

基于双重注意力卷积双向长短期记忆神经网络的电力系统状态估计

张程^{1,2}, 林锦平¹

(1. 福建理工大学电子电气与物理学院, 福州 350118; 2. 智能电网仿真分析与综合控制福建省高校工程研究中心, 福州 350118)

摘要: 随着现代电力系统规模不断扩大, 电力系统的结构与运行方式日趋复杂, 对电力系统进行实时、准确的状态估计至关重要。对此提出了一种基于双重注意力卷积双向长短期记忆神经网络(dual attention convolutional bidirectional long and short-term memory neural networks, DA-CNN-BiLSTM)的电力系统状态估计方法。该模型引入通道注意力机制自适应调整卷积神经网络(convolutional neural network, CNN)特征通道的权重, 通过引入特征注意力机制动态分配单一特征权重输入双向长短期记忆神经网络(bi-long short-term memory neural network, BiLSTM), 从时空特征中根据获取的重要性度量筛选重要特征, 动态挖掘量测量与状态量之间的相关性。通过获得的历史数据构建量测数据集建立了DA-CNN-BiLSTM状态估计模型, 将获得的实时量测数据输入建立的状态估计模型中, 即可得到实时的状态估计结果。通过IEEE标准系统的算例分析表明, 相比WLS、SE-CNN与FA-BiLSTM状态估计方法, 所提方法的状态估计结果具有更优的估计精度、鲁棒性和计算效率。

关键词: 状态估计; 注意力机制; 神经网络; 深度学习; 鲁棒性

Power System State Estimation Based on Dual Attention Convolutional Bidirectional Long and Short-Term Memory Neural Networks

ZHANG Cheng^{1,2}, LIN Jinping¹

(1. School of Electronic Electrical and Physics, Fujian University of Technology, Fuzhou 350118, China; 2. Fujian Provincial University Engineering Research Center for Simulation Analysis and Integrated Control of Smart Grid, Fujian University of Technology, Fuzhou 350118, China)

Abstract: With the continuous expansion of modern power systems and the increasing complexity of their structures and operational modes, real-time and accurate state estimation of power systems is crucial. To address this, a power system state estimation method based on dual attention convolutional bidirectional long and short-term memory neural networks (DA-CNN-BiLSTM) is proposed. This model introduces a channel attention mechanism to adaptively adjust the weights of feature channels in convolutional neural networks (CNN), and incorporates a feature attention mechanism to dynamically allocate weights for individual features before inputting them into the bidirectional long short-term memory neural network (BiLSTM). Important features are filtered from spatiotemporal characteristics based on acquired importance metrics and the correlation between measurements and state variables is dynamically explored. By constructing a measurement dataset from historical data, the DA-CNN-BiLSTM state estimation model is established. Real-time measurement data is then fed into this model to obtain real-time state estimation results. Case studies on IEEE standard systems demonstrate that compared to WLS, SE-CNN, and FA-BiLSTM state estimation methods, the proposed method achieves superior estimation accuracy, robustness, and computational efficiency.

Key words: state estimation; attention mechanism; neural network; deep learning; robustness

基金项目: 国家自然科学基金资助项目(52377088); 福建省财政厅专项资助项目(GY-Z220230); 福建省自然科学基金资助项目(2023J01951)。

Foundation item: Supported by the National Natural Science Foundation of China(52377088); the Special Fund of the Fujian Provincial Finance Department(GY-Z220230); the Natural Science Foundation of Fujian Province(2023J01951)。

0 引言

随着“碳达峰、碳中和”的实施,我国大力发展可再生能源,构建以新能源为主体的新型电力系统^[1-2]。近年来,新能源接入比例日趋增加,对电力系统的安全稳定运行带来极大的挑战^[3-4]。因此,需要通过状态估计来获取电力系统实时、可靠的运行数据来保证电力系统正常运行^[5-6]。

目前,基于加权最小二乘(weighted least square, WLS)的状态估计方法得到广泛应用,在量测噪声服从高斯分布的理想条件下,其计算结果为无偏最小方差。但实际量测数据中却存在非高斯噪声与坏数据,使得WLS计算难以收敛,计算结果误差较大^[7-8]。

