

DOI: 10.19783/j.cnki.pspc.230867

基于集成深度神经网络的配电网分布式状态估计方法

张汪洋, 樊艳芳, 侯俊杰, 宋雨露

(新疆大学电气工程学院, 新疆 乌鲁木齐 830047)

摘要: 随着大量分布式能源的接入, 配电系统的运行与控制方式愈加复杂。针对配电网状态估计方法面临分布式电源波动数据辨识困难、估计精度低、鲁棒性与估计时效性差等问题, 提出一种基于集成深度神经网络的配电网分布式状态估计方法。首先, 利用量测数据相关性检验的数据辨识技术识别不良数据和新能源波动数据。在此基础上, 利用时域卷积网络(temporal convolutional network, TCN)-双向长短期记忆网络(bidirectional long short term memory, BILSTM)对不良数据进行修正。然后, 建立集成深度神经网络(deep neural network, DNN)状态估计模型, 采用最大相关-最小冗余(maximum relevance-minimum redundancy, MRMR)的方法优化训练样本, 从而提高状态估计的精度和鲁棒性。最后, 建立分布式集成深度神经网络模型, 弥补了集中式状态估计速度慢的不足, 从而提高状态估计效率。基于 IEEE123 配电网的算例分析表明, 所提方法能更准确地辨识分布式电源波动数据和不良数据, 同时提高状态估计的精度和效率, 且具有较高的鲁棒性。

关键词: 状态估计; 最大相关-最小冗余; 分布式; 集成深度神经网络

Distribution network distributed state estimation method based on an integrated deep neural network

ZHANG Wangyang, FAN Yanfang, HOU Junjie, SONG Yulu

(School of Electrical Engineering, Xinjiang University, Urumqi 830047, China)

Abstract: With the integration of a large number of distributed energy sources, the operation and control methods of distribution systems have become increasingly complex. In response to the problems faced by distribution network state estimation methods such as difficulty in identifying distributed power source fluctuation data, low estimation accuracy, poor robustness and estimation timeliness, a distribution network distributed state estimation method based on integrated deep neural networks is proposed. First, the data identification technique of measuring data correlation testing is used to identify bad data and new energy fluctuation data. From this, the bad data is corrected using a temporal convolutional network (TCN) - bidirectional long short term memory (BILSTM). Then, an integrated deep neural network (DNN) state estimation model is established, and the maximum relevance-minimum redundancy (MRMR) method is used to optimize the training samples, thereby improving accuracy and robustness. Finally, a distributed integrated DNN model is established to compensate for the slow speed of centralized state estimation and improve efficiency. The numerical analysis based on an IEEE123 distribution network shows that the proposed method can more accurately identify distributed power source fluctuation data and bad data, while improving the accuracy and efficiency of state estimation, and is very robust.

This work is supported by the National Natural Science Foundation of Xinjiang Uygur Autonomous Region (No. 2022D01C365 and No. 2022D01C662).

Key words: state estimation; maximum relevance-minimum redundancy; distributed; integrated deep neural network

0 引言

随着我国“双碳”目标的提出, 为了高效地处

理指数级增长的配电网数据, 保障配电网稳定、可靠地运行, 对状态估计的精度和效率提出更高的要求^[1-3]。配电网状态估计作为配电管理系统(distribution management system, DMS)的基础, 通过对远程终端单元(remote terminal unit, RTU)、同步相量量测单元(phasor measurement unit, PMU)和高级量测体系(advanced metering infrastructure, AMI)等量测装置

基金项目: 新疆维吾尔自治区自然科学基金项目资助(2022D01C365, 2022D01C662); 2022 天山英才培养计划项目资助(2022TSYCLJ0019)

采集的实时量测数据的分析和计算^[4], 从而为配电系统提供可靠的运行数据。

由于分布式电源(distributed generation, DG)在配电网中广泛应用, 配电网的运行变得更为复杂, 控制与调度的难度也相应提升^[5-8]。同时 DG 具有分散性、随机性和波动性的特点, 增加了配电网不良数据辨识的难度。传统的不良数据辨识方法有: 残差搜索法^[9]、非二次准则法^[10]、估计辨识法^[11]和零残差辨识法^[12]等。然而在配电网同时出现不良数据的情况下, 上述不良数据辨识方法经常会出过辨识现象, 将分布式电源的正常波动数据当作不良数据剔除, 进而引发 DMS 的错误分析, 导致配电网的监测和控制出现较大偏差, 进而影响配电网的安全性和可靠性。

配电网节点众多、规模庞大, 传统集中式状态估计方法如基于加权最小二乘法(weighted least square, WLS)状态估计^[13]、基于加权最小绝对值(weighted least absolute value, WLAV)状态估计^[14]、Huber-M 估计^[15]、指数型目标函数估计^[16]等, 需要在处理大量实时量测数据的同时完成复杂的数学计算, 难以满足大规模配电网对状态估计精度和效率的要求。相比于传统的集中式状态估计, 分布式状态估计方法将任务分配给各个子区域并行计算, 提高了状态估计的效率^[17], 更有研究价值和现实意义。国内外学者对分布式状态估计进行了一系列研究, 然而目前的分布式状态估计多采用基于物理模型的方法^[18], 未能充分挖掘配电网历史运行数据中的有效信息, 从而限制了配电网状态估计精度、效率和鲁棒性的提升。基于数据驱动的状态估计方法^[19]可以有效地处理电力系统非线性、高维度的信息, 已成为配电网分布式状态估计领域的研究热点。文献[20]提出了联合长短期记忆神经网络和粒子滤波状态估计, 采用孤立森林法检测不良数据, 有较高的估计精度, 但对量测数据有过辨识的风险。文献[21]提出了基于门控图神经网络模型的状态估计算法, 利用图卷积层和类门控循环单元挖掘状态量与量测量之间的因果与时空关系, 有较高的鲁棒性, 但估计效率不够高。

为解决配电网中存在的过辨识、状态估计精度与效率不够高的问题, 并进一步提高系统的鲁棒性, 本文提出一种基于集成深度神经网络的配电网分布式状态估计方法。首先根据相容量测找出可疑数据, 并基于量测数据相关性检验的不良数据辨识方法, 剔除可疑数据中的不良数据, 保留 DG 波动数据, 经时域卷积网络(temporal convolutional network, TCN)-双向长短期记忆网络(bidirectional

long short term memory, BiLSTM)组合算法将不良数据修正后, 得到完整的量测数据集; 其次建立基于集成深度神经网络的状态估计模型并用最大相关-最小冗余(maximum relevance-minimum redundancy, MRMR)算法对量测数据集进行特征量测量提取, 得到优化后的训练样本; 最后建立分布式集成深度神经网络模型对配电网进行状态估计。经算例验证, 本文方法能够有效避免传统集中式状态估计方法的诸多不足, 提高配电网状态估计的精度、效率和鲁棒性, 更加适应配电网发展的需要。

1 不良数据的辨识与修正

当分布式电源接入电网时, 其运行数据会随着气象条件的变化而波动, 传统的不良数据辨识方法可能将正常波动的量测数据误判为不良数据并剔除, 进而影响系统正常运行, 因此本文提出了基于量测数据相关性检验的不良数据辨识方法与基于TCN-BiLSTM的不良数据修正方法。

1.1 基于量测数据相关性检验的不良数据辨识

电力系统中节点和支路的量测量如: 节点注入功率量测、节点电压幅值量测、支路功率与电流量测等之间受到物理拓扑和功率潮流约束, 在连续时段内存在一定的时间相关性^[22]。选取时间长度为 T 的量测序列 $[z_{k+1-T}, z_{k+2-T}, \dots, z_k]$, 计算两量测序列的皮尔逊相关系数如式(1)所示。

$$r = \frac{\sum_{t=1}^T (z_{k+1-t}(\mathbf{I}) - \bar{z}(\mathbf{I}))(z_{k+1-t}(\mathbf{J}) - \bar{z}(\mathbf{J}))}{\sqrt{\sum_{t=1}^T (z_{k+1-t}(\mathbf{I}) - \bar{z}(\mathbf{I}))^2} \sqrt{\sum_{t=1}^T (z_{k+1-t}(\mathbf{J}) - \bar{z}(\mathbf{J}))^2}} \quad (1)$$

式中: r 为量测序列 \mathbf{I} 、 \mathbf{J} 的相关系数; $\bar{z}(\cdot)$ 为量测序列的平均值; $z_{k+1-t}(\cdot)$ 为量测序列中第 $k+1-t$ 时刻的量测量。

由统计学中一般定义, 当 $0.8 < |r| \leq 1$ 时, 两量测序列互为极强相关。经仿真验证, 在 DG 接入的配电网中, 互为极强相关量测序列的相关系数变化较为稳定^[23]; 而含有不良数据时, 其值波动范围较大。为描述连续 N 个极强相关量测序列相关系数的最大波动范围 Δr_o , 本文选取时间长度均为 T 的量测序列 \mathbf{I} 和第 o 个与其互为极强相关的量测序列 \mathbf{J}_o , 计算它们在 $k+1$ 时刻之前的连续 N 个相关系数 $[r_1, r_2, \dots, r_N]$ 最大波动范围, 如式(2)所示。

$$\Delta r_o = |r_{\max}| - |r_{\min}| \quad (2)$$

式中, r_{\max} 、 r_{\min} 分别为量测序列 \mathbf{I} 和 \mathbf{J}_o 在连续 N 个相关系数 $[r_1, r_2, \dots, r_N]$ 中的最大、最小值。

