{h}_{\mathrm{E}(i)}$。

3）将节点特征 $\boldsymbol{h}_{\mathrm{v}(i)}$ 与邻边聚合特征 $\boldsymbol{h}_{\mathrm{E}(i)}$ 合并成节点 i 新的特征。

2.2 邻居节点采样

针对大规模图模型中全邻域特征聚合引发的计算开销急剧增长问题，GraphSAGE 创新性地在特征聚合之前引入邻居节点采样策略[21]。该方法通过对相邻节点进行有选择性的采样，将参与聚合的邻接节点数量控制在固定规模，从而显著降低计算资源消耗。这种基于采样的局部结构归纳机制不仅能够有效缓解模型过拟合风险，还能提升算法对不同拓扑结构的泛化性能。特别在配电网状态估计场景中，该模型通过动态调整邻域采样范围，既可适应配电网拓扑结构的频繁变动，又能平衡计算精度与效率，展现出相较于传统图神经网络的显著优势。

在节点采样过程中，采用由中心向外围的递进式扩展策略，以配电网中各节点为辐射中心，可将电网拓扑结构解构为 K 层邻域层级。在配电网中不同量测点的重要性不同，例如辐射型网络中根节点、T 接网路中联络节点的重要性更强，基于配电网的节点物理特征，本文在邻居节点采样过程中引入多头注意力机制[22]，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。下面以 $K-1$ 层某一节点 v 为例，其采样出的 K 层邻居节点图注意力系数计算过程为：

$$\alpha_{ij} = \frac{\exp\left(\sigma_{\mathrm{a}}\left(\boldsymbol{a}\left(\boldsymbol{W}\boldsymbol{h}_i, \boldsymbol{W}\boldsymbol{h}_j\right)\right)\right)}{\sum_{j \in N_K(v)} \exp\left(\sigma_{\mathrm{a}}\left(\boldsymbol{a}\left(\boldsymbol{W}\boldsymbol{h}_i, \boldsymbol{W}\boldsymbol{h}_j\right)\right)\right)} \tag{6}$$

式中：$N_K(v)$ 为节点 v 的 K 层邻居节点集合；α_{ij} 为注意力系数；$\boldsymbol{W}$ 为可学习权重矩阵；$\boldsymbol{a}$ 为可学习参数向量；σ_{a} 为 LeakyReLU 激活函数。

在第 1 轮采样过程中，根据边连接矩阵 $\boldsymbol{A}$ 获取

每个节点的所有 1 阶邻居节点，然后根据式(6)从 1 阶邻居节点中采样出指定数量的重要节点，例如采样 N_1 个，若 1 阶邻居节点个数不足 N_1 个，则使用全部 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，同样采样 N_2 个较为重要的节点，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 $l(1\le l\le k)$层的每个节点采样 N_k 个 k 阶邻居节点。

2.3　节点特征聚合

基于分层节点采样机制，各节点可动态构建包含直接邻接节点(1 阶邻域)和间接关联节点(2 阶邻域)的多级拓扑关联网络。通过聚合采样所得邻域节点特征与自身特征进行聚合，形成统一维度的输出。为应对邻域节点数量动态变化的特点，该机制采用可适应不同邻域规模的聚合算法，以确保输出的特征维度始终相同，不受节点数量的影响。如图 1 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 $K-1$ 层邻居节点之上，逐层聚合，最后聚合到中心节点上。

$K-1$ 层的某一节点 i 的特征为 $\boldsymbol{h}_{\mathrm{v}(i)}^{K-1}$，其在 K 层采样出的邻居节点集合为 $N_K(i)$，此节点的邻居节点特征聚合公式为：

$$\boldsymbol{h}_{N_K(i)}^{K-1}=\sigma_{\mathrm{b}}\left(\boldsymbol{h}_{\mathrm{v}(j)}^{K},\forall j\in N_K(i)\right) \tag{7}$$

式中：σ_{b} 表示聚合函数。

由于 $\boldsymbol{h}_{N_K(i)}^{K-1}$ 仅考虑了节点 i 的 K 层邻居节点特征，因此还需与节点 i 自身特征 $\boldsymbol{h}_{\mathrm{v}(i)}^{K-1}$ 拼接后作为节点 i 新的特征，即：

$$\hat{\boldsymbol{h}}_{\mathrm{v}(i)}^{K-1}=\sigma\left(\boldsymbol{W}^{k}\sigma_{\mathrm{c}}\left(\boldsymbol{h}_{N_K(i)}^{K-1},\boldsymbol{h}_{\mathrm{v}(i)}^{K-1}\right)\right) \tag{8}$$

式中：$\boldsymbol{W}^{k}$ 为可学习的权重参数；σ_{c} 为特征向量拼接函数。

对每一层的所有节点都按照式(7)、(8)的步骤进行节点特征聚合，经过多轮迭代，最终每个节点特征都得到了更新。

将式(6)计算出的注意力系数代入节点特征聚合过程中，得到新的节点特征聚合公式：

$$\boldsymbol{h}_{N_K(i)}^{K-1}=\sigma_{\mathrm{d}}\left(\alpha_{ij}^{m}\boldsymbol{h}_{\mathrm{v}(j)}^{K},\forall j\in N_K(i)\right) \tag{9}$$

$$\hat{\boldsymbol{h}}_{\mathrm{v}(i)}^{K-1}=\mathop{\Big\|}_{m=1}^{K'}\sigma\left(W^{k}\sigma_{\mathrm{c}}\left(\boldsymbol{h}_{N_K(i)}^{K-1},\boldsymbol{h}_{\mathrm{v}(i)}^{K-1}\right)\right) \tag{10}$$

