

基于深度迁移学习的时变拓扑下电力系统状态估计

臧海祥, 郭镜玮, 黄蔓云, 卫志农, 孙国强, 俞文帅

(河海大学能源与电气学院, 江苏省南京市 211100)

摘要: 针对电力系统拓扑实时变化导致数据驱动状态估计器不可用的情况, 提出一种基于深度迁移学习的数据驱动状态估计方法。将原拓扑海量历史数据训练得到的模型作为基础模型, 当新拓扑实时量测数据更新时, 加载和保存基础模型中特征提取层的权重和参数, 只需要微调模型的全连接层, 即可获得适应于新拓扑的神经网络, 提高了数据驱动状态估计模型的自适应性和泛化性能。通过对IEEE标准系统和中国某实际省网的算例测试, 并将其估计结果与加权最小二乘法和加权最小绝对值法进行比较。结果表明, 在考虑拓扑时变性的情况下, 该算法与上述2种物理算法相比具有更优的估计性能和估计效率。

关键词: 状态估计; 拓扑变化; 机器学习; 深度迁移学习

0 引言

电力系统状态估计在电力系统规划和运行中具有重要的意义^[1-2], 可以为实时调度以及后续一系列电力系统高级应用和分析提供可靠的数据库^[3]。目前, 基于加权最小二乘 (weighted least square, WLS) 的状态估计已被广泛应用于实际电力系统中, WLS的估计结果具有方差最小且无偏的统计特性。在理想条件下, 该算法是最优的状态估计方法^[4]。由于电网结构、运行工况和现场环境等因素的影响, 量测系统中不可避免地存在一定比例的坏数据, 但WLS属于L2范数估计, 该方法会将残差放大, 当量测系统存在一定比例坏数据时, WLS易出现不收敛的情况^[5-6]。

针对上述问题, 人们将研究重心聚焦到抗差估计算法中, 其中最常见的是基于加权最小绝对值 (weighted least absolute value, WLAV) 状态估计^[7]。WLAV属于L1范数估计, 利用非二次估计准则的优势, 解决了因加权平方和导致残差放大的问题, 将估计精度控制在既定范围之内。该算法通常利用原对偶内点法进行求解。除此之外, 文献[8-9]提出的M估计通过降权措施, 在计算速度、收敛性以及鲁棒性上得到了进一步提升。文献[10]提出的指数型目标函数估计适用于任何概率分布形式的量测系统, 能够自动排除坏数据对估计性能的影响, 但是该

方法会使状态量陷入局部最优。

然而, 上述传统状态估计算法受系统规模和硬件水平影响较大, 尤其在大系统中估计时间较长, 不满足状态估计实时性的要求^[11-12]。针对该问题, 文献[13]采用粒子群算法优化极限学习机方法对锂电池荷电状态进行估算, 提高了荷电状态估算的精度和效率。文献[14]采用神经网络进行大电网状态估计, 提高了状态估计的鲁棒性和实时性。文献[15]将脉冲神经网络应用于配电网状态估计的伪量测建模。但是在实际电网运行过程中, 系统拓扑是时变的^[16], 而且历史数据库中难以包含所有拓扑的海量数据。因此, 经常出现拟合的情况, 从而导致状态估计结果不准确^[17-18]。鉴于此, 可以利用原拓扑下海量的历史数据来弥补新拓扑样本少的问题^[19]。

迁移学习 (transfer learning, TL) 作为联系2个不同域之间的重要方法, 其核心是通过源域海量的数据学习相关知识并将其迁移到目标域以改善目标任务的学习性能^[20-21]。利用迁移学习可有效挖掘2种域之间的潜在联系以及提高数据驱动状态估计模型的泛化性能。同时, 离线阶段中仅需要对模型全连接层微调, 使离线训练效率也有明显提升。

本文基于深度迁移学习提出一种针对拓扑时变情况的状态估计方法。该方法分为离线训练和在线应用2个阶段。对于离线训练阶段, 首先, 合理选择一种拓扑作为基准拓扑 (源域); 其次, 利用源域历史量测和状态量作为预训练模型的输入和输出并进行离线训练; 最后, 以预训练模型为基础, 通过历史数据库中少量新拓扑的样本进行模型微调。对于在线

收稿日期: 2021-05-24; 修回日期: 2021-07-04。

上网日期: 2021-08-25。

国家重点研发计划资助项目 (2018YFB0904500)。

应用阶段,首先,采集新拓扑下当前断面的量测生数据;其次,将该数据输入离线训练阶段得到的模型;最后,获取该断面最接近系统真实状态的估计值。通过在 IEEE 标准系统和某实际省网进行的试验表明,本文方法较传统的 WLS 和 WLAV 以及深度神经网络 (deep neural network, DNN) 进行小样本训练有 2 个方面的优势:①该方法的估计性能优于对比方法;②估计时间小于 WLS 和 WLAV。