在第 $k+1$ 时刻该相关系数的波动值 $\Delta r'_o$ 如式(3)所示。

$$\Delta r'_o = \|r_{N+1} - r_N\| \quad (3)$$

式中, r_{N+1} 为量测序列 I 和 J_o 在第 $k+1$ 时刻的相关系数。

本文将在第 $k+1$ 时刻与量测序列 I 互为极强相关的量测序列 J_o 所对应的量测量满足式(4)判定为不良数据, 否则判定为波动数据, 如式(4)所示。

$$\Delta r'_o > \Delta r_o \quad (o=1, 2, \dots, s) \quad (4)$$

式中, s 为与量测序列 I 互为强相关的量测序列 J_o 的数量。

文献[24]提出了相容量测的概念: 对于某一量测值 Q_i , 已知其噪声分布, 将 Q_i 的估计值 \hat{Q}_i 与量测值 \hat{Q}_i 之差记为 β_i , 若能找一组状态量, 使得 Q_1, Q_2, \dots, Q_n 满足式(5), 则称量测是相容的。

$$|\beta_i| \leq 3\sigma_i, \quad i=1, 2, \dots, n \quad (5)$$

式中, σ_i 为分布标准差。

根据相容量测的定义, 正常量测集合必定是相容量测, 因此将在 $k+1$ 时刻除集合 A 外的数据定义为可疑量测集合 B , 集合 B 中可能包含 DG 波动数据。本文方法先根据相容量测得出集合 B , 然后根据其相关系数的波动情况, 逐一对各个可疑数据进行不良数据的排查, 区分出不良数据和正常波动数据。

1.2 基于 TCN-BILSTM 的不良数据修正

当识别并剔除出不良数据后, 需要对其进行修正得到完整的量测数据集, 本文采用 TCN-BILSTM 生成伪量测, 对不良数据进行修正。

1.2.1 TCN-BILSTM 模型框架

TCN-BILSTM 不良数据修正框架由输入层、时域卷积网络层、双向长短期记忆网络预测层构成。具体结构如图 1 所示。

1) 输入层: 读取配电网节点注入功率量测、节点电压幅值量测、支路功率与电流量测数据, 并将量测数据通过滑动窗 ($T=10$) 进行数据重构, 结果如表 1 所示。

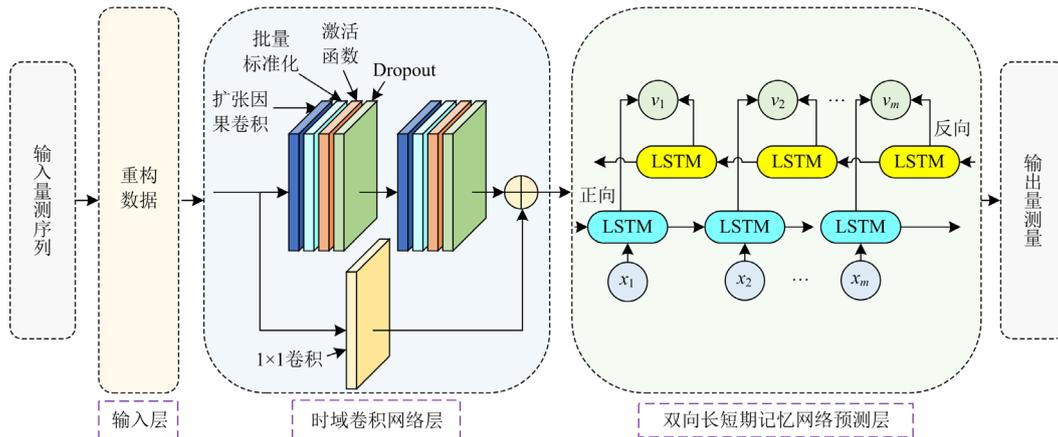


图 1 TCN-BILSTM 不良数据修正原理

Fig. 1 TCN-BILSTM bad data correction principle

表 1 数据重构结果

Table 1 Data reconstruction results

| 输入样本 | 输出样本 |
|--|-----------|
| $Z_1, Z_2, Z_3, Z_4, \dots, Z_{10}$ | Z_{11} |
| $Z_2, Z_3, Z_4, Z_5, \dots, Z_{11}$ | Z_{12} |
| \vdots | \vdots |
| $Z_{101}, Z_{102}, Z_{103}, Z_{104}, \dots, Z_{110}$ | Z_{111} |
| \vdots | \vdots |

2) 时域卷积网络层: TCN 是一种用于时间序列建模的神经网络模型^[25], 在电力系统量测量预测任务中, TCN 在特征提取方面显示出卓越的能力, 可以将原始测量特征进行融合, 从而提取高维度的抽

象特征, 进一步增强对测量信息的挖掘能力。相较于传统的一维卷积, TCN 具有一种独特的扩张因果卷积结构: 扩张卷积对上一层的输入进行扩张采样, 拥有较大的感受视野, 能够接收更长时间的数据采集与监控 (supervisory control and data acquisition, SCADA) 系统、PMU、AMI 的历史量测数据; 因果卷积保证预测结果不受未来信息的影响, 提高了模型的可靠性。TCN 残差模块中 ReLU 激活函数和 Dropout 层通常被应用在扩张因果卷积层之后, 在训练过程中用以稳定模型梯度, 并防止过拟合, TCN 计算公式和扩张因果卷积、残差模块的结构参见文献[26]。

3) 双向长短期记忆网络预测层: TCN 有很强的时序特征提取能力, 但通常无法获取从后到前的信息, 为了进一步提高模型预测的准确性, 本文引入 BILSTM 模型与 TCN 模型及进行组合, 以便更好地捕获量测序列中的双向依赖关系, 从而更加精确地对量测数据进行预测。BILSTM 由正向 LSTM 和反向 LSTM 组成, LSTM 网络的门结构和计算公式参考文献[27]。

1.2.2 TCN-BILSTM 不良数据修正流程

1) 读取配电网量测数据集并清洗, 经滑动窗口重构, 并划分为量测训练集与量测测试集。

2) 将量测训练集送至 TCN-BILSTM 模型进行训练, 经量测测试集测试后保存最佳模型参数: 时域卷积网络层的层数为 1, 卷积核个数为 100, 卷积核大小为 3, 扩张系数 d 分别为 1、2、4、8、16、32; BILSTM 网络的层数为 1, 神经元个数为 32, 激活函数为 \tanh , 模型优化器为 Adam, 学习率为 0.001, 损失函数为 mse, 迭代次数为 100, batchsize 为 32。

3) 在 $k+1$ 时刻识别出电力系统中的不良数据后, 将该量测量在 $k+1-T$ 时刻至 k 时刻的量测序列 $[z_{k+1-T}, z_{k+2-T}, \dots, z_k]$ 输入至预训练的 TCN-BILSTM 网络中, 由 TCN 提取量测时序特征输入至 BILSTM 网络对第 $k+1$ 时刻的量测量进行预测, 用预测值 z_{k+1} 替换不良数据, 完成不良数据修正。不良数据的辨识与修正具体流程见图 2。

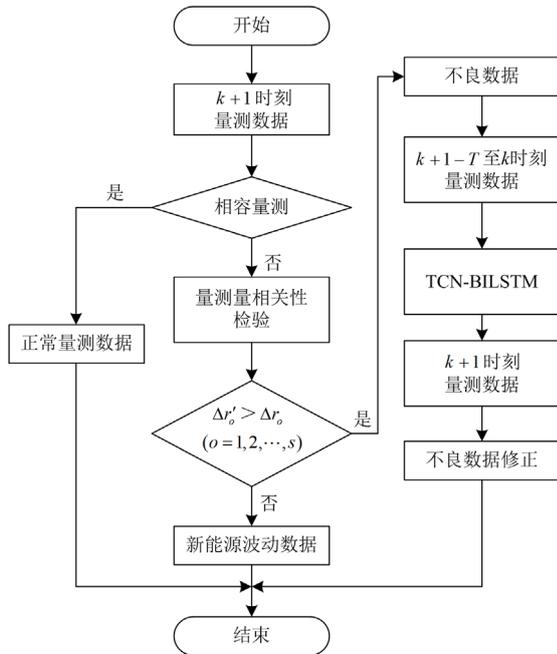


图 2 不良数据辨识与修正流程图

Fig. 2 Flow chart for identification and correction of bad data

2 基于集成 DNN 的状态估计模型

2.1 状态估计基本模型

传统电力系统状态估计算法先进行物理建模, 然后将原始量测数据进行迭代计算来获得当前的最优估计值: 在 k 时刻, 由包含噪声的系统实时量测量 $\mathbf{Z}(k)$ 得出系统实时状态量(节点电压幅值和相角) $\mathbf{X}(k)$, 物理模型为

$$\mathbf{Z}(k) = f(\mathbf{X}(k)) + \xi(k) \quad (6)$$

式中: $f(\cdot)$ 为量测函数; $\xi(k)$ 为量测噪声, 包括建模误差。

2.2 集成 DNN 状态估计模型

传统 WLS 方法对于测量误差的敏感性较高, 当输入信号中包含了较大的噪声干扰时, 会影响到状态估计的精度^[28]。为了解决上述问题, DNN 被引入到状态估计中, 然而 DNN 是通过随机训练算法学习参数, 导致模型每次训练的参数变化很大, 从而在每次训练后得到不同的权重集, 只用单一 DNN 进行状态估计会导致模型出现泛化能力差的问题, 影响状态估计的性能。因此, 本文将 DNN 作为基学习器, 支持向量回归(support vector regression, SVR)作为元学习器, 将多个 DNN 与一个 SVR 模型组合为集成 DNN 状态估计器, 并使用 MRMR 算法优化训练样本, 以提高估计状态估计的精度。