为了解决该问题,国内外学者提出鲁棒状态估计方法,即通过改变其求解的目标函数来提高状态估计的鲁棒性。包括加权最小绝对值(weighted least absolute value, WLAV)估计^[9]、二次线性(quadratic-linear, QL)估计、二次常数(quadratic-constant, QC)估计^[10]、指数型目标函数(maximum exponential square, MES)估计^[11]等。虽然以上方法应对坏数据的能力相比WLS有所提高,但存在目标函数复杂、求解困难的问题。对此,文献[12]提出一种动态分区的鲁棒估计方法,对量测量进行辨识分区,来自适应选择WLS或WLAV方法进行估计,在精度和鲁棒性良好的情况下提高效率。文献[13-14]提出将WLAV估计转换成通过非线性变换转化的双线性问题,提高求解效率。文献[15]在双线性WLAV基础上引入矩阵变换,提高电力系统杠杆点的鲁棒性。但传统状态估计方法对于当前电力系统海量的多源数据应对乏力,无法充分挖掘历史数据中的有效信息进行状态估计。

当下,基于海量历史数据和机器学习、深度学习的数据驱动状态估计逐渐成为研究热点^[16-17]。数据驱动方法不需要对电力系统状态估计进行复杂的数学建模过程,直接通过对历史数据自主学习得到量测量与状态量之间的映射关系形成模型,最后将实时量测数据输入得到估计结果,有效提高状态估计精度以及效率^[18-20]。文献[21]利用深度神经网络(deep neural networks, DNN)进行伪量测建模,解决交直流混合配电网交替迭代状态下实时量测数据少的问题,提高量测冗余度,准确估计混合配电网

状态。文献[22]以长短期记忆神经网络(long short-term memory neural network, LSTM)进行数据处理与粒子滤波相结合进行状态估计,具有较高的精度。文献[23]通过粒子滤波算法生成训练数据与CNN相结合用于状态估计领域中,用实时PMU数据状态估计,提高估计结果准确度。

针对传统状态估计在面对规模庞大的电力系统时,无法充分挖掘历史数据中的有效信息进行实时、准确的状态估计,本文提出一种基于DA-CNN-BiLSTM的电力系统状态估计方法。在CNN-BiLSTM基础上,引入通道注意力机制的挤压激励网络(squeeze and excitation network, SENet)模块形成SE-CNN,自适应调整CNN特征通道的权重,解决了对常规CNN而言各个通道间的相关联系难以刻画的问题;引入特征注意力(feature attention, FA)模块形成FA-BiLSTM,对输入特征通道上单一特征分配动态权重,有效解决传统特征相关性分析方法筛选输入特征过程中出现的特征关联信息丢失的问题。通过将CNN、BiLSTM和注意力机制相结合,提高模型的性能。该方法以节点、支路功率作为输入变量,电压幅值和电压相角作为输出变量。离线阶段通过历史数据构建量测数据集在搭建的DA-CNN-BiLSTM网络上进行训练,保存得到状态估计模型;在线估计阶段将实时量测数据输入训练好的模型进行状态估计得到结果。最终,进行仿真并与WLSWLS、SE-CNN与FA-BiLSTM对比验证所提方法的有效性。

1 传统状态估计

电力系统量测方程表达式^[7-8]为:

$$z = h(x) + e \quad (1)$$

式中: z 为 m 维量测向量,包含节点电压幅值、节点电压相角、节点注入功率、支路功率; $h(x)$ 为量测方程; x 为 n 维状态变量,包括节点电压幅值和相角; e 为 n 维量测噪声向量。

状态估计就是求得一组状态变量,使得量测方程与实际量测量之间的误差最小。其中,WLS状态估计方法应用最为广泛,求解方程为:

$$\min J(x) = (z - h(x))^T R^{-1} (z - h(x)) \quad (2)$$

式中: $J(x)$ 为损失函数; R^{-1} 为量测权重对角矩阵。

式(2)可以利用高斯-牛顿迭代法求解,通过式(3)的线性方程组迭代求解。

$$\begin{cases} \Delta x = \mathbf{G}^{-1} \mathbf{H}^T \mathbf{R}^{-1} (\mathbf{z} - h(x)) \\ x^{k+1} = x^k + \Delta x \end{cases} \quad (3)$$

式中: Δx 为迭代中求和到状态变量 x 的状态修正量; $\mathbf{H}$ 为量测方程 $h(x)$ 求导后的雅可比矩阵; $\mathbf{G} = \mathbf{H}^T \mathbf{R}^{-1} \mathbf{H}$ 为增益矩阵; k 为迭代次数。当 $\Delta x_{\max}^k$ 的绝对值小于所设置的收敛阈值时判定为收敛, 停止迭代计算对应的 x^k 作为最优结果输出。