式中：σ_{d} 为平均聚合函数；“||”表示向量拼接；K' 为注意力头数。图 2 为加入多头注意力系数的特征聚合示意图。

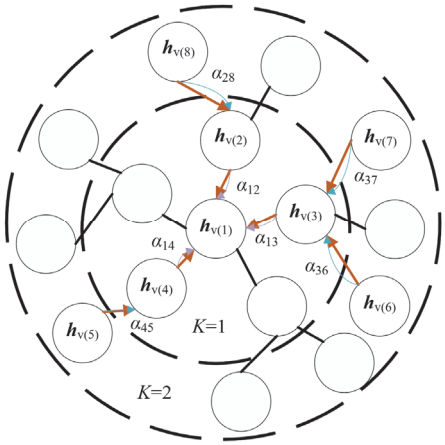


图 1　节点特征聚合

Fig.1　Node feature aggregation

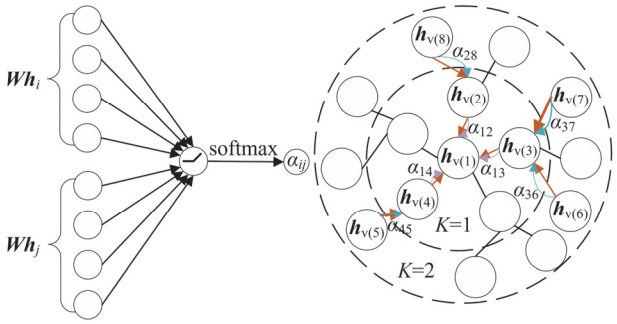


图 2　加入多头注意力机制的节点特征聚合

Fig.2　Node feature aggregation with multi-head attention mechanism

2.4　融入物理信息的损失函数构造

损失函数作为模型优化的核心评价机制，在机器学习训练过程中承担着可微分评价指标的核心作用[23]。其数学本质是通过构建预测输出与真实标签之间的偏差度量空间，量化模型预测误差的数值表征。在模型迭代训练阶段，基于反向传播机制，结合梯度下降算法，系统化实施参数空间寻优：首先计算当前网络权重下的损失函数梯度张量，继而通过链式求导法则逐层调整神经网络的可训练参数，驱动模型输出分布向真实数据分布渐进式收敛。这种基于误差反馈的动态优化过程，本质上是通过最小化预设的损失曲面(如均方误差、交叉熵等)，促使模型参数逐步逼近全局最优解空间，从而实现从高维特征到目标输出的精准映射关系学习。在状态估计中，可用加权最小二乘法(weighted least squares, WLS)构造损失函数，即：

$$L(z,x)=\sum_{k\in U}\frac{\left|\boldsymbol{z}_k-\boldsymbol{h}_k(x)\right|^2}{\sigma_k^2} \tag{11}$$

式中：σ_k 为量测量的标准差；$\boldsymbol{z}_k$ 为量测向量，包含节点电压幅值、节点注入功率、支路功率；$\boldsymbol{h}_k(x)$ 为真实向量；x 为状态变量，包含节点电压幅值和相角；U 为量测数据集。

然而，模型的计算性能受到训练数据集数量少和缺乏配电网状态估计计算过程中相关物理信息的限制，预测结果可能出现不满足某些约束条件的情况。通过增加数据集数量只能缓解这一问题，需将神经网络模型与物理模型相结合，即将配电网状态估计所需的物理约束条件加入损失函数，以实现预测结果与物理知识的一致性。本模型将以下 3 种主要约束条件加入损失函数中，以减少局部极小值的数量：电压稳定约束、相角稳定约束和功率平衡约束。

1）电压稳定约束损失

电力系统中，需确保每个节点的电压等级在 $V^{\mathrm{LB}}\sim V^{\mathrm{UB}}$ 之间保持稳定，其中 $V^{\mathrm{LB}}=95\%$，$V^{\mathrm{UB}}=105\%$。因此，在损失函数中增加了一个双边惩罚 $\left(\left(V_k-V^{\mathrm{LB}}\right)+\left(V^{\mathrm{UB}}-V_k\right)\right)$ 来强制执行该准则，即：

$$L_1=\sum_{k\in U}\left(\left(V_k-V^{\mathrm{LB}}\right)^2+\left(V^{\mathrm{UB}}-V_k\right)^2\right) \tag{12}$$

式中：L_1 为电压稳定约束的损失函数；V_k 为节点电压标幺值。

2）相角稳定约束损失

在稳定系统中，相角不能发生较大变化。例如，若 2 个相邻节点之间的相位角差>$\Delta\varphi^{\mathrm{UB}}$(0.25 rad)，则表示网络不稳定。因此，在损失函数中添加第 2 个双边惩罚 $\left(\left(\Delta\varphi_k-\Delta\varphi^{\mathrm{UB}}\right)+\left(-\Delta\varphi^{\mathrm{UB}}-\Delta\varphi_k\right)\right)$，以约束相位角差<0.25 rad，即：

$$L_2=\sum_{k\in U}\left(\left(\Delta\varphi_k-\Delta\varphi^{\mathrm{UB}}\right)^2+\left(-\Delta\varphi^{\mathrm{UB}}-\Delta\varphi_k\right)^2\right) \tag{13}$$

式中：L_2 为相角稳定约束的损失函数；$\Delta\varphi_k$ 为相邻节点的相角差；$\Delta\varphi^{\mathrm{UB}}$ 为相邻节点的相角差的上限，值为 0.25 rad。