2.2.1 基学习器 DNN

DNN 由多个神经元层组成, 包括输入层、多个隐藏层和输出层, 各层之间全连接, 在训练过程中通过前向传播算法和反向传播算法交替进行^[29]。前向传播算法中, 使用前一层神经元的输出作为后一层神经元的输入, 如式(7)和式(8)所示。

$$c_i^l = \sum_{j=1}^v w_{ij}^l a_j^{l-1} + h_i^l \quad (7)$$

$$a_i^l = \sigma(c_i^l) \quad (8)$$

式中: c_i^l 为第 L 层、第 l 个神经元激活前的输出; w_{ij}^l 为 a_j^{l-1} 到 c_i^l 的线性传递系数; a_i^l 为第 L 层、第 l 个神经元激活后的输出; h_i^l 为偏置常数; $\sigma(\cdot)$ 为激活函数。

DNN 反向传播算法将正向传播输出状态估计值与真实状态量比较, 计算损失函数, 根据梯度下降法使损失函数取极小值, 从而更新每个神经元的线性传递系数 w 和偏置常数 h , 损失函数采用均方误差函数。DNN 作为基学习器, 分别对节点电压幅值和相角进行多次预测, 并把所有预测值组合为元学习器的输入。

2.2.2 元学习器 SVR

SVR 是一种监督学习方法^[30], 遵循结构风险最小化原则, 旨在同时将训练样本的经验风险和置信范围最小化, 以提高未知样本的泛化能力, 能够更好地处理基学习器 DNN 的预测量, 从而完成系统的状态估计。将基学习器的预测量与状态量一起组成数 n 个 u 维的训练样本 D , 如式(9)所示。

$$D = \{(x_i, y_i)\}_{i=1}^n \quad (9)$$

式中: x_i 为基学习器预测量, $x_i \in R^u$, R^u 为样本空间; y_i 为状态量, $y_i \in R$; n 为样本个数。

设非线性映射函数为 $\varphi(x)$, 将训练集从低维空间映射到高维空间的定义为

$$f(x) = \omega^\top \varphi(x) + b \quad (10)$$

式中: $f(x)$ 为回归函数; ω 为权重向量; b 为截距。

利用结构风险最小化原则, 得到的风险函数如式(11)所示。

$$\min_{\omega, b} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^n \ell(f(x_i), y_i) \quad (11)$$

式中: $\|\omega\|^2$ 为结构风险; ℓ 为损失函数; c 为惩罚系数, $c > 0$ 。

求风险函数的最小值与求解式(12)约束最小化优化问题等价。

$$\begin{cases} \min_{\omega, b, \xi_i, \hat{\xi}_i} \frac{1}{2} \|\omega\|^2 + c \sum_{i=1}^n (\xi_i + \hat{\xi}_i) \\ \text{s.t.} \begin{cases} y - (\omega, \varphi(x_i)) - b \leq \varepsilon + \hat{\xi}_i \\ -y + (\omega, \varphi(x_i)) + b \leq \varepsilon + \xi_i \\ \xi_i \geq 0, \hat{\xi}_i \geq 0, i = 1, 2, \dots, n \end{cases} \end{cases} \quad (12)$$

式中: ξ_i 和 $\hat{\xi}_i$ 均为松弛变量; ε 为不敏感损失系数。

为了便于计算, 使用拉格朗日函数将上述优化问题转化为对偶问题。通过引入高斯核函数, 集成 DNN 状态估计问题可以表示为

$$f(x) = \sum_{i=1}^n (\alpha_i - \hat{\alpha}_i) K(x_i, x) + b \quad (13)$$

式中: α_i 和 $\hat{\alpha}_i$ 均为拉格朗日乘子; $K(x_i, x)$ 为核函数。

本文选取径向基核函数, 如式(14)所示。

$$K(x_i, x) = e^{-\frac{\|x_i - x\|^2}{\sigma^2}} \quad (14)$$

式中, σ 为径向基核函数的宽度。

在实验中, SVR 模型的各个参数通过程序自动寻优确定。

2.2.3 基于 MRMR 的集成 DNN 输入特征筛选

配电网中量测数据规模庞大, 由于量测量中包

含大量与状态量关联性很低的量测特征, 若把所有的量测数据作为 DNN 的特征输入时会存在特征冗余, 使得 DNN 学习效率下降, 影响状态估计的准确性。为提高 DNN 训练效率, 本文以支路功率和节点注入功率为量测量, 以节点电压幅值和电压相角为状态量, 采用最大相关-最小冗余算法^[31]综合考虑量测量与状态量相关性、各量测量之间的冗余性, 对 DNN 输入特征进行筛选。

输入特征筛选: 从初始 W 个量测量数据集 $G = \{g_1, g_2, \dots, g_W\}$ 中筛选出与状态量相关性最大且与其他量测量相关性最小的 m 个量测量, 作为 DNN 网络的最优输入特征, 以提高模型状态估计的效率和精度。互信息的计算公式为

$$I(e, g_i) = \iint p(e, g_i) \log \frac{p(e, g_i)}{p(e)p(g_i)} de dg_i \quad (15)$$

$$I(g_i, g_q) = \iint p(g_i, g_q) \log \frac{p(g_i, g_q)}{p(g_i)p(g_q)} dg_i dg_q \quad (16)$$

式中: $I(e, g_i)$ 为量测量 g_i 与状态量 e 的互信息; $I(g_i, g_q)$ 为量测量 g_i 、 g_q 之间的互信息, $g_i, g_q \in G$, $i \neq q$; $p(\cdot)$ 为概率密度函数。

最大相关计算原则如式(17)所示。

$$D(S, e) = \frac{1}{|S|} \sum_{g_i \in S} I(e, g_i) \quad (17)$$

最小冗余计算原则如式(18)所示。

$$R(S) = \frac{1}{|S|^2} \sum_{g_i, g_q \in S} I(g_i, g_q) \quad (18)$$

式中: S 为目标量测特征集合; $|S|$ 为 S 的维数; $D(\cdot)$ 为相关性; $R(\cdot)$ 为冗余性。

整合 $D(S, e)$ 和 $R(S)$, MRMR 的计算指标为

$$\begin{cases} \max \phi(D, R) \\ \phi = D - R \end{cases} \quad (19)$$

采用增量搜索法求解式(19), 在已选出 $m-1$ 个量测量的集合 S_{m-1} 后, 从 G 中剩余的量测量 $U = G - S_{m-1}$ 选取第 m 个量测量, 应满足式(20)。

$$\max_{g_q \in U} \left[I(g_q, e) - \frac{1}{m-1} \sum_{g_i \in S_{m-1}} I(g_q, g_i) \right] \quad (20)$$

通过以上准则, 将与节点电压幅值对应的输入特征量测量记为 \tilde{v} ; 与节点电压相角对应的输入特征量测量记为 $\tilde{\theta}$ 。

2.2.4 集成 DNN 状态估计模型

集成 DNN 状态估计结构见图 3。该模型由多个基学习器 DNN 模型和一个元学习器 SVR 模型

构成, 通过将多个 DNN 的状态估计结果进行分析, 削弱单个基学习器状态估计泛化能力不足的影响, 有效地提高了状态估计的精度。

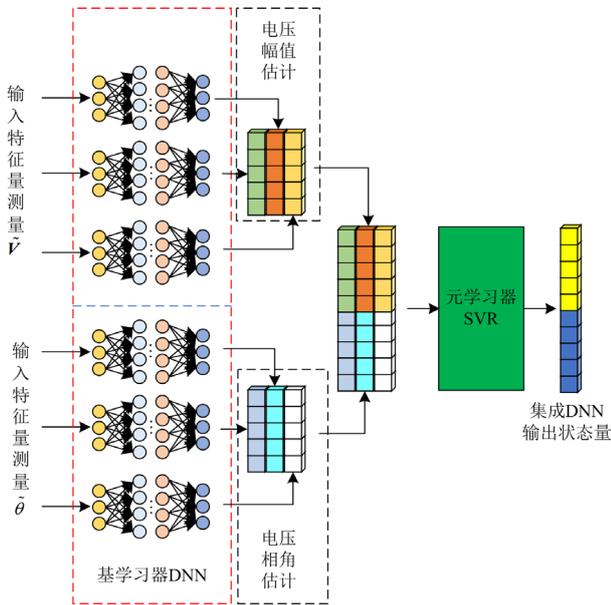


图 3 集成 DNN 状态估计结构

Fig. 3 Integrated DNN state estimation structure

1) 基学习器状态估计: 将经过 MRMR 算法筛选出的量测特征作为基学习器 DNN 输入, 分别对电压幅值和电压相角进行多组状态估计;