1 深度迁移学习算法基本原理

1.1 深度学习基本原理

深度学习核心功能是根据输入的数据进行分类或者回归^[22]。与浅层学习相比,深度学习组合若干低层次特征,从而挖掘高维数据的分布形式,这种组合方式可以让深度学习更好地适应较为复杂的函数表达^[23]。与传统机器学习算法相比,深度学习最大的特点是端到端(end-to-end)的学习,在进行学习之前,无须进行特征提取等操作,可以通过深层次的神经网络模型自动从原始数据中提取有用的特征^[22]。将深度学习应用在电力系统中可以有效挖掘历史数据特征,并且可以弥补传统机器学习中存在的函数表达能力不足的缺陷^[23-24]。

1.2 迁移学习基本原理

迁移学习的核心是对一组数据集特征的深层挖掘,提取其相关知识并将其运用到其他未知且相似的领域中^[25]。迁移学习具有较强的自适应性,与其他机器学习相比,迁移学习有 3 点优势:①训练和测试数据可以服从不同分布;②无须大量带标签数据;③模型可以在不同任务之间迁移^[26]。

在迁移学习中,设下标 S 和 T 分别代表源任务和目标任务, D_S 和 D_T 分别为源域和目标域,利用特征向量空间 X 和概率分布函数 $P(X)$ 构成对应的领域,即^[25-26]:

$$\begin{cases} D_S = \{X_S, P(X_S)\} \\ D_T = \{X_T, P(X_T)\} \end{cases} \quad (1)$$

设 Y_S 和 Y_T 分别为源域和目标域的标签向量空间, f_S 和 f_T 分别为源域和目标域的映射函数,则源域和目标域内的任务 T_S 和 T_T 可分别描述为:

$$\begin{cases} T_S = \{Y_S, f_S\} \\ T_T = \{Y_T, f_T\} \end{cases} \quad (2)$$

假设源域与目标域的特征分布相同,但标签空间不同,则迁移学习的目标是使学习映射函数 $f_i: X_i \rightarrow X_S$ 在 D_T 上的期望误差最小,并满足 $X_i = X_S$ 、 $Y_i = Y_S$ 和 $P(Y_i | X_i) \neq P(Y_S | X_S)$ 。

本文在源域模型训练中使用卷积神经网络

(convolutional neural network, CNN), 利用网络的特征学习能力,进行 2 个领域的知识迁移。具体知识迁移流程示意图如附录 A 图 A1 所示。

2 基于迁移学习的状态估计

2.1 预训练模型

在一个系统主体结构不变的情况下,增加或减少某几条支路在数据的表现上依然有极大的相似性,因此,可以将原拓扑的数据迁移到新拓扑中。具体迁移过程如图 1 所示。

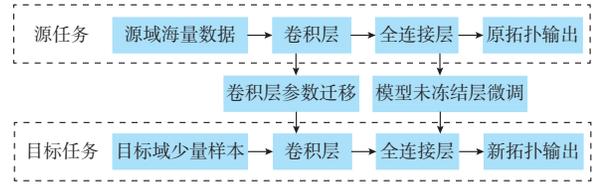


图 1 模型迁移过程
Fig. 1 Model migration process

本文预训练模型使用 CNN。其结构图如附录 A 图 A2 所示。CNN 包括卷积层、激活层和池化层^[27]。卷积层采用局部连接和权重共享的方式,使得卷积层与下一层的连接数显著减少。CNN 输出的结果是数据的特征向量,因此在最后一层池化层后要接入全连接层。

在前向传导阶段,第 l 层第 p 个的净输入(指没有经过非线性激活函数的净活性值) $z^{(l,p)}$ 为第 $l-1$ 层第 p 个活性值 $a^{(l-1,p)}$ 与卷积核 $\omega^{(l,p)} \in R^K$ 的卷积,即^[27]:

$$\begin{cases} z^{(l,p)} = \omega^{(l,p)} \times a^{(l-1,p)} + b^{(l,p)} \\ y^{(l,p)} = f(z^{(l,p)}) \end{cases} \quad (3)$$