3）功率平衡约束损失

在电力系统中，功率平衡约束是确保系统稳定运行的关键条件之一，它要求在任何时刻，节点总发电功率必须等于总负荷功率加上系统中的总损耗。功率平衡约束可以分为有功功率平衡和无功功率平衡 2 部分，即：

$$L_3=\sum_{k\in U}\left(\begin{array}{l}\left(P_k+\sum\limits_{i\in N_{\mathrm{DG}}}P_{\mathrm{DG},i}-\sum\limits_{j\in N_k}P_{kj}\right)^2+\\ \left(Q_k+\sum\limits_{i\in N_{\mathrm{DG}}}Q_{\mathrm{DG},i}-\sum\limits_{j\in N_k}Q_{kj}\right)^2\end{array}\right) \tag{14}$$

式中：L_3 为功率平衡约束的损失函数；P_k 为节点注入有功功率；Q_k 为节点注入无功功率；P_{kj} 为支路 kj 上的有功功率；Q_{kj} 为支路 kj 上的无功功率；$P_{\mathrm{DG},i}$ 为分布式电源注入有功功率；$Q_{\mathrm{DG},i}$ 为分布式电源注入有功功率；N_{DG} 为节点 i 接入的分布式新能源集合；N_k 为与节点 i 连接的支路集合。

4）分布式电源出力约束

电力系统中，分布式新能源的出力波动可能导致电网频率偏差或电压越限。通过设定出力上下限，可减少功率突变对电网的冲击，避免系统失稳。在损失函数中增加了一个双边惩罚 $\left(\left(P_{\mathrm{DG},i}-P_{\mathrm{DG},i}^{\min}\right)+\left(P_{\mathrm{DG},i}^{\max}-P_{\mathrm{DG},i}\right)\right)$ 来强制执行该准则，即：

$$L_4=\sum_{i\in N_{\mathrm{DG}}}\left(\left(P_{\mathrm{DG},i}-P_{\mathrm{DG},i}^{\min}\right)^2+\left(P_{\mathrm{DG},i}^{\max}-P_{\mathrm{DG},i}\right)^2\right) \tag{15}$$

式中：L_4 为分布式电源出力约束的损失函数；$P_{\mathrm{DG},i}$ 为节点的分布式电源出力总和；$P_{\mathrm{DG},i}^{\max}$ 和 $P_{\mathrm{DG},i}^{\min}$ 为分布式电源出力的上、下限。

总的损失函数表示上述函数加权之和：

$$f_{\mathrm{Loss}}=\lambda_{\mu}L(z,x)+\lambda_1L_1+\lambda_2L_2+\lambda_3L_3+\lambda_4L_4 \tag{16}$$

式中：λ_{μ}、λ_1、λ_2、λ_3、λ_4 分别为各损失函数的权重。各权重系数设置遵循量纲一致性原则、物理约束优先级原则和数据可靠性原则。确保各损失项处于同一量级，并按重要性分级设定权重，若量测误差较大，则需增大物理约束权重；若数据充足且精确，则可适当降低物理约束权重。

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

3 融合物理信息和 GraphSAGE 模型的配电网状态估计流程

基于第 2 章所提方法，本文所提融合物理信息和 GraphSAGE 模型的配电网状态估计框架如图 3 所示。利用本文所提配电网状态估计计算方法流程如下：

1）构建数据集。数据处理层负责将配电网量测数据转化为 $\boldsymbol{G}(\boldsymbol{X},\boldsymbol{A},\boldsymbol{E})$形式。$\boldsymbol{X}$ 是电网节点的特征矩阵，表示电网的节点信息，本模型中包含节点

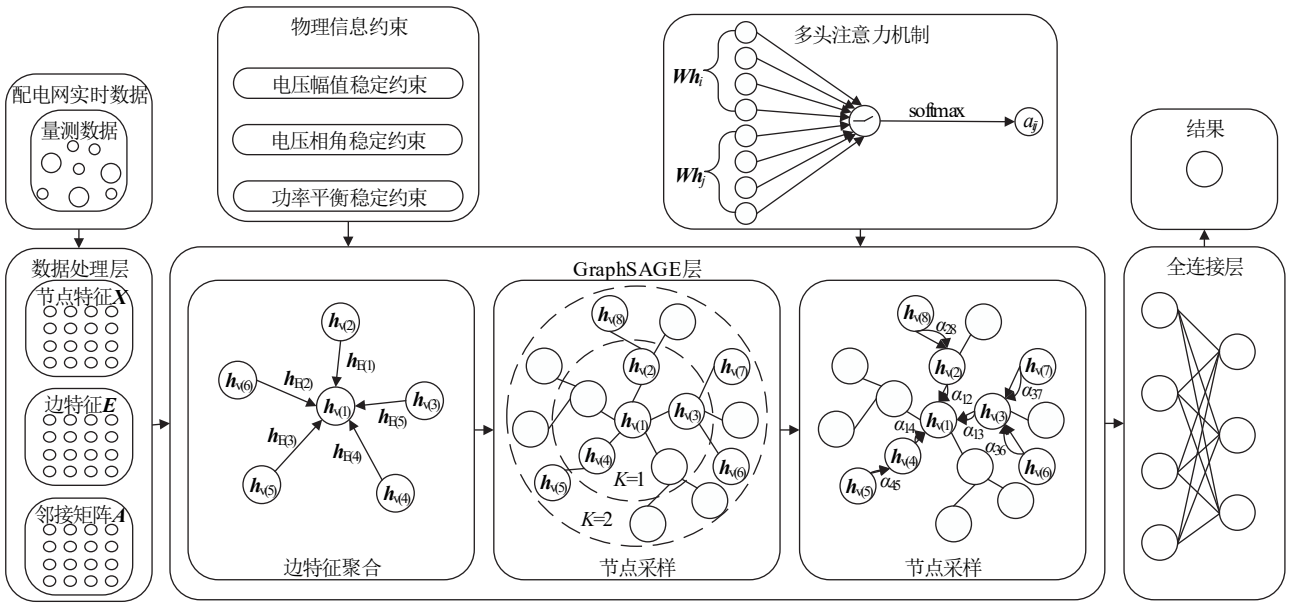


图 3　内嵌物理知识学习的配电网状态估计模型框架

Fig.3　Distribution network state estimation model framework with embedded physics knowledge learning