2) 集成基学习器的状态估计数据集: 相同类型状态量的估计值进行横向集成, 不同类型状态量的估计值进行纵向集成;

3) 集成 DNN 状态估计: 将集成后的数据集当作元学习器 SVR 模型的输入, SVR 模型的输出为最终状态估计结果。

3 分布式集成 DNN 状态估计

随着配电网规模的扩大, 控制中心需要收集大量的测量信息, 然而传统的集中式状态估计算法由于通信负担重、计算量大等问题影响状态估计的效率。为解决上述问题, 本文提出分布式集成 DNN 状态估计, 该模型由多个集成 DNN 状态估计模型组成, 同时对系统的各个子区域进行状态估计, 并将输出结果提供至 DMS 数据中心, 以提高状态估计的效率, 其结构见图 4。

本文提出的分布式集成 DNN 状态估计具体流程见图 5, 该方法分为离线训练和在线状态估计两个阶段。

1) 离线训练阶段: 首先将系统的历史数据集分为

各个子区域的数据集, 对各子区域: 将经过 MRMR 提取的特征量测量作为 DNN 的输入, 状态量作为 DNN 的输出, 进行基学习器的训练; 然后将基学习器输出的预测值集成后作为 SVR 模型输入, 状态量作为 SVR 模型的输出, 进行元学习器的训练, 训练完成后保存所有模型权重参数。

2) 在线状态估计阶段: 将实时量测数据经过不良数据的辨识与修正, 得到修正后的量测数据; 将修正后的量测数据中的特征量测量输入到各个子区域的集成 DNN 模型中进行状态估计, 待各子区域均完成状态估计且满足系统的潮流约束条件时, 输出状态估计结果。对不满足系统潮流约束条件的状态量, 采用传统 WLS 估计输出结果。

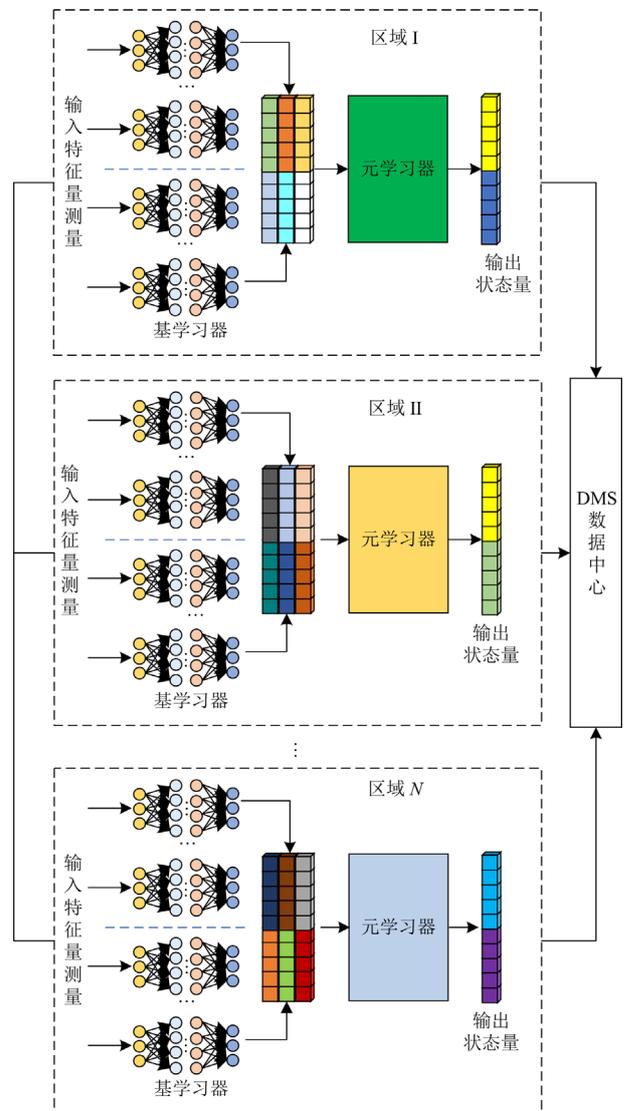


图 4 分布式集成 DNN 状态估计结构

Fig. 4 Distributed integrated DNN state estimation structure

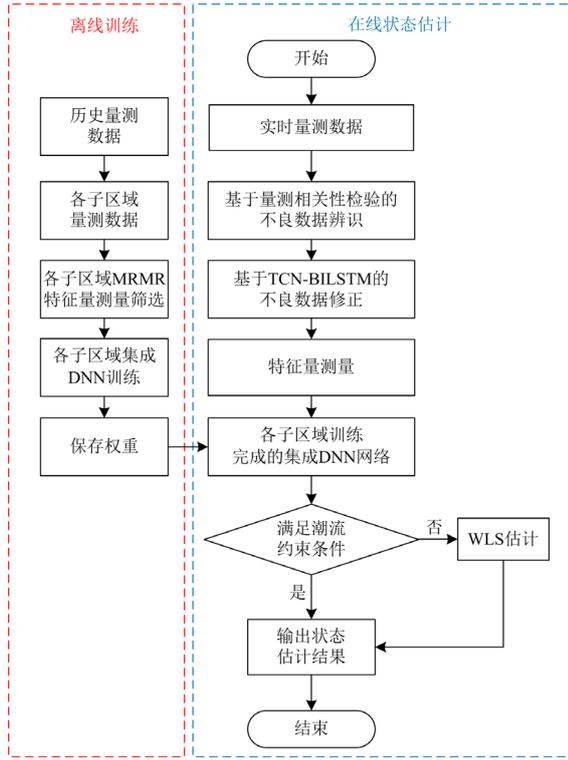


图5 分布式集成DNN状态估计流程图

Fig. 5 Flow chart of distributed integrated DNN state estimation

4 算例分析

本文测试环境的硬件基于PC机, CPU为Intel® Core™ i9-13900HX, 16 G内存, GPU显存为8 G; 软件基于Matlab 2021b和Python 3.7.4。

4.1 数据预处理与评价指标

本文为消除量测数据量纲的差异, 进行数据归一化, 如式(21)所示。

$$x_n = \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} \quad (21)$$

式中: x_n 为归一化的值; x_i 为输入值; x_{\max} 、 x_{\min} 分别为数据中的最大、最小值。

采用查准率 η_p 、查全率 η_r 、准确率 η_a 衡量不良数据辨识精度, 计算公式分别为

$$\eta_p = \frac{T_N}{T_N + F_N} \quad (22)$$

$$\eta_r = \frac{T_N}{T_N + F_P} \quad (23)$$

$$\eta_a = \frac{T_P + T_N}{T_P + F_P + F_N + T_N} \quad (24)$$

式中: T_N 为模型正确辨识为不良数据的样本数量; T_P 为模型正确辨识为正常数据的样本数量; F_N 为

模型错误地将正常数据辨识为不良数据的样本数量; F_P 为模型错误地将不良数据辨识为正常数据的样本数量。

采用决定系数 R^2 、平均百分比误差(mean absolute percent error, MAPE)、均方根误差(root mean square error, RMSE)、平均相对误差 η_b 和平均绝对误差 η_c 来评估各个模型的预测精度, 分别如式(25)~式(29)所示。

$$R^2 = 1 - \frac{\sum_{t=1}^M (y_t - \hat{y}_t)^2}{\sum_{t=1}^M (y_t - \bar{y})^2} \quad (25)$$

$$R_{\text{MSE}} = \sqrt{\frac{1}{M} \sum_{t=1}^M (y_t - \hat{y}_t)^2} \quad (26)$$

$$M_{\text{APE}} = \frac{1}{M} \left(\sum_{t=1}^M \left| \frac{y_t - \hat{y}_t}{y_t} \right| \right) \quad (27)$$

$$\eta_b = \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (28)$$

$$\eta_c = \frac{1}{M} \sum_{t=1}^M |y_t - \hat{y}_t| \quad (29)$$

式中: y_t 、 \hat{y}_t 分别为 t 时刻状态量的真实值和预测值; \bar{y} 为状态量的平均值; M 为测试样本数目。

4.2 IEEE123 配电网分析

为验证本文提出的集成DNN分布式状态估计模型在实际配电网中的估计效果, 本文针对修改的IEEE123节点配电网进行仿真测试, 系统的电压基准为4.16 kV; 负荷参数采用新疆某地实际配电网负荷数据; 风力发电机组数据为新疆某地风电厂实际运行数据, 其装机容量均为120 MW; 线路参数参考文献[32]; 电压幅值、电流幅值量测的标准差为0.005, 功率量测误差标准差为0.02。部分节点装设PMU装置, 其余节点均装设SCADA装置, 具体的系统结构及区域划分见图6。