式中:卷积核 $\omega^{(l,p)} \in R^K$ 为可学习的权重向量,其中 R^K 为 K 维实数向量空间; $b^{(l,p)}$ 为可学习的偏置; $y^{(l,p)}$ 为第 l 层第 p 个神经元激活后的输出; $f(\cdot)$ 为非线性激活函数,设 x 为来自上一层神经网络的输入向量,一般用 ReLU 函数表示,如式(4)所示。

$$f(x) = \max\{0, x\} \quad (4)$$

在反向传播过程中,首先,将实际结果与预期结果的误差按前向传播路径逐层返回,计算出每一层的误差。然后,进行权值更新。最后,得出满足要求的结果。

本文选用 CNN 作为基础拓扑数据的特征提取器,再将预训练模型卷积层冻结,保存和加载其权重和参数,利用历史数据库中新拓扑的少量样本微调模型未冻结部分得到新拓扑的神经网络。此方法既可以解决新拓扑下出现的小样本问题,也可以提高估计效率以及数据驱动状态估计模型的泛化能力。

2.2 模型训练与数据预处理

本文采用电压幅值和相角并行估计的方式进行模型离线训练。在源域中,通过分析数据的时序特性,利用原拓扑海量历史数据进行基础模型的预训练并将其作为特征提取器。在拓扑变化时,分析2种拓扑之间的潜在联系,在基础拓扑进行模型微调,最终得到新拓扑下的数据驱动状态估计模型。

通常,状态估计方法得到的估计结果是节点复电压。但从数据本身出发,节点相角是一个相对值,因此,利用数据驱动对节点电压相角进行状态估计时,会因数据之间缺少物理联系而导致估计精度不高,但对于潮流断面的计算,相角差的准确估计更有意义。为了能够体现数据之间的电气联系,并更好地体现出最终潮流计算的准确性,本文将支路相角差代替节点相角作为待估计量。这样可以加强数据之间的关联性,从而提高数据驱动状态估计的估计性能。具体转换公式为:

$$\varphi = (D^T D)^{-1} D^T \Delta\varphi \quad (5)$$

式中: φ 为节点电压相角估计向量; $\Delta\varphi$ 为支路相角差估计向量; D 为关联矩阵。

本文量测与状态变量之间的函数关系为:

$$\begin{cases} V_i = V_j \\ P_{ij} = V_i V_j (G_{ij} \cos \varphi_{ij} + B_{ij} \sin \varphi_{ij}) - k_{ij} G_{ij} V_i^2 \\ Q_{ij} = V_i V_j (G_{ij} \sin \varphi_{ij} - B_{ij} \cos \varphi_{ij}) - k_{ij} B_{ij} V_i^2 \end{cases} \quad (6)$$

式中: k_{ij} 为支路 ij 变压器非标准变比; φ_{ij} 为支路 ij 的相角差向量; G_{ij} 和 B_{ij} 分别为节点 i 至节点 j 导纳矩阵中的实部和虚部所形成的矩阵。

为了减少数据量纲对预训练网络的影响以及避免网络训练时出现过拟合现象,源域模型进行训练前将数据进行归一化处理。具体公式为:

$$x_i^* = \frac{x_i - \min x_i}{\max x_i - \min x_i} \quad (7)$$

式中: x_i^* 为第 i 个归一化后的估计值; x_i 为第 i 个原实际值。

为了使数据驱动状态估计模型适应实际系统的各种工况,提升其抗差性,本文在训练集中加入随机混合高斯误差,使数据驱动状态估计模型具有良好的鲁棒性。

2.3 算法流程

本文提出的基于深度迁移学习状态估计方法,能够有效挖掘和提取历史数据以及2种不同域之间的潜在关联。在离线训练阶段,首先,通过原拓扑的历史数据以及添加随机噪声训练基础神经网络;其次,利用少量新拓扑历史数据对基础网络进行微调。在线估计阶段,采集新拓扑的实时量测,输入新

拓扑模型即可获得当前断面的快速状态估计结果。具体流程图如图2所示。

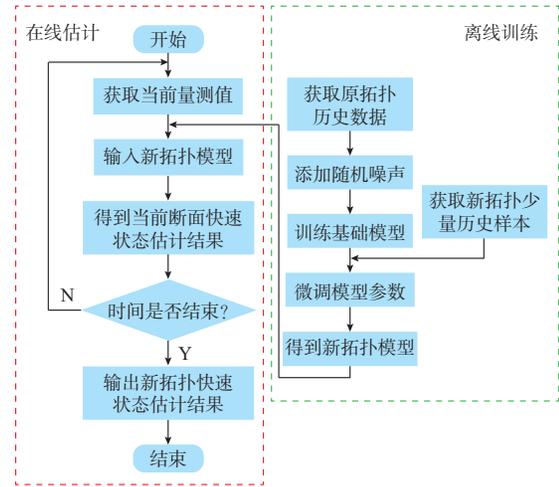


图2 深度迁移学习状态估计流程图
Fig.2 Flow chart of state estimation for deep transfer learning

3 算例测试分析

3.1 测试系统与模型调优

为验证本文方法的有效性,将所提方法在IEEE 118节点系统和某实际省级电网中进行试验。

在源域中,首先,利用省级电网实际运行数据得到负荷曲线,并得到原拓扑下的多断面量测。其次,利用WLAV进行多断面状态估计获取相应的状态量,将得到的量测与对应状态量按照训练集与测试集数量的比例为15:1的原则进行数据分配并进行网络训练。