2 DA-CNN-BiLSTM 结构

本文所提的 DA-CNN-BiLSTM 神经网络的模型结构如图 1 所示。主要由 SE-CNN 和 FA-BiLSTM 组成, SE-CNN 自适应调整 CNN 特征通道的权重的加强空间特征提取能力; FA-BiLSTM 动态分配单一特征权重, 避免特征关联信息丢失, 双向发掘时序特征^[24]。通过双重注意力机制加强 CNN-BiLSTM 网络的输入特征与目标特征的关联程度, 提高模型性能。

2.1 SE-CNN 结构

将一组输入的量测量通过数据处理转换成多通道固定维度矩阵, 通过在 CNN 的卷积层后插入 SENet 模块形成的 SE-CNN 进行计算。SE-CNN 既具有常规 CNN 局部权重共享的结构, 能够较好地处理高维数据的优点^[25]; 又能对网络输入通道进行计算得到通道权值, 通过对应的权值来放大或抑制相应的特征通道, 提高 CNN 的性能。

SE-CNN 结构如图 2 所示, 包含 4 个部分。

1) 变换

通过设定不同的卷积方式进行卷积, 提取出未加权的特征图 U , 图 2 左侧为二维分组卷积, 其优点是通过将输入数据分为 g 份, 利用与常规卷积相同的参数量进行运算能够生成 g 倍的特征图, 有助于后续的特征提取; C 为卷积核组数量, 每组卷积核形成 1 维特征图。

2) 挤压

通过挤压操作将各个通道内含有的信息进行空间维度的聚合, 形成一个包含各个通道重要程度信息的多维统计量。本文的 Squeeze 采用全局平均池化与全局最大池化实现, 将二者池化后的数据进行相加。池化过程中将未加权的特征图 U 降维, 最终得到 C 维统计量 $\mathbf{z} \in R^C$, 其中第 c 个元素为:

$$\begin{aligned} z_c &= F_{sq}(u_c) = z_{c1} + z_{c2} \\ &= \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j) + \max \{ u_c(i, j) \} \end{aligned} \quad (4)$$

式中: z_{c1} 为平均池化结果; z_{c2} 为最大池化结果; H 、 W 为全连接层参数; $u_c(i, j)$ 为输入数据中第 i 行第 j 列的元素。

3) 激励

每个特征通道通过两个全连接层构成的自选门机制, 生成一个不同颜色的权重代表其重要程度。对挤压部分输出的 C 维统计量 $\mathbf{z}$ 计算, 得到代表特




图 1 DA-CNN-BiLSTM 模型结构图

Fig. 1 DACNN-BiLSTM model structure




图 2 SE-CNN 结构

Fig. 2 SE-CNN model structure

征通道重要性的权重 s :

$$\begin{aligned} s &= F_{ex}(z, W) = \text{sigmoid}(f(z, W)) \\ &= \text{sigmoid}(W_2 \text{Re lu}(W_1 z)) \end{aligned} \quad (5)$$

式中: sigmoid 与 Re lu 分别为两个全连接层后的激活函数; $f(\cdot)$ 代表激活函数的前置结构; W_1 与 W_2 分别为两个全连接层参数, W_1 用于降维、 W_2 用于升维。

4) 放缩

将激励部分输出的权重 s 与变换部分输出的未加权特征图 U 按维数相乘, 输出通道加权特征图 $\tilde{X}$ 。

$$\tilde{x}_c = F_{\text{scale}}(U_c, s_c) = s_c U_c \quad (6)$$

$$\tilde{X} = [\tilde{x}_1, \dots, \tilde{x}_c, \dots, \tilde{x}_c] \quad (7)$$

SE-CNN 对输入通道之间的相关关系进行显式建模, 通过上述步骤对神经网络的通道权重进行计算, 将所得的结果与原通道进行相乘。提升对当前任务有用的特征通道, 抑制对当前任务用处不大的特征通道, 提高模型性能, 解决了对常规 CNN 而言各个通道间的相关联系难以刻画的问题。