4.2.1 不良数据辨识效果分析

本节采用基于量测数据相关性检验的不良数据辨识方法, 选取系统连续4000个断面量测数据, 在不同断面分别加入5%、15%的不良数据(各2000个连续断面), 不良数据的模拟方法为: 将正常功率量测增大或减小50%, 正常电压量测增大或减小20%。不良数据辨识性能对比: 取 $N=8$, 分别将含有5%、15%不良数据的连续断面中每100个连续断面为一组, 分别随机抽取10组取平均值, 将标准残差搜索法、FCM算法和本文方法对比, 不良数据辨识性能结果见表2。

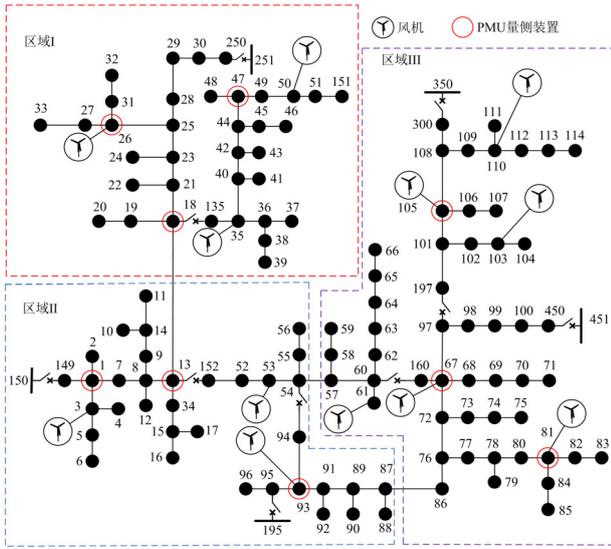


图 6 IEEE123 节点配电网

Fig. 6 IEEE123 node distribution network

表 2 不良数据辨识性能对比

Table 2 Comparison of bad data identification performance

| 不良数据比例/% | 方法 | 查全率/% | 查准率/% | 准确率/% |
|----------|--------|-------|-------|-------|
| 5 | 标准残差搜索 | 83.5 | 86.8 | 85.8 |
| | FCM | 87.2 | 89.6 | 91.5 |
| | 本文方法 | 99.3 | 96.9 | 98.6 |
| 15 | 标准残差搜索 | 71.6 | 75.2 | 73.8 |
| | FCM | 77.9 | 78.7 | 80.2 |
| | 本文方法 | 97.8 | 96.5 | 96.9 |

由表 2 可知, 在不良数据为 5% 时, 相较于标准残差搜索法和 FCM 算法, 本文方法的准确率提高了 14.9% 和 7.8%; 在不良数据为 15% 时, 相较于标准残差搜索法和 FCM 法, 本文方法查全率分别提高了 36.6% 和 25.5%, 查准率分别提高了 28.3% 和 22.6%。在两种比例的不良数据下, 本文所提方法的查全率、查准率和准确率都在 96% 以上, 均高于标准残差搜索法和 FCM 算法。结果表明, 当配电网存在较大比例不良数据时, 本文所提的方法能较准确地识别出不良数据。

4.2.2 TCN-BILSTM 预测效果分析

本节采用 BILSTM 模型、TCN 模型、TCN-LSTM 模型和 TCN-BILSTM 模型进行对比。模型的输入为 4.2.1 节中系统连续 4000 个断面量测数据, 其中 80% 为训练集, 20% 为测试集, 采用 M_{APE} 、 R_{MSE} 和 R^2 来评估各个模型的预测精度。实验测试 100 次取平均值, 不同方法测试结果见表 3。

由表 3 可知, 本文所提的 TCN-BILSTM 模型的 M_{APE} 和 R_{MSE} 较 BILSTM 模型、TCN 模型、TCN-

LSTM 模型分别降低了 74.6%、69.1%、53.1% 和 61.6%、53.6%、32.3%, 说明本文方法预测误差最小; TCN-BILSTM 模型的 R^2 最大, 说明了本文方法的拟合度最高。对比分析表明本文所提 TCN-BILSTM 模型对于量测序列预测较为有效, 可以较准确地完成不良数据修正任务。

表 3 量测量预测误差指标

Table 3 Prediction error indicators of measurement

| 预测模型 | M_{APE} | R_{MSE} | R^2 |
|------------|-----------|-----------|-------|
| BILSTM | 1.008 | 0.852 | 0.871 |
| TCN | 0.829 | 0.705 | 0.892 |
| TCN-LSTM | 0.546 | 0.483 | 0.933 |
| TCN-BILSTM | 0.256 | 0.327 | 0.989 |

4.2.3 状态估计效果分析

集成 DNN 分布式状态估计模型数据集为 IEEE123 节点系统区域 I、II、III 中每个区域连续 1500 h 的实际运行数据, 以 10 min 为 1 个样本断面, 共计 9000 个断面, 其中 80% (共计 7200 个断面) 作为训练集, 20% (共计 1800 个断面) 作为测试集。区域 I、II、III 的节点数量分别为 36、35、52, 输出状态量分别为该区域所有节点的电压幅值和相角参数, 经 MRMR 算法筛选出的特征量测量参考附录 A。各区域 DNN 参数如表 4 所示, 包括各区域 DNN 数量、DNN 层数以及每层神经元数。在模型训练的过程中, 采用动量梯度下降法进行优化, 将初始学习率设置为 0.01, batchsize 设置为 32, epoch 设置为 100, dropout 设置为 0.3。不同参数对集成 DNN 模型的影响和参数搜索范围与寻优过程参见附录 B。

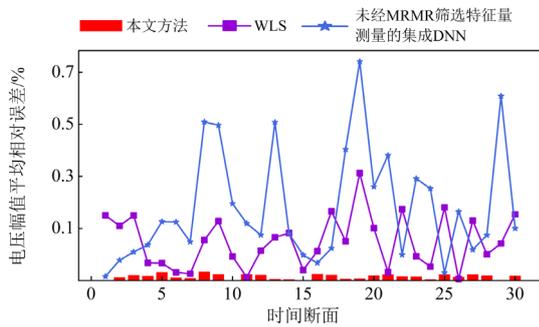
表 4 各区域深度神经网络参数

Table 4 Deep neural network parameters for each region

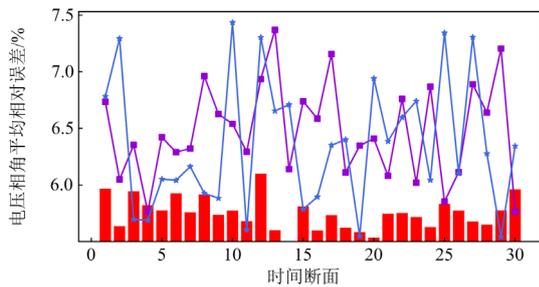
| 区域 | 估计类型 | DNN 层数 | 每层神经元数 | DNN 数量 |
|-----|------|--------|---------------|--------|
| I | 电压幅值 | 3 | 128/32/16 | 4 |
| | 电压相角 | 3 | 128/64/16 | 4 |
| II | 电压幅值 | 3 | 128/64/16 | 4 |
| | 电压相角 | 3 | 128/64/32 | 4 |
| III | 电压幅值 | 4 | 256/64/32/16 | 4 |
| | 电压相角 | 4 | 256/128/64/16 | 4 |

选取区域 I 中 26 号节点、区域 II 中 53 号节点、区域 III 中 67 号节点, 测试经过 MRMR 筛选特征量测量的集成 DNN 分布式状态估计、未经过 MRMR 筛选特征量测量的集成 DNN 分布式状态估计与 WLS 状态估计的效果。为直观分析结果, 采用平均相对误差作为衡量不同算法状态估计精度指标。对上述 3 个节点随机选取 30 个连续时间断面进行测试, 测试结果见图 7。

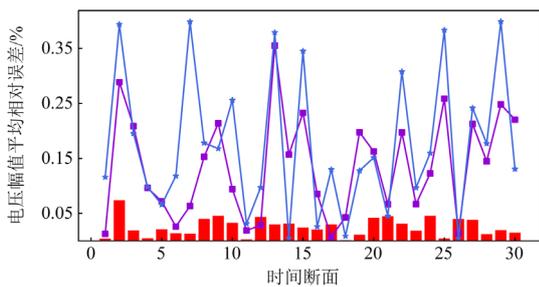
由图 7 可知：对于电压幅值的平均相对误差而言，经过 MRMR 筛选特征量测量后，集成 DNN 算法在 3 个区域下均低于 0.15%，WLS 算法和未经 MRMR 筛选特征量测量的集成 DNN 算法最大值分别大于 0.35%和 0.7%；对于电压相角的相对误差而言，经过 MRMR 筛选特征量测量后，集成 DNN 算法在 3 个区域下均低于 6.5%，WLS 算法和未经 MRMR 筛选的集成 DNN 算法最大值分别大于 7%和 8%。结果表明，经过 MRMR 算法对特征量测量的筛选，保证了输入至集成 DNN 的量测量与状态量最大相关，同时量测量之间冗余性最小，从而使集成 DNN 算法能更精确地进行状态估计。