在目标域中,假设拓扑变化后的数据量只有5个断面,那么可以在源域模型的基础上进行微调,从而得到适应于新拓扑下的状态估计模型。

本文算法基于Python中的Keras模块实现。模型调优主要包括网络层数和神经元个数等。模型迁移的调优主要包括冻结层个数。本文仅展示部分模型估计过程以及模型迁移估计结果。不同卷积层数和冻结层数的估计结果如表1和表2所示。

表1 不同卷积层数的估计结果
Table 1 Estimation results for different number of convolution layers

卷积层数	幅值绝对误差/ 10^{-4}	相角绝对误差/ 10^{-4}	微调时间/s	估计时间/ms
1	20.875	18.635	0.262 4	11.19
2	3.241	4.258	0.278 1	12.92
3	10.358	9.667	0.297 2	13.54
4	11.235	12.419	0.308 5	15.23

表2 不同冻结层数的估计结果
Table 2 Estimation results for different number of frozen layers

冻结层数	幅值绝对误差/ 10^{-4}	相角绝对误差/ 10^{-4}	微调时间/s	估计时间/ms
1	4.416	5.176	0.321	11.86
2	4.317	3.645	0.324	11.54
3	3.729	2.985	0.289	11.69
4	2.891	2.356	0.259	11.32
5	4.327	4.454	0.275	12.91

由表1和表2可以看出,CNN的层数为2,冻结层数为4,即冻结全部的卷积层,微调模型剩余的全连接层。此时的估计精度和估计效率达到最优。其余估计过程、整体基础模型参数以及各层含义见附录B。

3.2 IEEE 118节点系统测试

3.2.1 估计精度测试

本文在理想条件下测试该方法在IEEE 118节点系统的估计精度,其中,训练集和测试集的收敛曲线见附录B图B1和图B2。为了更好地表现出拓扑前后各个电气量的变化,本文利用支路1拓扑变化前后的首端有功功率和首端无功功率进行展示,具体如附录C图C1所示。

从附录C图C1可以看出,经过模型迁移后,本文方法在仅含高斯白噪声情况下能够准确估计系统状态。在经过一定的数据积累进行模型微调后,新拓扑模型依然适用。

为了能让各个算法之间的估计结果更直观地表现出来,对测试集数据进行状态估计计算并与真值进行比较得到最大绝对误差值。因为小样本直接训练的DNN估计精度与其他方法有数量级的差距,所以本文采用对数形式进行成果展示,状态估计的估计精度合格线 $\epsilon_{k,max}$ 在对数值为3的位置。其计算公式为:

$$\epsilon_{k,max} = \lg \left(\max_{u \in [1,T]} |\hat{x}_k(u) - x_k(u)| \times 10^5 \right) \quad (8)$$

式中: $\hat{x}_k(u)$ 为第 u 个断面中第 k 个状态估计结果; $x_k(u)$ 为第 u 个断面中第 k 个真实值; T 为总断面数。运用式(8)可求出5个断面全部状态量的最大绝对误差。

表3为不同算法下节点电压幅值、支路相角差、支路首端有功功率和支路首端无功功率的最大绝对误差的标么值。从表3可以看出,本文方法所得的支路相角差和节点电压幅值误差较WLS分别降低了48.17%和41.36%,与WLAV相比降低了52.71%和43.6%,其估计误差低于上述2种传统的物理模型驱动状态估计。而由小样本直接训练得到

的DNN估计精度明显达不到状态估计的精度要求。

表3 IEEE 118节点系统的状态估计误差对比
Table 3 Comparison of state estimation errors for IEEE118-bus system

算法名称	最大绝对值误差标么值			
	幅值/ 10^{-3}	相角/ 10^{-3}	首端支路有功功率/ 10^{-3}	首端支路无功功率/ 10^{-3}
WLS	3.610 2	3.824 8	3.524 8	3.654 2
WLAV	3.965 9	4.447 5	3.556 1	4.015 8
DNN	64.749 0	131.312 0	142.075 0	132.532 0
本文方法	1.875 3	2.241 6	1.025 6	1.336 8

3.2.2 鲁棒性测试

为了让该估计方法能更好地适应电力系统各种工况。本节在历史样本中随机选择部分量测添加混合高斯误差构成含噪声的训练样本,以此测试该算法的鲁棒性,添加的坏数据包括功率量测和电压幅值量测。