2.2 FA-BiLSTM 结构

通过在 BiLSTM 前插入 FA 模块形成的 FA-BiLSTM, 具有常规 BiLSTM 双向挖掘时序数据特征的优点^[26-27], 还能通过对 BiLSTM 输入特征通道上的单个特征动态分配注意力权重^[28-30], 有效解决传统特征相关性分析方法筛选输入特征过程中, 出现的特征关联信息丢失问题。

图 3 所示为 BiLSTM 网络结构, 该 BiLSTM 网络在 $t-1$ 、 t 、 $t+1$ 时刻分别展开, 其中 x_t 为 t 时刻模型输入, h_t 为 t 时刻隐藏层状态, y_t 为 t 时刻输出。相对于单向的 LSTM 网络, BiLSTM 网络是一种双向循环结构, 可以同时进行从过去到未来的正向传播和从未来到过去的反向传播。因为两个传播方向的隐藏层之间并没有发生交互, 所以可以把 BiLSTM 当成




图 3 BiLSTM 网络结构

Fig. 3 BiLSTM model structure

两个独立的 LSTM 网络, 通过同时处理双向时序数据, 能够更好地发掘数据的时序特征。

本文所采用的 FA-BiLSTM 模块结构包含两个部分, 如图 4 所示。

1) 放缩

通过二维常规卷积将特征图上含有的信息进行聚合, 形成一个包含特征图上各个特征重要程度信息的一维统计量。过程中将输入的 C_1' 维特征图 X_1 , 采用二维常规卷积运算(后跟 sigmoid 激活函数)降维成包含特征信息的一维注意力权重图 e 。

$$e = \text{sigmoid}(W_e X_1 + b_e) \quad (8)$$

式中: e 为输入特征图上单个特征对应的注意力权重系数组合; W_e 为卷积层参数; b_e 为设置的偏置向量。

然后, 将输入特征图 X_1 与所得的权重图 e 相乘得到加权特征图 U_1 。

$$U_1 = eX \quad (9)$$

2) 变换

通过 Softmax 函数对所得加权特征图的特征做归一化处理, 降低数据量纲对输出结果的影响, 防止过拟合, 对单一特征 x 归一化公式为:




图 4 FA-BiLSTM 模型结构

Fig. 4 FA-BiLSTM model structure

$$x' = \frac{x - \min x}{\max x - \min x} \quad (10)$$

将归一化结果 x' 通过激活函数 swish, 加入非线性因素, 以解决线性模型表达能力不足的缺陷, 得到新的加权特征图 U_2 。

然后, 将 U_2 通过分组卷积设置 valid 计算方式进行逐点卷积, 进一步提取相关特征, 并进行归一化处理(后跟 swish 激活函数), 得到最终输出特征图 $\tilde{X}_1$ 。

最后, 将 $\tilde{X}_1$ 通过 flatten 函数进行数据扁平化, 得到分配动态权重的时间特征序列, 输入 BiLSTM 模型。BiLSTM 在处理长序列数据时, 前向与后向的 LSTM 层需要对每一个时间步进行处理, 然后将所有时间步的输出进行线性组合来形成最终的输出。但由于 BiLSTM 后续的信息处理依赖前序信号的处理结果, 可能会导致对某些重要特征的关注不够或者被早期的处理结果所限制。通过与 FA 模块结合形成 FA-BiLSTM, 能够对 BiLSTM 输入特征通道上的单个特征动态分配注意力权重, 动态地聚焦于序列中的关键信息, 而不是平均地对待所有信息, 这有助于解决长序列中的信息稀释问题, 使得模型能够更好地处理序列中的时间依赖性, 从而提高了并发性能。

3 本文算法流程

本文提出基于 DA-CNN-BiLSTM 的状态估计模型通过将注意力机制、CNN、BiLSTM 相结合, 增强时空特征提取能力, 放大有用特征, 抑制无用特征, 充分挖掘历史数据中量测量与状态量的关系。离线训练阶段以量测量节点功率、支路功率为输入, 状态量节点电压幅值与相角为输出, 对多时间截面数据进行训练得到模型, 在线估计阶段采集实时数据通过训练完成的模型进行状态估计。

参考电力系统量测配置, 本文的量测量与状态量的函数公式如式(11)所示。

$$\begin{cases} v_i = v_i \\ \theta_i = \theta_i \\ P_i = v_i \sum_{j \in N_i} v_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_i = v_i \sum_{j \in N_i} v_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \\ P_{ij} = v_i^2 (g_{si} + g_{ij}) - v_i v_j g_{ij} \cos \theta_{ij} - v_i v_j b_{ij} \sin \theta_{ij} \\ Q_{ij} = -v_i^2 (b_{si} + b_{ij}) + v_i v_j b_{ij} \cos \theta_{ij} - v_i v_j g_{ij} \sin \theta_{ij} \end{cases} \quad (11)$$