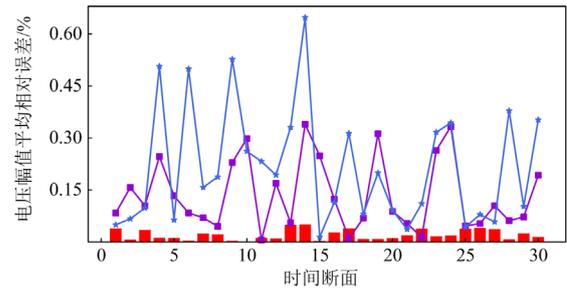
(a) 区域I 26号节点状态估计相对误差



(b) 区域II 53号节点状态估计相对误差



(c) 区域III 67号节点状态估计相对误差



(a) 区域I 29号节点状态估计精度对比

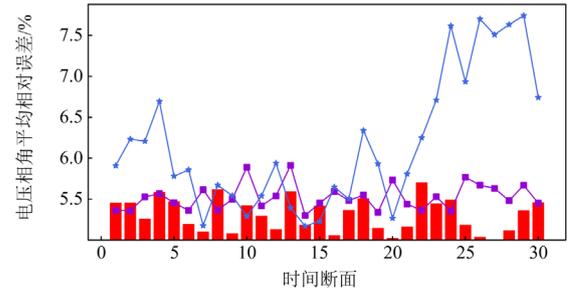
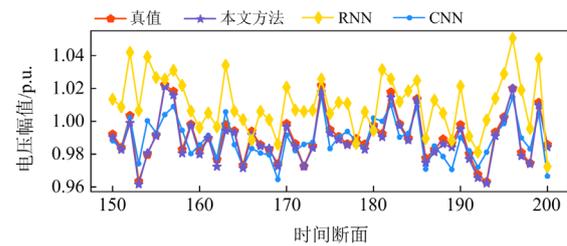


图 7 集成 DNN 分布式状态估计分析

Fig. 7 Integrated DNN distributed state estimation analysis

4.2.4 状态估计精度分析

本节利用 4.2.3 节中量测数据集，将集成 DNN 分布式状态估计与传统集中式的 RNN 和 CNN 状态估计精度进行对比分析，随机选取区域 I 中 29 号节点、区域 II 中的 93 号节点、区域 III 中 105 号节点的电压幅值和相角进行测试，其数据截面 150—200 的状态估计结果见图 8。由图 8 可知，对电压幅值的估计而言，RNN 和 CNN 状态估计效果相当，但与集成 DNN 相比较差；对电压相角的估计而言，集成 DNN 效果最好，CNN 次之，RNN 效果最差。结果表明，本文提出的集成 DNN 分布式状态估计将多组 DNN 估计结果进行集成学习，较 RNN 和 CNN



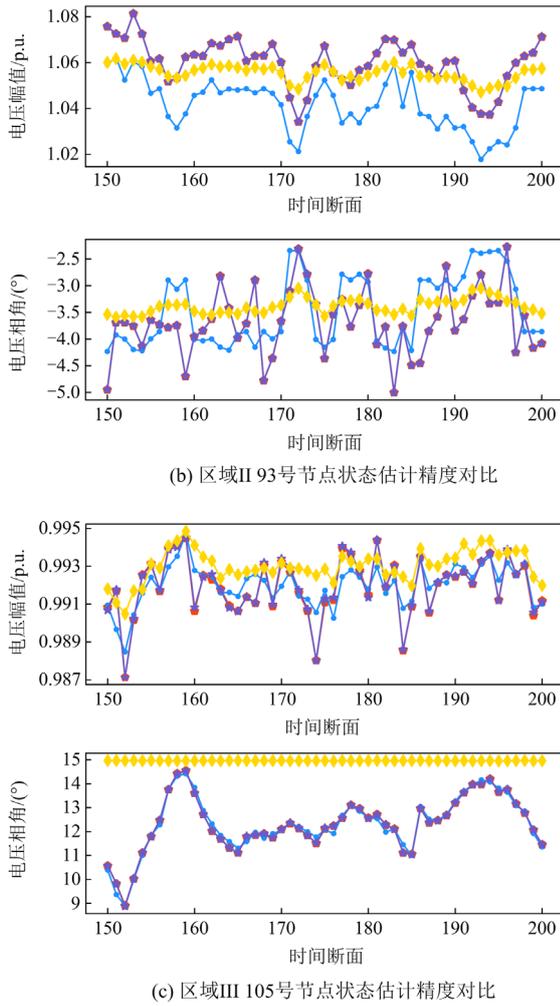


图 8 不同模型估计效果

Fig. 8 Estimation effects of different models

具有较高的泛化能力, 更加满足配电管理系统对状态估计高精度的要求。

4.2.5 状态估计鲁棒性分析

在实际配电网运行中难免会有不良数据的出现, 在鲁棒性测试过程中, 将 4.2.3 节中测试集的 1800 个断面注入 10% 的不良数据, 把集成 DNN 分布式状态估计与传统集中式的 DNN 和基于物理模型的 WLS、WLAV 估计进行测试。为了方便定量分析, 采用平均绝对误差衡量不同算法的精度。对电压幅值 V 、电压相角 θ , 不同方法的状态估计测试结果见表 5。

由表 5 可知, 与集中式的 DNN、WLS、WLAV 估计相比, 本文方法在在区域 I 中, 电压幅值平均绝对误差分别降低了 88.1%、80.4%、78.8%; 在区域 II 和 III 中, 电压相角平均绝对误差分别降低了 64.5%、61.6%、59.4%和 70.1%、73.8%、71.9%。结果表明, 本文所提的分布式集成 DNN 状态估计在存在不良

数据的情况下, 相比传统集中式 DNN、WLS、WLAV 估计, 具有更强的鲁棒性, 更能满足配电网的安全运行需求。

表 5 不同模型鲁棒性测试

Table 5 Robustness testing of different models

| 算法 | 平均绝对误差 | 区域 I | 区域 II | 区域 III |
|----------|--------------------------------------|-------|-------|--------|
| 集中式 WLS | $V(\times 10^{-4})/\text{p.u.}$ | 18.69 | 22.35 | 20.18 |
| | $\theta(\times 10^{-3})/(\text{°})$ | 22.86 | 21.93 | 27.76 |
| 集中式 WLAV | $V(\times 10^{-4})/\text{p.u.}$ | 17.32 | 23.64 | 22.33 |
| | $\theta(\times 10^{-3})/(\text{°})$ | 23.51 | 20.75 | 25.83 |
| 集中式 DNN | $\theta(\times 10^{-4})/\text{p.u.}$ | 30.82 | 20.92 | 21.15 |
| | $\theta(\times 10^{-3})/(\text{°})$ | 31.56 | 23.73 | 24.28 |
| 本文算法 | $V(\times 10^{-4})/\text{p.u.}$ | 3.67 | 6.23 | 5.68 |
| | $\theta(\times 10^{-3})/(\text{°})$ | 5.38 | 8.43 | 7.26 |

4.3 状态估计效率分析

为满足 DMS 稳定运行, 状态估计需要可靠地提供实时估计结果, 需分析不同估计模型的计算复杂度。不同模型在各测试系统某一时间断面的状态估计耗时结果见表 6。

表 6 不同模型估计耗时

Table 6 Estimated time for different models

| 测试系统 | 某一断面估计时间/s | | |
|---------|------------|----------|--------|
| | 集中式 WLS | 集中式 WLAV | 本文方法 |
| IEEE33 | 0.0026 | 0.0073 | 0.0008 |
| IEEE119 | 0.0219 | 0.0384 | 0.0023 |
| IEEE123 | 0.0395 | 0.0556 | 0.0029 |

由表 6 可知, 随着系统规模的增大, 传统的集中式 WLS、WLAV 估计计算复杂度随之上升, 导致状态估计用时增加幅度陡升, 很难满足状态估计实时性的需求。本文提出的基于集成深度学习的分布式状态估计方法, 将状态估计任务分配到各个子区域, 并利用 GPU 并行加速计算, 从而大大降低了状态估计的计算复杂度, 满足 DMS 对状态数据的实时性需求。在 IEEE123 节点测试系统中, 本文方法相比于传统集中式的 WLS 和 WLAV 估计, 计算效率分别提升了 12.6 倍和 18.2 倍。

5 结论

针对配电网状态估计存在的分布式电源波动数据误判、状态估计的精度和效率不高的问题, 本文提出一种基于集成 DNN 分布式状态估计方法。主要结论如下。

1) 提出量测量相关性检验的不良数据辨识技术和基于 TCN-BILSTM 的量测数据修正技术, 相较于传统的不良数据辨识法, 本文方法在不良数据辨识方面有更高的查全率、查准率和准确率; 在量测