图3为不同方法在添加20%混合高斯误差后的支路首端功率误差。

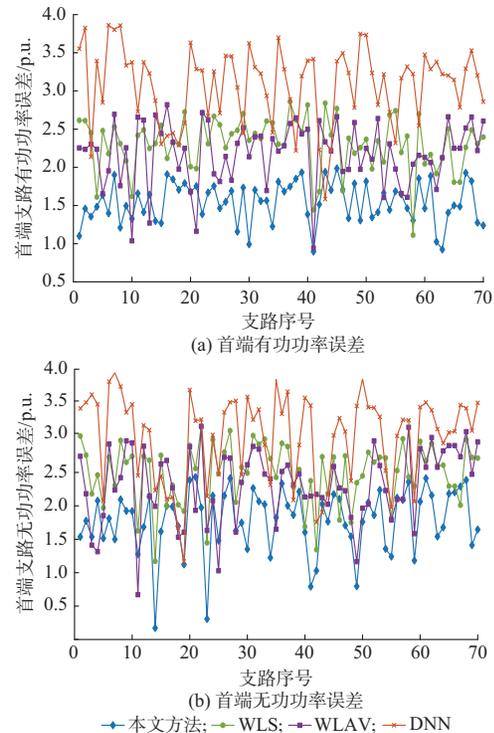


图3 IEEE 118节点系统含坏数据状态估计精度
Fig. 3 Accuracy of state estimation for IEEE 118-bus system with bad data

从图3可以看出,当量测系统存在不良数据时,本文方法计算出的支路潮流精度较其他方法有所提高,其中,由小样本直接训练得到的DNN估计精度

明显达不到状态估计既定要求。因此,本文方法与其他方法相比具有良好的抗差性。

3.3 某实际省网系统测试

3.3.1 实际电网估计精度测试

为了能进一步验证本文算法在实际电网中的估计性能,本文对实际电网运行数据进行试验。其基础拓扑的等效拓扑信息为1 389个节点和2 419条支路。本文输入的量测值包括节点电压幅值量测以及首末端支路功率量测,其量测冗余 $m = 3.67$ 。

为了能直观地表现出某一断面全网估计误差情况,图4为整个省级电网某一断面的节点电压幅值和支路相角差最大绝对误差区间分布图。

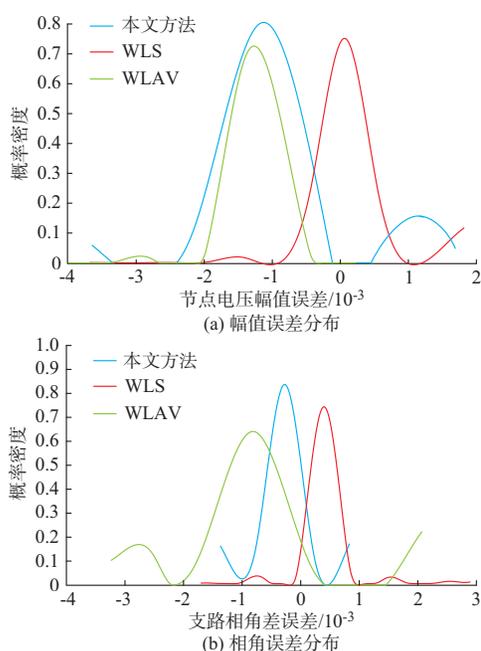


图4 实际省级电网状态估计误差分布图

Fig. 4 Error distribution curves of State estimation for actual provincial grid

从图4可以看出,在仅含高斯白噪声的情况下,本文方法的估计误差主要集中在 $(-10^{-3}, 10^{-3})$ 内,而WLS和WLAV误差基本在 $(-10^{-3}, 10^{-3})$ 及该区间外。DNN估计精度基本达不到状态估计要求,不予展示。因此,本文方法在实际电网中同样能有较传统方法更好的估计性能。

3.3.2 实际电网鲁棒性测试

本节在实际电网的量测数据中加入混合坏数据,测试本文方法在实际系统中的鲁棒性。

附录C图C2为该省级电网支路1的首端功率在本文方法、WLS、WLAV和DNN的估计结果与潮流真值进行比较得到的最大绝对误差。

从附录C图C2和表4可以看出,在添加混合坏数据情况下,本文提出的方法在绝大部分支路和节

表4 实际省级电网不同方法状态估计精度对比
Table 4 Comparison of state estimation accuracy of actual provincial grid in different methods

算法名称	最大绝对误差标幺值	
	幅值/ 10^{-3}	相角/ 10^{-3}
WLS	7.346 2	6.334 8
WLAV	5.167 6	5.867 1
DNN	677.540 0	386.910 0
本文方法	2.730 4	2.016 8