式中: v_i 和 θ_i 分别为节点电压幅值和相角; N_i 为所有与节点 i 通过支路相连的节点集合; P_i 和 Q_i 分别为节点 i 的有功与无功功率; P_{ij} 和 Q_{ij} 分别为支路 ij 有功与无功功率; G_{ij} 和 B_{ij} 分别为支路 ij 电导与电纳; g_{si} 和 g_{ij} 分别为支路 si 、 ij 等效电导。

本文算法流程如图5所示, 分为离线训练与在线估计两部分。




图5 算法流程图

Fig. 5 Algorithmic flowchart

具体步骤如下。

1) 数据集生成。通过获得的多截面负荷数据进行潮流计算得到多截面历史潮流数据作为真实值, 在此基础上加入量测噪声生成多截面量测数据作为数据集。

2) 数据预处理。对数据进行归一化、维度转换和数据平铺等处理, 按照 7 : 3 划分训练集与测试集, 训练集用于训练模型, 测试集用于测试性能。

3) 搭建模型并设置参数。搭建 DA-CNN-BiLSTM 的网络结构, 生成模型结构编程并设置学习率、迭代次数等参数。

4) 模型离线训练。通过训练集进行 DA-CNN-

BiLSTM模型训练,根据迭代结果与实际值之间的误差,更新模型权重;判断是否达到最大迭代次数,若否,则打乱数据集进行下一次迭代,若是,则结束训练保存模型并利用测试集测试。

5)在线估计。将实时量测数据经过数据预处理,输入训练好的状态估计模型,输出得到对应时刻的估计值,通过与真实值进行对比并计算性能指标,输出结果。

4 算例分析

本文以 IEEE 33 节点系统作为仿真系统,以英国伦敦家庭用户负荷数据为历史数据库,以 5 min 为一个样本截面,生成 3 000 组实际负荷,以 7:3 划分训练集与测试集。将多截面实际负荷归算为节点负荷进行潮流计算得到的潮流结果作为真实值。通过在潮流真值上添加不同的噪声模拟实际量测与坏数据进行验证。具体量测配置为全部节点注入有功、无功功率和支路 1-2、2-3、4-5、7-8、9-10、12-13、15-16、20-21、24-25、26-27、29-30 的支路首端有功、无功功率。

本文由 MATLAB 编程实现,通过深度网络设计器搭建神经网络。优化器采用 Adam,初始学习率设置为 0.01,通过批量归一化和分组卷积防止过拟合。


4.1 估计精度分析

本节的精度测试为在多截面潮流数据中添加标准差为 2% 的高斯噪声模拟实际量测。用于验证提出的基于 DA-CNN-BiLSTM 的状态估计模型估计精度,并通过 WLS、SE-CNN、FA-BiLSTM 与本文方法进行对比。


图 6 为随机选择的第 50 个截面下的状态估计结果图。从图 6 中可以看出本文方法的状态估计结果有着较高的精度。为了更加直观地对比不同方法的差异,通过平均绝对误差(MAE,其值用 M_{AE} 表示)、最大绝对误差(MaxAE,其值用 M_{ax-AE} 表示)、均方根误差(RMSE,其值用 R_{MSE} 表示)表示状态估计性能。

$$M_{AE} = \frac{1}{T} \sum_{t=1}^T |\hat{x}_i(t) - x_i(t)| \quad (12)$$

$$M_{ax-AE} = \max_{t \in [1, T]} \{ |\hat{x}_i(t) - x_i(t)| \} \quad (13)$$



(a) 节点电压幅值



(b) 节点电压相角

图 6 33 节点状态估计结果对比

Fig. 6 Comparison of 33-node state estimation results

$$R_{MSE} = \sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{x}_i(t) - x_i(t))^2} \quad (14)$$

式中: $\hat{x}$ 为状态向量估计值; x 为状态向量真实值; 计算单截面数据时, i 为截面号, t 为节点号, T 为总节点数量; 计算多截面数据时, i 为节点号, t 为节时间截面, T 为总时间截面数量;