电压、节点电压相角、节点注入有功功率和无功功率；$\boldsymbol{A}$ 是邻接矩阵，用于描述电网的拓扑结构；$\boldsymbol{E}$ 是边特征矩阵，包含电网的支路有功、无功功率和支路导纳。考虑量测数据量纲的异构性对模型训练的影响和过拟合现象，对数据进行归一化处理，即：

$$u_k' = \frac{u_k - \min\limits_k (u_k)}{\max\limits_k (u_k) - \min\limits_k (u_k)} \tag{17}$$

式中：u_k' 为第 k 个量测量归一后的值；u_k 为第 k 个量测量真实值。

2）模型训练。GraphSAGE 层首先将节点特征和边特征融合来考虑配电网线路参数对状态估计结果的影响，接着进行邻居节点采样，并同时采样到邻居节点的注意力系数，通过多头注意力机制在节点特征聚合过程中对不同的邻居节点采取不同的权重，使得模型能够更深入学习到节点特征表示，最终得到状态估计模型。

3）在线应用。将当前时刻电网的量测数据拓扑信息输入训练好的状态估计模型中，在线计算输出配电网状态估计结果。

4　算例分析

4.1　算例设置

算例基于 IEEE 118 节点配电网系统[24]，额定电压设定为 12.66 kV，基准功率取 10 MVA，为验证所提算法的有效性，选取多种神经网络模型作为基准方法进行性能对比。为模拟配电网真实运行状态变化，实验采用某实际电网连续 400 h 的运行数据构建负荷曲线，以 20 min 作为 1 个采样周期，共可获得 1 200 组的采样数据，包括每个节点的电压幅值、电压相角、注入有功功率和无功功率的量测值，其中训练集 840 份样本、验证集 240 份样本、测试集 120 份样本。数据构建过程中，首先通过潮流计算生成基准真值，叠加均值为 0、标准差为 0.01 的高斯分布随机扰动来模拟量测噪声，融合离线拓扑信息构建数据集，模型训练阶段采用相位角作为监督标签，通过计算预测值与真值间的损失函数优化网络参数。

测试的硬件平台为 PC 机，处理器为 Intel® Core™i7-9700CPU@3.00 GHz，内存为 12 GB，基于 Python 软件的 Pytorch 模块进行编程。

为了更直观体现本文所提算法和其他算法的估计性能差异，对估计状态量计算平均相对误差，即：

$$\bar{\delta} = \frac{1}{U}\sum_{l=1}^{U}\left|\frac{\widehat{\boldsymbol{h}_k}(l) - \boldsymbol{h}_k(l)}{\boldsymbol{h}_k(l)} \times 100\%\right| \tag{18}$$

式中：$\bar{\delta}$ 为平均相对误差；$\widehat{\boldsymbol{h}_k}(l)$ 为第 l 个量测数据集下第 k 个状态估计结果；$\boldsymbol{h}_k(l)$ 为第 l 个量测数据集下第 k 个真实值。

4.2　参数设置

模型以平均百分比误差 ε (mean absolute per-

centage error, MAPE)损失率和预测精度ψ作为实验指标，对比不同模型性能，具体计算式为：

$$\varepsilon=\frac{\sum\left|(\hat{y}-y)/y\right|}{M}\times 100\% \tag{19}$$

式中：y为样本标签；$\hat{y}$为模型预测配电网状态量估计值；M为样本数量。

预测精度计算式为：

$$\psi=1-\varepsilon \tag{20}$$

为了更好地对比不同注意力头数时模型的性能，本文使用不同头数的注意力机制训练得到模型，所得结果如表 1 所示。

由表 1 可知，在训练本文模型时，当注意力机制的头数取 4 时，训练集精度最高，效果最佳，该头数下的模型可以更好地捕捉数据中的关键信息。相反地，当注意力机制的头数取 10 时，模型的效果较差，这是因为当头数过多时，在小样本下预训练模型不能很好地学习重要的特征，进而导致模型性能下降。因此，在小样本下训练神经网络模型时，注意力机制的头数并不是越多越好，而是需要根据实验数据和模型结构进行合理的选择。

经过多次实验得到最优的模型性能，参数设置如表 2 所示。

4.3 损失和精度对比实验

分别采用 GCN 模型、传统 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率大小，如图 4 所示。

从图 4 可以看出，由于 GCN 模型使用所有邻居节点特征进行卷积操作，当迭代次数较少时，未能充分学习到配电网图数据全局特征，因此此时损失率曲线波动较大；当迭代次数超过 400 时，GCN 模型的损失率曲线趋于平稳，几乎无波动。GraphSAGE 模型使用邻居采样策略和归纳式学习，能显著降低计算复杂度，训练收敛速度较 GCN 有明显提升，当迭代次数超过 400 时，训练集损失率与 GCN 模型区别不大。本文模型基于 GraphSAGE 模型，在节点特征聚合时嵌入边特征，使得模型学习更全面，通过多头图注意力机制，关注更加重要的节点特征，并且通过内嵌物理信息，使得训练和预测过程满足物理约束，因此训练速度与训练精度有一定提升。

在迭代训练过程中，同时使用训练后的模型对验证集进行状态估计，并画出对应的损失率随迭代次数变化的曲线，验证集实验结果如图 5 所示。当各模型训练完成后，通过测试集得到各模型测试集

表 1 不同注意力头数下训练精度对比

Table 1 Comparison of training accuracy under different numbers of attention heads