点的估计精度都比传统方法要高。节点电压幅值的最大绝对误差较WLS和WLAV分别提高了62.8%和41.2%;支路相角差的最大绝对误差较WLS和WLAV分别提高了68.6%和65.6%。因此,本文方法在实际系统中具有较好的鲁棒性。

为了能直观地看出实际电网拓扑变化前后各个电气量的变化,本文采用支路1首端功率进行结果展示。

图5为某省级电网在加入坏数据时拓扑变化前后的首端功率变化图。从图中可以看出,在系统中存在坏数据时,其支路功率的估计精度仍在既定的要求范围内。

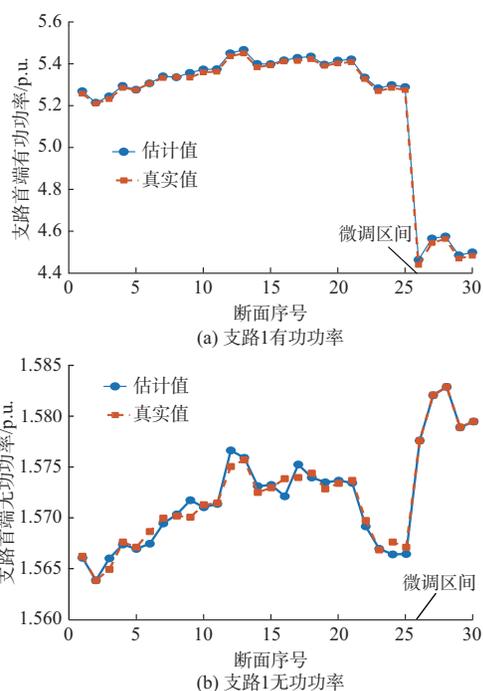


图5 实际省级电网拓扑变化前后的支路功率曲线
Fig. 5 Branch power curves before and after actual provincial grid topology changes

在量测数据中分别加入10%~70%的坏数据,状态估计精度见附录C图C3。

3.4 估计效率对比

传统状态估计算法的基本原理是基于雅可比矩

阵迭代来寻找最优解。该方法受系统规模影响较大,尤其是在大电网下,状态估计的计算效率明显下降。而数据驱动状态估计只有离线训练阶段受系统规模影响较大,在线应用阶段受系统规模影响较小。因此,本文提出的基于深度迁移学习的状态估计方法不仅能满足状态估计鲁棒性的要求,也可以满足其实时性的要求。

由表5可以看出,随着系统规模增大,传统的模型驱动状态估计算法所用时间受系统规模影响较为明显。尤其是在大系统下运行WLAV时,估计方法已经很难满足状态估计在线应用的实时性要求,但从不同规模的系统测试结果来看,本文算法的在线估计效率可以保持在一定范围内,基本不受系统规模影响。在某实际省级电网的算例仿真测试中,本文方法的计算效率较传统的WLS和WLAV分别提升了6.23%和71.05%。

表5 各种算法的状态估计效率
Table 5 Efficiency of state estimation for various algorithms

测试环境	某一断面估计时间/s		
	WLS	WLAV	本文方法
IEEE 14	0.001 8	0.003 4	0.012 5
IEEE 118	0.006 1	0.019 2	0.012 9
IEEE 2383	0.154 2	1.207 7	0.014 2
某省级电网 (断1条支路)	0.084 3	0.833 2	0.014 3
某省级电网 (断2条支路)	0.088 7	0.875 6	0.014 4
某省级电网 (断3条支路)	0.089 1	1.023 1	0.014 4

4 结语

面对拓扑时变导致数据驱动状态估计模型估计性能较差的缺陷,本文提出了基于深度迁移学习的状态估计方法,解决了因电网实际运行过程中拓扑变化导致的数据驱动估计器不可用的问题。通过IEEE标准系统和某实际省网的算例测试,得出以下结论。