图 7 为第 50 个截面下各个方法的状态估计结果与潮流真值计算得到的绝对误差图。

表 1—2 为 IEEE 33 节点在第 50 个数据截面下不同算法的状态估计结果指标。

通过将表 1、2 中本文方法与 WLS 的平均绝对误差相对比,第 50 个数据截面整体状态的电压幅值和电压相角误差比 WLS 分别降低了 56.07% 和 40.52%,本文方法其他两项误差指标也都小于 WLS。而与其他数据驱动算法对比,提取单一特征的 SE-CNN、FA-BiLSTM 的平均绝对误差虽然小于 WLS,但是其最大绝对误差会出现大于 WLS 的情况,这可能会使得状态估计结果出现较大偏差。而本文方法对比提取单一特征的方法解决了这一缺点,并且整体估计误差更小。可以得出,本文方法在单一数据截面的状态估计精度比传统 WLS 方法




图 7 第 50 个截面状态估计结果绝对误差
Fig. 7 Absolute errors in state estimation results for the 50th cross-section

表 1 第 50 个截面幅值状态估计结果指标
Tab. 1 Indicator of the amplitude state estimation results at the 50th cross-section

方法	电压幅值误差/(10 ⁻² p. u.)		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	0.091 9	0.305 8	0.010 4
SE-CNN	0.180 2	1.064 3	0.021 4
FA-BiLSTM	0.189 0	1.205 4	0.023 5
WLS	0.209 2	0.881 1	0.023 4

表 2 第 50 个截面相角状态估计结果指标
Tab. 2 Indicator of the angle state estimation results at the 50th cross-section

方法	电压相角误差/(10 ⁻² (°))		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	12.381 5	38.187 1	1.431 7
SE-CNN	16.753 3	44.387 9	1.742 2
FA-BiLSTM	17.542 2	44.076 7	1.806 9
WLS	20.816 9	108.577 5	3.148 9

和其他数据驱动算法有显著提高。
为了验证本文方法在不同数据截面下的精度, 通过取单一节点的部分截面数据来判断其精度。图

8 为随机选取节点 30 在第 150—200 数据截面下各个方法的状态估计结果与潮流真值进行计算得到的绝对误差图。




图 8 第 150—200 个截面状态估计结果绝对误差
Fig. 8 Absolute errors in state estimation results for the 150th-200th cross-sections

由图 8 的数据可以看出本文提出的状态估计方法在高斯噪声下, 多数数据截面整体误差较小。表 3—4 为节点 30 在第 150—200 个数据截面下不同算法的状态估计结果指标。

表 3 第 150—200 个截面幅值状态估计结果指标
Tab. 3 Indicator of the amplitude state estimation results at the 150th—200th cross-section

方法	节点 30 电压幅值误差/(10 ⁻² p. u.)		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	0.312 0	1.123 4	0.038 5
SE-CNN	0.387 0	1.201 1	0.045 7
FA-BiLSTM	0.401 1	1.252 9	0.048 8
WLS	0.418 6	1.524 6	0.052 2

通过将表 3、4 中本文方法与 WLS 的平均绝对误差相对比, 节点 30 在第 150—200 个数据截面下的电压幅值和电压相角误差比 WLS 分别降低了 25.47 % 和 18.66 %, 其他两项误差指标也都小于

表 4 第 150—200 个截面相角状态估计结果指标

Tab. 4 Indicator of the angle state estimation results at the 150th—200th cross-section

方法	节点 30 电压相角误差/($10^{-2}(\circ)$)		
	平均绝对误差	最大绝对误差	均方根误差
本文方法	18.142 4	48.427 2	2.156 5
SE-CNN	20.899 1	53.022 0	2.444 8
FA-BiLSTM	19.647 1	52.937 1	2.341 9
WLS	22.304 5	71.230 0	2.926 2

WLS。同时,各项误差指标也都小于两种提取单一特征方法的误差。可以得出,本文方法在多数数据截面下的状态估计精度比传统 WLS 方法和其他数据驱动算法有显著提高。

4.2 鲁棒性分析

坏数据是量测数据中会对估计结果造成较大偏差的数据类型。因此,测试状态估计算法在量测数据中存在坏数据情况下的估计精度,对于其实用性具有重大意义。本文的坏数据通过添加标准差为 10 % 的高斯噪声在部分支路上模拟现实中量测的坏数据,添加支路为 29—30(包含支路有功和无功功率两部分),其余支路添加噪声与上一节一致。