注意力头数	训练集损失率/%	训练集精度/%
4	3.44	96.56
6	4.78	95.22
8	6.17	93.83
10	10.83	89.17

表 2 参数设置

Table 2 Parameter settings

参数名称	取值
迭代次数	1 000
神经网络层数	2
隐藏层单元大小	128
多头注意力机制头数	4
学习率	0.001
聚合函数	Mean
激活函数	LeakyReLU
优化器	Adam

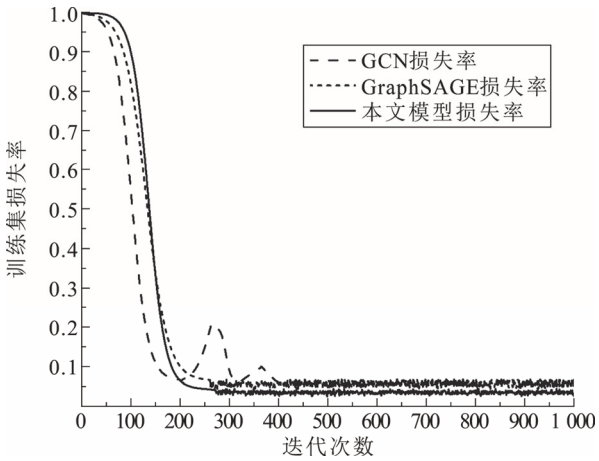


图 4 训练集损失率

Fig.4 Loss rate of training set

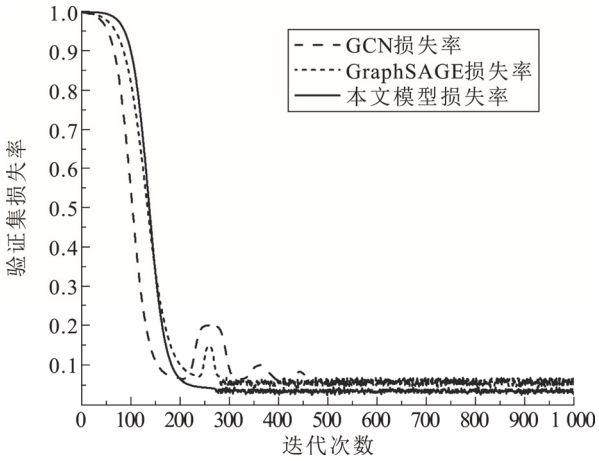


图 5 验证集损失率

Fig.5 Loss rate of verification set

平均损失率和精度对比，如表 3 所示。

4.4　小样本下的正确性验证和对比

在采用本模型进行配电网状态估计过程中，由于实际配电网网络拓扑规模通常很大，导致构建数据集异常困难且工作量巨大，因此设计本实验来降低训练样本的数量，各模型在小样本情况下对完整拓扑下的状态估计进行了模拟仿真，并与 GCN、GAT、GraphSAGE 进行对比，所得各节点状态估计结果精度如表 4 所示。

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。GraphSAGE 通过邻居节点采样与聚合，避免对全图数据的依赖，预测精度高于 GCN 和 GAT；本文算法在 GraphSAGE 模型基础上，通过损失函数内嵌物理信息使得模型在小样本情况下预测精度更高，这是因为内嵌了物理信息之后，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，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，因此下降幅度最小，即使在训练样本数只有 200 的情况下，预测精度仍然可以达到 93.45%。

4.5　拓扑变化下的正确性验证和对比

随机模拟了如表 5 所示的 5 种配电网拓扑变化情况，每个拓扑选取 20 个不同时间时刻下的量测数据和拓扑结构。该算例以随机选取的节点 68 为例，并与 WLS、GCN、GraphSAGE、PINN、DeepPhy 进行对比，各算法在拓扑变化下估计的电压幅值平均相对误差和电压相角平均相对误差分别如表 6 和表 7 所示。

由表 6 和表 7 可知，某条支路断开后拓扑发生变化，传统 WLS 算法和 GCN 算法难以满足精度要求；PINN 算法和 DeepPhy 算法将物理信息融入数据驱动模型中，因此精度较 GCN 有所提升，但在多处拓扑变化情况下，估计精度明显降低；而本文算法在 GraphSAGE 算法基础上，通过邻域节点采样策略，并将线路电气特征聚合到节点特征上，同时通过可学习的特征聚合器和多头注意力权重分配模块，根据邻居节点重要性，动态分配权重，而非依赖固定图结构，从而实现对未知节点及新拓扑结构的直接泛化推理，适用于拓扑结构动态变化的场景，因此获得了更精确的状态估计结果；实验结果表明，当断开支路数增加时，本文所提算法精度略有降低，估计误差增幅控制在 3%以内，仍在可接受范围之内，且较其他 3 种方法有明显优势。

表 3　测试集损失率和精度

Table 3　Loss rate and accuracy of test set

模型	测试集损失率/%	测试集精度/%
GCN	6.37	93.63
GraphSAGE	5.86	94.14
本文模型	3.44	96.56
GAT	5.74	94.26
GIN	8.53	91.47

表 4　不同数量样本下各模型预测精度对比

Table 4　Comparison of the prediction accuracy of each model under different numbers of samples

算法	不同样本数下的预测精度/%			
	200	400	600	800
本文算法	93.45	94.87	95.42	96.63
GCN	85.87	88.23	90.65	92.85
GAT	86.76	89.62	91.94	93.39
GraphSAGE	90.52	92.03	93.34	95.26

表 5　拓扑变化场景

Table 5　Topological time-varying conditions

时间断面	拓扑
1~20	拓扑 1：支路 5-6 断开
21~40	拓扑 2：支路 32-33 断开
41~60	拓扑 3：支路 55-56 断开
61~80	拓扑 4：支路 2-4、支路 26-27、支路 41-42 和支路 78-79 断开