1)基于深度迁移学习进行原拓扑和新拓扑之间模型迁移,提高了数据驱动状态估计模型的泛化性能。

2)本文通过含噪声的增广网络以及数据驱动方式,可以同时满足大电网状态估计的鲁棒性和实时性要求。

3)本文方法建立在新拓扑样本有一定积累或历史数据库中含有新拓扑少量样本的情况下进行模型

迁移,后续可以研究该方法在无数据积累情况下新拓扑的状态估计。

附录见本刊网络版(<http://www.aeps-info.com/aeps/ch/index.aspx>),扫英文摘要后二维码可以阅读网络全文。

参考文献

- [1] 于尔铿. 电力系统状态估计[M]. 北京: 中国水利电力出版社, 1985.
YU Erkeng. Power system state estimation[M]. Beijing: China Water & Power Press, 1985.
- [2] BARAN M E, ABUR A. Power system state estimation[M]. New York, USA: John Wiley & Sons Inc, 1999.
- [3] 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.
- [4] SCHWEPPE F C. Power system static-state estimation Part III: implementation [J]. IEEE Transactions on Power Apparatus and Systems, 1970, 89(1): 130-135.
- [5] BIAN X M, LI X R, CHEN H M, et al. Joint estimation of state and parameter with synchrophasors Part I: state tracking [J]. IEEE Transactions on Power Systems, 2011, 26(3): 1196-1208.
- [6] BIAN X M, LI X R, CHEN H M, et al. Joint estimation of state and parameter with synchrophasors Part I: state tracking [J]. IEEE Transactions on Power Systems, 2011, 26(3): 1196-1208.
- [7] 陈艳波, 马进. 一种双线性抗差状态估计方法[J]. 电力系统自动化, 2015, 39(6): 41-47.
CHEN Yanbo, MA Jin. A bilinear robust state estimation method for power systems [J]. Automation of Electric Power Systems, 2015, 39(6): 41-47.
- [8] GARANAYAK P, PANDA G. An adaptive linear neural network with least mean M -estimate weight updating rule employed for harmonics identification and power quality monitoring [J]. Transactions of the Institute of Measurement and Control, 2018, 40(6): 1936-1949.
- [9] 李超然, 肖飞, 樊亚翔, 等. 基于门控循环单元神经网络和Huber- M 估计鲁棒卡尔曼滤波融合方法的锂离子电池荷电状态估算方法[J]. 电工技术学报, 2020, 35(9): 2051-2062.
LI Chaoran, XIAO Fei, FAN Yaxiang, et al. A hybrid approach to lithium-ion battery SOC estimation based on recurrent neural network with gated recurrent unit and Huber- M robust Kalman filter [J]. Transactions of China Electrotechnical Society, 2020, 35(9): 2051-2062.
- [10] 郭烨, 张伯明, 吴文传. 指数型目标函数电力系统抗差状态估计的解法与性能分析[J]. 中国电机工程学报, 2011, 31(7): 89-95.
GUO Ye, ZHANG Boming, WU Wenchuan. Solution and