量预测方面,相比于 BILSTM 等方法,本文方法有更高的预测精度,能够更准确地修正不良数据,保证量测数据的可靠性。

2) 提出集成 DNN 分布式状态估计方法,对不同基学习器进行组合,增强模型的泛化能力,并利用 MRMR 筛选量测特征,对比传统的集中式 RNN、CNN 算法,提高了状态估计的精度。

3) 对比传统的集中式 WLS、WLAV 估计,集成 DNN 分布式状态估计提高了系统的鲁棒性,并且利用多子区域并行计算,在计算效率上有明显优势。

附录 A

以区域 I 为例,特征量测量 \tilde{V} 、 $\tilde{\theta}$ 见表 A1,其中 P_i 和 Q_i 为节点注入功率量测量; P_{i-j} 和 Q_{i-j} 为支路功率量测量。

表 A1 区域 I 输入特征量测量

Table A1 Region I input feature measurement

| 区域 | \tilde{V} | $\tilde{\theta}$ |
|----|---|---|
| I | $P_{21}, P_{22}, P_{25}, P_{28}, P_{35},$ | $P_{18}, P_{21}, P_{24}, P_{25}, P_{26},$ |
| | $P_{44}, P_{47}, P_{50}, P_{18-19}, P_{19-20},$ | $P_{28}, P_{29}, P_{32}, P_{35},$ |
| | $P_{26-31}, P_{27-26}, P_{29-30}, P_{35-36},$ | $P_{40}, P_{42}, P_{44}, P_{45}, P_{47},$ |
| | $P_{40-41}, P_{42-43}, P_{44-45}, P_{50-51},$ | $P_{21-22}, P_{27-26}, P_{29-30}, P_{32-31},$ |
| | $Q_{20}, Q_{21}, Q_{24}, Q_{25}, Q_{27},$ | $P_{35-36}, P_{38-39}, P_{42-43}, P_{45-46},$ |
| | $Q_{28}, Q_{29}, Q_{35}, Q_{36}, Q_{38},$ | $P_{49-50}, Q_{18}, Q_{21}, Q_{22}, Q_{25},$ |
| | $Q_{42}, Q_{47}, Q_{50}, Q_{19-20},$ | $Q_{29}, Q_{33}, Q_{37}, Q_{45}, Q_{47},$ |
| | $Q_{22-21}, Q_{24-23}, Q_{32-31},$ | $Q_{51}, Q_{22-21}, Q_{24-23}, Q_{28-25},$ |
| | $Q_{33-27}, Q_{38-39}, Q_{40-42},$ | $Q_{29-30}, Q_{38-39}, Q_{42-43}, Q_{44-45},$ |
| | $Q_{44-47}, Q_{47-48}, Q_{49-50}$ | Q_{44-47}, Q_{47-48} |

附录 B

本文采用网格搜索法确定模型最优参数,观测指标设置为模型状态估计耗时和平均绝对误差。在集成 DNN 训练过程中,考虑到 batch_size 过大将导致收敛速度减慢,过小将导致模型难以收敛;初始学习率过大将引起梯度爆炸而使训练不稳定,过小会导致训练过程缓慢;dropout 过大将增加模型在训练集上的误差,过小将无法发挥正则化作用,导致模型泛化能力差;DNN 总数量、每个 DNN 的层数、各层神经元的数量过多将降低计算效率,过少将导致模型欠拟合,搜索范围设置: batch_size 为[16, 32, 64, 128, 256]; epoch 为[50, 100, 150, 200];初始学习率为[0.001, 0.01, 0.1]; dropout 为[0.2, 0.3, 0.4, 0.5, 0.6]; DNN 层数搜索范围为[1, 2, 3, 4, 5];每层神经元数为[4, 8, 16, 32, 64, 128, 256]; DNN 总数为[1, 2, 3, 4, 5, 6]。以确定 IEEE123 节点系统区域 I 中电压相角估计模型的 DNN 层数和每层神经元的数量、DNN 总数为例,过程如下:

1) 确定 DNN 层数,如表 B1 所示。当 DNN 层数为 3 时,状态估计平均绝对误差最小,状态估计耗时满足系统需求。

表 B1 DNN 层数寻优结果

Table B1 Optimization result of DNN layer number

| DNN 层数 | 估计耗时/s | 平均绝对误差/(°) |
|--------|-----------------------|------------------------|
| 1 | 1.65×10^{-2} | 20.86×10^{-3} |
| 2 | 2.28×10^{-2} | 10.63×10^{-3} |
| 3 | 3.15×10^{-2} | 5.16×10^{-3} |
| 4 | 4.29×10^{-2} | 15.57×10^{-3} |
| 5 | 5.07×10^{-2} | 21.79×10^{-3} |

2) 确定每层神经元数,如表 B2 所示。当 DNN 每层神经元数为[128, 64, 16]时,状态估计平均绝对误差最小,状态估计耗时满足系统需求。

表 B2 神经元数寻优结果

Table B2 Optimization results of neuron number

| 第 1 层 | 第 2 层 | 第 3 层 | 估计耗时/s | 平均绝对误差/(°) |
|-------|-------|-------|-----------------------|-----------------------|
| 32 | 16 | 4 | 1.27×10^{-2} | 7.66×10^{-3} |
| 32 | 16 | 8 | 1.63×10^{-2} | 7.08×10^{-3} |
| 64 | 32 | 8 | 1.95×10^{-2} | 6.45×10^{-3} |
| 64 | 32 | 16 | 2.58×10^{-2} | 5.73×10^{-3} |
| 128 | 64 | 16 | 3.15×10^{-2} | 5.16×10^{-3} |
| 128 | 64 | 32 | 3.41×10^{-2} | 5.90×10^{-3} |
| 256 | 128 | 32 | 3.79×10^{-2} | 6.35×10^{-3} |
| 256 | 128 | 64 | 3.86×10^{-2} | 6.87×10^{-3} |

3) 确定 DNN 数量,如表 B3 所示。当 DNN 数量为 4 时,状态估计平均绝对误差最小,状态估计耗时满足系统需求。

表 B3 DNN 数量寻优结果

Table B3 Optimization results of DNN number

| DNN 个数 | 估计耗时/s | 平均绝对误差/(°) |
|--------|-----------------------|-----------------------|
| 1 | 1.57×10^{-2} | 8.76×10^{-3} |
| 2 | 1.89×10^{-2} | 7.58×10^{-3} |
| 3 | 2.33×10^{-2} | 6.35×10^{-3} |
| 4 | 3.15×10^{-2} | 5.16×10^{-3} |
| 5 | 4.81×10^{-2} | 8.27×10^{-3} |
| 6 | 6.03×10^{-2} | 9.13×10^{-3} |

参考文献

[1] 田钧祥,陈铁,陈彬. 基于改进自适应 UKF 算法的中压配电网鲁棒动态状态估计方法[J]. 中国电力, 2023, 56(11): 128-133.
TIAN Junxiang, CHEN Tie, CHEN Bin. Robust dynamic state estimation method for medium voltage distribution networks based on improved adaptive UKF algorithm[J]. Electric Power, 2023, 56(11): 128-133.