表 6　IEEE 118 节点拓扑时变下电压幅值估计误差

Table 6　Voltage amplitude estimation error of time-varying topology of IEEE 118 nodes

算法	节点电压幅值平均相对误差/%			
	拓扑 1	拓扑 2	拓扑 3	拓扑 4
本文算法	0.370 7	0.389 8	0.368 6	0.417 9
WLS	6.106 8	6.338 4	5.893 4	9.845 9
GCN	4.768 3	4.682 4	4.247 8	7.846 7
GraphSAGE	2.163 7	2.171 2	2.165 3	2.189 7
PINN	1.457 3	1.625 6	1.729 4	3.527 9
DeepPhy	1.367 2	1.769 2	1.545 8	2.959 5

表 7　IEEE 118 节点拓扑时变下电压相角估计误差

Table 7　Voltage phase angle estimation error of time-varying topology of IEEE 118 nodes

算法	节点电压相角平均相对误差/%			
	拓扑 1	拓扑 2	拓扑 3	拓扑 4
本文算法	0.391 4	0.407 3	0.412 3	0.421 2
WLS	6.045 4	6.234 6	6.184 1	10.853 6
GCN	4.853 6	4.633 9	4.619 5	6.837 6
GraphSAGE	2.173 2	2.184 6	2.169 3	2.236 8
PINN	1.546 4	1.667 4	1.363 6	3.555 3
DeepPhy	1.494 3	1.785 2	1.763 6	3.483 1

4.6 非高斯噪声下的正确性验证和对比

在配电网实际运行中，存在大量多样化的噪声，为了更好地验证本文算法的抗噪性，在潮流计算生成的基准真值上叠加非高斯噪声，噪声分布为：

$$r_k = 0.7N_\rho\left(0,0.05^2\right)+0.3N_\rho\left(0,1\,000\times0.05^2\right) \quad (24)$$

式中：r_k 为量测噪声；$N_\rho\left(\mu,\sigma_\rho^2\right)$ 为均值 μ、标准差 σ_ρ 的高斯分布。

在非高斯噪声条件下进行仿真实验，各节点状态估计结果如图 6 和图 7 所示，电压幅值平均相对误差和电压相角平均相对误差如表 8 所示。

可以看出，在非高斯噪声下，相较于高斯噪声，各算法估计性能均有所下降，而由于 PINN 和本文算法将物理约束融入损失函数中，迫使模型输出必须满足这些规律，因此当数据中存在噪声时，物理约束会惩罚偏离规律的解，从而过滤掉不合理的噪声影响，仍能保持较好的估计精度。本文算法在提升状态估计精度的同时，还能保证一定的抗噪性，可见本文算法的优越性。

4.7 计算时间对比

传统状态估计方法基于雅可比矩阵的迭代修正机制，可实现状态量的精确求解，但随着系统复杂度增加，其运算负荷呈指数级增长。本文算法引入数据驱动的思想，学习量测量和状态量之间的潜在关联，无需对系统内部进行精确建模，同时在损失函数中融入物理信息，强制训练过程满足物理约束，缩短训练时间，显著提升了系统在线评估效率。不同规模电力系统完整拓扑下使用 GCN 算法、GraphSAGE 算法和本文算法的在线估计时间如表 9 所示。

由表 9 可知，对于较小规模的电力系统，本文所提方法在计算时间上的优势并不显著。然而，随着系统规模的逐步扩大，GraphSAGE 算法由于邻居采样策略，支持小批量训练，因此估计耗时能保持相对稳定，未出现显著增长。相比之下，GCN 算法和 PINN 算法在计算大规模系统时必须加载完整的图结构，导致内存消耗大，花费时间久。而本文算法由于增加了物理信息约束，计算时间较 GraphSAGE 算法进一步缩短。在面对如 IEEE 13984 节点这样的大型系统时，本文算法具有较好的可行性。

5 结论

本文聚焦于传统数据驱动配电网状态估计算法中存在的物理解释性差、小样本下估计精度低、计算速度慢的问题，提出了一种基于融合物理信息和 GraphSAGE 模型的配电网状态估计方法。通过理论分析与仿真对比，得到以下结论：

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，能够捕捉到图的局部和全局特征，对配电网拓扑变

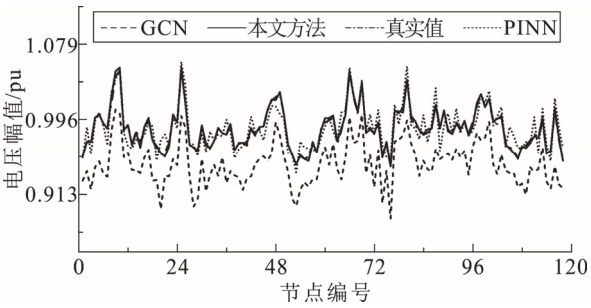


图 6 非高斯噪声下的电压幅值估计情况

Fig.6 Voltage amplitude estimation under non-Gaussian noise

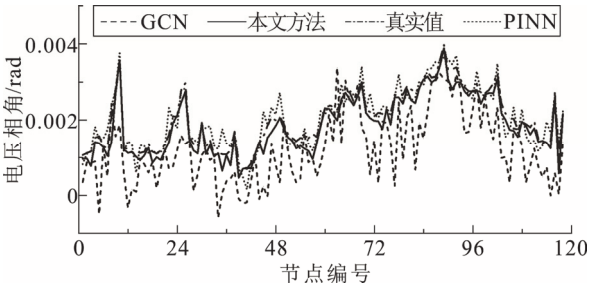


图 7 非高斯噪声下的电压相角估计情况

Fig.7 Voltage phase angle estimation under non-Gaussian noise

表 8 非高斯噪声下电压幅值和相角估计精度

Table 8 Estimation accuracy of voltage amplitude and phase angle under non-Gaussian noise