- performance analysis to a robust state estimation method with exponential objective function [J]. Proceedings of the CSEE, 2011, 31(7): 89-95.
- [11] 刘广一,戴仁昶,路轶,等.基于图计算的能量管理系统实时网络分析应用研发[J].电工技术学报,2020,35(11):2339-2348. LIU Guangyi, DAI Renchang, LU Yi, et al. Graph computing based power network analysis applications [J]. Transactions of China Electrotechnical Society, 2020, 35(11): 2339-2348.
- [12] 周念成,廖建权,王强钢,等.深度学习在智能电网中的应用现状分析与展望[J].电力系统自动化,2019,43(4):180-191. ZHOU Niancheng, LIAO Jianquan, WANG Qianggang, et al. Analysis and prospect of deep learning application in smart grid [J]. Automation of Electric Power Systems, 2019, 43(4): 180-191.
- [13] 缪家森,成丽珉,吕宏水.基于PSO-ELM的储能锂电池荷电状态估算[J].电力工程技术,2020,39(1):165-169. MIAO Jiasen, CHENG Limin, LYU Hongshui. Estimation of state of charge of energy storage lithium battery based on PSO-ELM [J]. Electric Power Engineering Technology, 2020, 39(1): 165-169.
- [14] 赵巍岳,靳松,吕天成.基于神经网络的状态估计方法研究[J].电力系统保护与控制,2018,46(22):109-115. ZHAO Weiye, JIN Song, LYU Tiancheng. Research on state estimation based on artificial neural networks [J]. Power System Protection and Control, 2018, 46(22): 109-115.
- [15] 黄蔓云,孙国强,卫志农,等.基于脉冲神经网络伪量测建模的配电网三相状态估计[J].电力系统自动化,2016,40(16):38-43. HUANG Manyun, SUN Guoqiang, WEI Zhinong, et al. Three-phase state estimation in distribution systems based on pseudo measurement modeling using spiking neural network [J]. Automation of Electric Power Systems, 2016, 40(16): 38-43.
- [16] ZAMZAM A S, FU X, SIDIROPOULOS N D. Data-driven learning-based optimization for distribution system state estimation [J]. IEEE Transactions on Power Systems, 2019, 34(6): 4796-4805.
- [17] WENG Y, NEGI R, FALOUTSOS C, et al. Robust data-driven state estimation for smart grid [J]. IEEE Transactions on Smart Grid, 2017, 8(4): 1956-1967.
- [18] YU J F, WENG Y, RAJAGOPAL R. PaToPaEM: a data-driven parameter and topology joint estimation framework for time-varying system in distribution grids [J]. IEEE Transactions on Power Systems, 2019, 34(3): 1682-1692.
- [19] JI X Q, YIN Z Y, ZHANG Y M, et al. Real-time robust forecasting-aided state estimation of power system based on data-driven models [J]. International Journal of Electrical Power & Energy Systems, 2021, 125: 106412.
- [20] 方静,彭小圣,刘泰蔚,等.电力设备状态监测大数据发展综述[J].电力系统保护与控制,2020,48(23):176-186. FANG Jing, PENG Xiaosheng, LIU Taiwei, et al. Development trend and application prospects of big data-based condition monitoring of power apparatus [J]. Power System Protection and Control, 2020, 48(23): 176-186.
- [21] 赵晋泉,夏雪,徐春雷,等.新一代人工智能技术在电力系统调度运行中的应用评述[J].电力系统自动化,2020,44(24):1-10. ZHAO Jinquan, XIA Xue, XU Chunlei, et al. Review on application of new generation artificial intelligence technology in power system dispatching and operation [J]. Automation of Electric Power Systems, 2020, 44(24): 1-10.
- [22] 程乐峰,余涛,张孝顺,等.机器学习在能源与电力系统领域的应用和展望[J].电力系统自动化,2019,43(1):15-31. CHENG Lefeng, YU Tao, ZHANG Xiaoshun, et al. Machine learning for energy and electric power systems: state of the art and prospects [J]. Automation of Electric Power Systems, 2019, 43(1): 15-31.
- [23] 杨挺,赵黎媛,王成山.人工智能在电力系统及综合能源系统中的应用综述[J].电力系统自动化,2019,43(1):2-14. YANG Ting, ZHAO Liyuan, WANG Chengshan. Review on application of artificial intelligence in power system and integrated energy system [J]. Automation of Electric Power Systems, 2019, 43(1): 2-14.
- [24] 肖飞,叶康,邓祥力,等.基于最优编码集及智能状态估计的电网故障诊断方法[J].电力系统保护与控制,2021,49(2):89-97. XIAO Fei, YE Kang, DENG Xiangli, et al. A fault diagnosis method of a power grid based on an optimal coding set and intelligent state estimation [J]. Power System Protection and Control, 2021, 49(2): 89-97.
- [25] WANG C, CHEN D L, CHEN J W, et al. Deep regression adaptation networks with model-based transfer learning for dynamic load identification in the frequency domain [J]. Engineering Applications of Artificial Intelligence, 2021, 102: 104244.
- [26] REN C, XU Y. Transfer learning-based power system online dynamic security assessment: using one model to assess many unlearned faults [J]. IEEE Transactions on Power Systems, 2020, 35(1): 821-824.
- [27] 王浩,杨东升,周博文,等.基于并联卷积神经网络的多端直流输电线路故障诊断[J].电力系统自动化,2020,44(12):84-92. WANG Hao, YANG Dongsheng, ZHOU Bowen, et al. Fault diagnosis of multi-terminal HVDC transmission line based on parallel convolutional neural network [J]. Automation of Electric Power Systems, 2020, 44(12): 84-92.

臧海洋(1986—),男,通信作者,博士,副教授,硕士生导师,主要研究方向:电力系统规划与运行分析、人工智能在电力系统中的应用。E-mail:zanghaixiang@hhu.edu.cn

郭镜玮(1998—),男,硕士研究生,主要研究方向:数据驱动状态估计。E-mail:657800307@qq.com

黄蔓云(1991—),女,博士,讲师,主要研究方向:互联大电网状态估计、中低压配电网态势感知。E-mail:hmy_hhu@yeah.net

(编辑 杨松迎)

State Estimation for Power Systems with Time-varying Topology Based on Deep Transfer Learning

ZANG Haixiang, GUO Jingwei, HUANG Manyun, WEI Zhinong, SUN Guoqiang, YU Wenshuai

(College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China)

Abstract: A data-driven state estimation method based on deep transfer learning is proposed for the situation that the data-driven state estimator is not available due to the real-time change of power system topology. The model obtained by training the massive historical data of the original topology is used as the base model. When the new topology is updated with real-time measurement data, the weights and parameters of the feature extraction layer in the base model are loaded and saved. Only fully connected layers of the model need to be fine-tuned to obtain a neural network adapted to the new topology, which improves the adaptiveness and generalization performance of the data-driven state estimation model. The estimation results are tested by arithmetic cases on the IEEE standard system and an actual provincial power grid of China, and compared with the weighted least squares method and weighted least absolute value method. The results show that the algorithm has better estimation performance and estimation efficiency compared with the above two physical algorithms when topological time-variability is considered.

This work is supported by National Key R&D Program of China (No. 2018YFB0904500).

Key words: state estimation; topological change; machine learning; deep transfer learning