[2] 黄崇鑫,洪明磊,伏帅,等. 考虑虚假数据注入攻击的

- 有源配电网分布式状态估计[J]. 电力工程技术, 2022, 41(3): 22-31.
- HUANG Chongxin, HONG Minglei, FU Shuai, et al. Distributed state estimation of active distribution network considering false data injection attack[J]. Electric Power Engineering Technology, 2022, 41(3): 22-31.
- [3] 张新鹤, 刘铠诚, 梁琛, 等. 基于节点度搜索分区的配电网状态估计方法[J]. 电力科学与技术学报, 2023, 38(3): 149-156.
- ZHANG Xinhe, LIU Kaicheng, LIANG Chen, et al. State estimation method for distribution networks based on node degree search partitioning[J]. Journal of Electric Power Science and Technology, 2023, 38(3): 149-156.
- [4] 杜翔. 配电网状态估计研究综述[J]. 电工材料, 2022(2): 27-30.
- DU Xiang. A review on distribution system state estimation[J]. Electrical Engineering Materials, 2022(2): 27-30.
- [5] 王杰, 王维庆, 王海云, 等. 考虑越限风险的主动配电网中 DG、SOP 与 ESS 的两阶段协调规划[J]. 电力系统保护与控制, 2022, 50(24): 71-82.
- WANG Jie, WANG Weiqing, WANG Haiyun, et al. Two-stage coordinated planning of DG, SOP and ESS in an active distribution network considering violation risk[J]. Power System Protection and Control, 2022, 50(24): 71-82.
- [6] 季玉琦, 王涛, 史少彧, 等. 含分布式电源的配电网功率优化模式影响因素分析[J]. 电力科学与技术学报, 2023, 38(1): 97-107.
- JI Yuqi, WANG Tao, SHI Shaoyu, et al. Analysis of influencing factors of power optimization modes in distribution network containing distributed generations[J]. Journal of Electric Power Science and Technology, 2023, 38(1): 97-107.
- [7] 杨晓辉, 杨爽, 徐正宏, 等. 计及灵活配电单元的分布式电源优化配置方法[J]. 电力工程技术, 2023, 42(1): 19-25.
- YANG Xiaohui, YANG Shuang, XU Zhenghong, et al. Optimal configuration method of distributed generation considering flexible distribution unit[J]. Electric Power Engineering Technology, 2023, 42(1): 19-25.
- [8] 袁兆祥, 肖智宏, 王晶, 等. 考虑多时刻和压缩候选集合的配电网最小化采集优化方法[J]. 中国电力, 2023, 56(12): 20-30.
- YUAN Zhaoxiang, XIAO Zhihong, WANG Jing, et al. A minimized data collection optimization method for distribution networks considering multiple-time and compressed candidate sets[J]. Electric Power, 2023, 56(12): 20-30.
- [9] KOGLIN H J, NEISIUS T H, SCHMITT K D, et al. Bad data detection and identification[J]. International Journal of Electrical Power & Energy Systems, 1990, 12(2): 94-103.
- [10] 魏强, 王凯, 韩学山. 不良数据识别发生误判和漏判时的处理[J]. 东北电力大学学报, 2003, 23(1): 34-38.
- WEI Qiang, WANG Kai, HAN Xueshan. A correction method for distributor when bad data identification mistake happens[J]. Journal of Northeast Electric Power University, 2003, 23(1): 34-38.
- [11] 刘广一, 于尔铿, 夏祖治. 量测系统误差方差的估计与修正[J]. 中国电机工程学报, 1990, 10(6): 31-39.
- LIU Guangyi, YU Erkeng, XIA Zuzhi. Estimation and update of measurement system error variance[J]. Proceedings of the CSEE, 1990, 10(6): 31-39.
- [12] 于尔铿. 电力系统状态估计中不良数据的零残差辨识法[J]. 电网技术, 1981, 5(2): 66-73.
- [13] 李碧君, 薛禹胜, 顾锦汶, 等. 电力系统状态估计问题的研究现状和展望[J]. 电力系统自动化, 1998, 22(11): 53-60.
- LI Bijun, XUE Yusheng, GU Jinwen, et al. Status QUO and prospect of power system state estimation[J]. Automation of Electric Power Systems, 1998, 22(11): 53-60.
- [14] WEI H, SASAKI H, KUBOKAWA J, et al. An interior point method for power system weighted nonlinear L1 norm static state estimation[J]. IEEE Transactions on Power Systems, 1998, 13(2): 617-623.
- [15] ZHAO J, MILI L. A framework for robust hybrid state estimation with unknown measurement noise statistics[J]. IEEE Transactions on Industrial Informatics, 2018, 14(5): 1866-1875.
- [16] 付艳兰, 陈艳波, 姚锐, 等. 基于最大指数绝对值目标函数的抗差状态估计方法[J]. 电网技术, 2013, 37(11): 3166-3171.
- FU Yanlan, CHEN Yanbo, YAO Rui, et al. A robust state estimation approach based on objective function of maximum exponential absolute value[J]. Power System Technology, 2013, 37(11): 3166-3171.
- [17] SEIDU K, MUKAI H. Parallel multi-area state estimation[J]. IEEE Power Engineering Review, 1985, 5(5): 31-32.
- [18] 张海波, 易文飞. 基于异步迭代模式的电力系统分布式状态估计方法[J]. 电力系统自动化, 2014, 38(9): 125-131.
- ZHANG Haibo, YI Wenfei. Distributed state estimation method for power systems based on asynchronous iteration mode[J]. Automation of Electric Power Systems, 2014, 38(9): 125-131.
- [19] WANG Yaojian, GU Jie, YUAN Lyuzerui. Distribution network state estimation based on attention-enhanced

- recurrent neural network pseudo-measurement modeling[J]. Protection and Control of Modern Power Systems, 2023, 8(2): 508-523.
- [20] 夏添梁, 张玉敏, 杨明, 等. 联合长短期记忆神经网络和粒子滤波的配电网预测辅助鲁棒状态估计方法[J]. 高电压技术, 2022, 48(4): 1343-1355.
XIA Tianliang, ZHANG Yumin, YANG Ming, et al. Robust forecasting-aided state estimation method of distribution network based on long-short term memory neural network and particle filter[J]. High Voltage Engineering, 2022, 48(4): 1343-1355.
- [21] 刘艺娴, 王玉彬, 杨强. 基于门控图神经网络的高容错配电网状态估计方法[J]. 综合智慧能源, 2023, 45(6): 1-8.
LIU Yixian, WANG Yubin, YANG Qiang. High fault-tolerant distribution network state estimation method based on gated graph neural network[J]. Integrated Intelligent Energy, 2023, 45(6): 1-8.
- [22] 葛俊, 童陆园, 耿俊成, 等. TCSC 暂态过程中晶闸管导通角特性的研究[J]. 电网技术, 2001, 25(7): 18-22.
GE Jun, TONG Luyuan, GENG Juncheng, et al. Research on thyristor conduction angle characteristics in transient process of TCSC[J]. Power System Technology, 2001, 25(7): 18-22.
- [23] 穆钢, 陈奇, 刘洪波, 等. 揭示电力系统运行数据中因果关系的逆信息熵因果推理方法[J]. 中国电机工程学报, 2022, 42(15): 5406-5417.
MU Gang, CHEN Qi, LIU Hongbo, et al. A reciprocal information entropy causal inference method for exploring the cause-effect relationship in power system operation data[J]. Proceedings of the CSEE, 2022, 42(15): 5406-5417.
- [24] DONG Shufeng, HE Guangyu, MEI Shengwei. A new method for bad data identification in power system[C]// Proceedings of the 2011 International Conference on Software Engineering and Multimedia Communication SEMC 2011 V3, 2011: 158-161.
- [25] 赵凌云, 刘友波, 沈晓东, 等. 基于 CEEMDAN 和改进时间卷积网络的短期风电功率预测模型[J]. 电力系统保护与控制, 2022, 50(1): 42-50.
ZHAO Lingyun, LIU Youbo, SHEN Xiaodong, et al. Short-term wind power prediction model based on CEEMDAN and an improved time convolutional network[J]. Power System Protection and Control, 2022, 50(1): 42-50.
- [26] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv preprint arXiv: 1803.01271, 2018.
- [27] 郎伟明, 麻向津, 周博文, 等. 基于 LSTM 和非参数核密度估计的风电功率概率区间预测[J]. 智慧电力, 2020, 48(2): 31-37, 103.
LANG Weiming, MA Xiangjin, ZHOU Bowen, et al. Wind power probabilistic intervals prediction based on LSTM and nonparametric kernel density estimation[J]. Smart Power, 2020, 48(2): 31-37, 103.
- [28] 赵化时, 李胜, 林子杰, 等. 电力系统低模型耦合智能状态估计[J]. 电力科学与技术学报, 2022, 37(2): 116-128.
ZHAO Huashi, LI Sheng, LIN Zijie, et al. Smart power system state estimation with low model coupling[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 116-128.
- [29] 龚逊东, 费有蝶, 凌佳凯, 等. 基于深度神经网络伪量测建模的交直流混合配电网交替迭代法状态估计[J]. 电力建设, 2022, 43(10): 111-120.
GONG Xundong, FEI Youdie, LING Jiakai, et al. Alternating-iteration state estimation of AC/DC hybrid distribution system based on pseudo-measurement modeling using deep neural network[J]. Electric Power Construction, 2022, 43(10): 111-120.
- [30] 朱城昊, 王晗, 孙国歧, 等. 一种并网逆变器直流电容容值辨识方法[J]. 上海交通大学学报, 2022, 56(6): 693-700.
ZHU Chenghao, WANG Han, SUN Guoqi, et al. An identification method for DC-link capacitor capacitance of grid connected inverter[J]. Journal of Shanghai Jiaotong University, 2022, 56(6): 693-700.
- [31] 胡威, 张新燕, 李振恩, 等. 基于优化的VMD-mRMR-LSTM 模型的短期负荷预测[J]. 电力系统保护与控制, 2022, 50(1): 88-97.
HU Wei, ZHANG Xinyan, LI Zhen'en, et al. Short-term load forecasting based on an optimized VMD-mRMR-LSTM model[J]. Power System Protection and Control, 2022, 50(1): 88-97.
- [32] AHMED H M A, ELTANTAWY A B, SALAMA M M A. A generalized approach to the load flow analysis of AC-DC hybrid distribution systems[J]. IEEE Transactions on Power Systems, 2018, 33(2): 2117-2127.

收稿日期: 2023-07-08; 修回日期: 2023-12-31

作者简介:

张汪洋(1999—), 男, 硕士研究生, 研究方向为电力系统状态估计; E-mail: 790720806@qq.com

樊艳芳(1971—), 女, 通信作者, 教授, 博士生导师, 研究方向为电力系统状态估计; E-mail: 410849062@qq.com

侯俊杰(1993—), 男, 博士, 讲师, 研究方向为电力系统状态估计。E-mail: 826686025@qq.com

(编辑 张颖)