算法	幅值平均相对误差/%	相角平均相对误差/%
本文算法	0.355 6	0.525 9
GCN	5.073 2	6.343 3
PINN	0.893 1	1.466 7

表 9 各系统完整拓扑下估计时间比较

Table 9 Comparison of estimated time in the complete topology of each system

测试系统	估计耗时/s			
	GCN	GraphSAGE	PINN	本文模型
IEEE 118	0.008 1	0.014 5	0.012 8	0.014 3
IEEE 300	0.060 2	0.017 3	0.045 5	0.017 7
IEEE 2786	0.696 3	0.043 4	0.389 7	0.021 7
IEEE 8449	4.947 9	0.088 0	2.137 5	0.037 8
IEEE 13984	10.769 5	0.163 9	7.182 9	0.047 3

化具有更强的适应能力。

2）物理信息融入 GraphSAGE 模型，使其结果更加符合现实物理常识，约束损失可削弱异常值的梯度贡献，在原理层面提高了模型的鲁棒性、可信性及可解释性。此外，物理约束在训练过程中作为隐式正则化项，一定程度上弥补了小样本数据不足的缺陷，降低了模型训练要求，可行性强。

3）本文模型在配电网拓扑未知情况下能较为精确地预测出配电网的状态估计结果，更符合配电网实际情况与未来新能源并网的趋势。

4）本文所提算法在新型配电网状态估计中具有较好的应用前景，与传统 WLS 算法相比，在保证计算精度的同时，在大型电网状态估计中的计算时间大幅缩短，能够满足在线应用要求。

后续工作考虑将物理信息内嵌入模型中而并非只在损失函数中，并与分布式计算融合以进一步提升大规模电网状态估计的效率和扩展性。

参考文献　References

[1] 郑凯元，王　松，高　阳，等. 同步波形数据及其在电力系统应用综述[J]. 电力信息与通信技术，2025，23(2)：59-70.
ZHENG Kaiyuan, WANG Song, GAO Yang, et al. A review of synchronized waveform data and its application in power system[J]. Electric Power Information and Communication Technology, 2025, 23(2): 59-70.

[2] 王成山，于　浩，李　鹏，等. 新型配电网中的软件定义技术理念及特征[J]. 新型电力系统，2024，2(1)：1-12.
WANG Chengshan, YU Hao, LI Peng, et al. Concepts and features of software-defined technology in new power distribution networks[J]. New Type Power Systems, 2024, 2(1): 1-12.

[3] 林　军，张洋宁，刘吉权，等. 基于 5G 的智能配网保护流量控制方法分析[J]. 电力信息与通信技术，2025，23(2)：94-99.
LIN Jun, ZHANG Yangning, LIU Jiquan, et al. Analysis of flow control methods for 5G smart distribution network protection[J]. Electric Power Information and Communication Technology, 2025, 23(2): 94-99.

[4] 王　玥，于　越，金朝阳. 基于改进 Att-LSTNet 与无迹粒子滤波融合的主动配电网预测辅助状态估计[J]. 电力系统保护与控制，2024，52(8)：98-110.
WANG Yue, YU Yue, JIN Zhaoyang. Forecasting-aided state estimation for active distribution networks based on improved Att-LSTNet and unscented particle filter fusion[J]. Power System Protection and Control, 2024, 52(8): 98-110.

[5] 孙　健，李　勇，王秀茹. 基于多源量测的主配网一体化状态估计方法[J]. 电力系统及其自动化学报，2024，36(4)：76-83.
SUN Jian, LI Yong, WANG Xiuru. State estimation method for integrated transmission-distribution power system based on multi-source measurement data[J]. Proceedings of the CSU-EPSA, 2024, 36(4): 76-83.

[6] 梁　栋，刘啸宇，曾　林，等. 基于潮流引导神经网络的配电网贝叶斯状态估计[J]. 高电压技术，2024，50(11)：4864-4874.
LIANG Dong, LIU Xiaoyu, ZENG Lin, et al. Bayesian state estimation for distribution networks based on power flow-informed neural networks[J]. High Voltage Engineering, 2024, 50(11): 4864-4874.

[7] 魏新迟，徐　琴，柳劲松，等. 基于同步相量测量的配电网状态估计方法[J]. 电力系统及其自动化学报，2023，35(9)：30-39.
WEI Xinchi, XU Qin, LIU Jinsong, et al. Synchronous phasor measurements based distribution network state estimation method[J]. Proceedings of the CSU-EPSA, 2023, 35(9): 30-39.

[8] 李诗伟，骆　晨，何　叶，等. 多源量测环境下计及时延融合的配电网区间状态估计[J]. 电力系统自动化，2024，48(12)：120-129.
LI Shiwei, LUO Chen, HE Ye, et al. Interval state estimation for distribution network considering time-delay fusion in multi-source measurement environment[J]. Automation of Electric Power Systems, 2024, 48(12): 120-129.

[9] 黄蔓云，徐启颖，孙国强，等. 事件触发机制下配电网三相动态状态估计[J]. 电力系统自动化，2024，48(13)：100-108.
HUANG Manyun, XU Qiying, SUN Guoqiang, et al. Three-phase dynamic state estimation for distribution network in event-triggered mechanism[J]. Automation of Electric Power Systems, 2024, 48(13): 100-108.

[10] 蒲天骄，乔　骥，赵紫璇，等. 面向电力系统智能分析的机器学习可解释性方法研究(一)：基本概念与框架[J]. 中国电机工程学报，2023，43(18)：7010-7029.
PU Tianjiao, QIAO Ji, ZHAO Zixuan, et al. Research on interpretable methods of machine learning applied in intelligent analysis of power system (part I): basic concept and framework[J]. Proceedings of the CSEE, 2023, 43(18): 7010-7029.

[11] 席　磊，陈采玉，陈洪军，等. 基于图注意力与多尺度并行融合卷积的虚假数据注入攻击定位检测[J]. 高电压技术，2025，51(4)：1763-1772.
XI Lei, CHEN Caiyu, CHEN Hongjun, et al. Localization detection for false data injection attacks based on graph attention and multi-scale parallel fusion convolution[J]. High Voltage Engineering, 2025, 51(4): 1763-1772.

[12] 陈源奕，王玉彬，杨　强. 基于时空特征图卷积网络的配电网实时状态估计方法[J]. 高电压技术，2021，47(7)：2386-2395.
CHEN Yuanyi, WANG Yubin, YANG Qiang. Real-time state estimation method for distribution networks based on spatial-temporal feature graph convolution network[J]. High Voltage Engineering, 2021, 47(7): 2386-2395.

[13] 王春义，卢志鹏，杨　扬，等. 基于改进图卷积网络的配电网状态估计方法[J]. 现代电力，2023，40(1)：133-142.
WANG Chunyi, LU Zhipeng, YANG Yang, et al. An improved graph convolutional network-based state estimation method of distribution network[J]. Modern Electric Power, 2023, 40(1): 133-142.

[14] 杨　茂，王　达，王小海，等. 基于数据物理混合驱动的超短期风电功率预测模型[J]. 高电压技术，2024，50(11)：5132-5141.
YANG Mao, WANG Da, WANG Xiaohai, et al. Ultra-short term wind power prediction method based on data physics hybrid driven model[J]. High Voltage Engineering, 2024, 50(11): 5132-5141.

[15] 于　越，丁　磊，金朝阳. 考虑小样本不平衡的主动配电网预测辅助鲁棒状态估计[J]. 高电压技术，2024，50(10)：4550-4560.
YU Yue, DING Lei, JIN Zhaoyang. Robust forecasting-aided state estimation method of active distribution network considering small sample imbalance[J]. High Voltage Engineering, 2024, 50(10): 4550-4560.

[16] 周　宁，方　治，蔺晨晖，等. 基于正则化拉格朗日乘子法的配电网网络拓扑辨识[J]. 供用电，2024，41(6)：12-20.
ZHOU Ning, FANG Zhi, LIN Chenhui, et al. Topology identification of distribution network based on regularized Lagrangian multiplier[J].

Distribution & Utilization, 2024, 41(6): 12-20.

[17] 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)：4396-4404.
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): 4396-4404.

[18] 胡家祥，曹　迪，胡维昊，等. 融入拓扑知识的图神经网络配电网抗差状态估计方法[J]. 电力系统自动化，2023，47(10)：84-97.
HU Jiaxiang, CAO Di, HU Weihao, et al. Robust state estimation method for distribution network based on graph neural network incorporating topology knowledge[J]. Automation of Electric Power Systems, 2023, 47(10): 84-97.

[19] 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.

[20] 郭　傲，陈　颖，肖谭南，等. 基于消息传递网络的多变拓扑微电网群故障检测方法[J]. 高电压技术，2023，49(6)：2339-2347.
GUO Ao, CHEN Ying, XIAO Tannan, et al. A fault detection method for multi-microgrid considering topological variations based on message passing neural network[J]. High Voltage Engineering, 2023, 49(6): 2339-2347.

[21] 顾雪平，刘　彤，李少岩，等. 用于未来态预测的电网运行断面时空相似性挖掘[J]. 电工技术学报，2022，37(23)：6145-6156.
GU Xueping, LIU Tong, LI Shaoyan, et al. Temporal and spatial similarity mining of power grid running section for future state prediction[J]. Transactions of China Electrotechnical Society, 2022, 37(23): 6145-6156.

[22] 王　泽，张玉敏，吉兴全，等. 基于深度学习与内核岭回归的电力系统鲁棒状态估计[J]. 高电压技术，2022，48(4)：1332-1342.
WANG Ze, ZHANG Yumin, JI Xingquan, et al. Robust state estimation of power system based on deep learning and kernel ridge regression[J]. High Voltage Engineering, 2022, 48(4): 1332-1342.

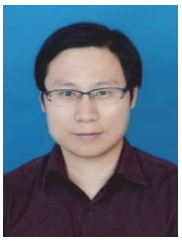
[23] 张佳琛，郭庆来，王志伟，等. 基于物理信息神经网络的热网动态状态估计方法[J]. 电力自动化设备，2023，43(10)：69-78.
ZHANG Jiachen, GUO Qinglai, WANG Zhiwei, et al. Dynamic state estimation method of heating network based on physics-informed neural networks[J]. Electric Power Automation Equipment, 2023, 43(10): 69-78.

[24] 陈　中，顾叮咚，郭　庆. 考虑全局相关性的主动配电网电压安全优化控制[J]. 电力系统自动化，2023，47(21)：99-107.
CHEN Zhong, GU Dingdong, GUO Qing. Optimization and control of voltage security in active distribution network considering global correlation[J]. Automation of Electric Power Systems, 2023, 47(21): 99-107.



颜浩伟
1998—，男，硕士生
主要研究方向为新型电力系统配电网状态估计等
E-mail:220232946@seu.edu.cn

YAN Haowei



陈　中(通信作者)
1975—，男，博士，教授，博导
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

CHEN Zhong
Ph.D., Professor
Corresponding author

收稿日期　2025-03-31　在线出版日期　2025-07-23　　编辑　程子丰