由图 10 的数据可以看出本文提出的状态估计方法在含坏数据时,单一数据截面整体误差较小。表 5—6 为 IEEE33 节点在含坏数据的第 50 个数据截面下不同算法的状态估计结果指标。

含坏数据的第 50 个截面下的 IEEE 33 节点系统数据状态估计结果如图 9 所示。

从图 9 中可以看出在含坏数据的情况下,本文方法的状态估计结果依旧有着较高的精度。

图 10 为含坏数据的第 50 个截面下各个方法状态估计结果与潮流真值进行计算得到的绝对误差图。

由表 5—6 可知,在含坏数据的情况下,本文方法的电压幅值和电压相角误差小于其他 3 种方法。同时,将每个方法的平均绝对误差与上一节对比, WLS 在含坏数据时的误差较含 2 % 高斯噪声时的误差分别增大了 118.55 % 和 61.79 %,本文方法误差增大了 31.77 % 和 9.15 %。可以得出,本文所提方法在系统量测含坏数据的单一数据截面状态估计精度和鲁棒性高于传统 WLS 和其他数据驱动算法。

图 11 为含坏数据的节点 30 在数据截面第 150—




图 9 含坏数据的 33 节点状态估计结果对比

Fig. 9 Comparison of 33-node state estimation results containing bad data




图 10 含坏数据的第 50 个截面状态估计结果绝对误差

Fig. 10 Absolute errors in state estimation results for the 50th cross-section containing bad data

表 5 含坏数据的第 50 个截面幅值状态估计结果指标

Tab. 5 Indicator of the amplitudes tate estimation results at the 50th cross-section containing bad data

方法	电压幅值误差/(10 ⁻² p. u.)		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	0. 121 1	0. 312 5	0. 012 0
SE-CNN	0. 276 6	1. 810 5	0. 034 6
FA-BiLSTM	0. 255 4	1. 381 6	0. 031 8
WLS	0. 457 2	1. 985 3	0. 057 9

表 6 含坏数据的 50 截面相角状态估计结果指标

Tab. 6 Indicator of the angle state estimation results at the 50th cross-section containing bad data

方法	电压相角误差/(10 ⁻² (°))		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	13. 514 2	44. 125 9	1. 544 3
SE-CNN	19. 844 2	47. 030 5	1. 922 7
FA-BiLSTM	20. 170 6	54. 052 3	2. 193 5
WLS	33. 679 0	109. 192 7	4. 203 4

200 个各个方法的状态估计结果与潮流真值进行计算得到的绝对误差图。


由图 11 的数据可以看出本文提出的状态估计方法在含坏数据时, 多数据截面整体误差较小。表 7、表 8 为含坏数据的节点 30 在第 150—200 数据截面下不同算法的状态估计结果指标。

由表 7—8 可知, 在不同数据截面含坏数据的情况下, 本文方法的电压幅值和电压相角误差小于其他 3 种方法。同时, 将每个方法的平均绝对误差与上一节对比, WLS 在含坏数据时的误差较含 2 % 高斯噪声时的误差分别增大了 115. 12 % 和 85. 30 %, 本文方法误差增大了 14. 39 % 和 19. 41 %。可以得出, 本文所提方法在含坏数据的多数据截面状态估计精度和鲁棒性高于传统 WLS 和其他数据驱动算法。


4. 3 非高斯噪声分析

本节测试在多截面潮流数据中添加 Cauchy 分布噪声模拟实际量测, 验证所提方法在非高斯噪声下的性能。不同尺度参数 β 的 Cauchy 分布噪声下, 各个方法第 150—200 个数据截面估计结果与潮流真值计算得到的整体 MAE 值对比如表 9 所示。

从表 9 可知, 不同的尺度参数 β 下, 本文方法的误差均小于其他 3 种方法。以 $\beta = 2$ 时为例, 本



(a) 节点30电压幅值绝对误差



(b) 节点30电压相角绝对误差

图 11 含坏数据的第 150—200 个截面状态估计结果绝对误差

Fig. 11 Absolute error in state estimation results for the 150th—200th cross-sections containing bad data

表 7 含坏数据的第 150—200 个截面幅值状态估计结果指标

Tab. 7 Indicator of the state estimation results at the 150th—200th cross-section containing bad data

方法	节点 30 电压幅值误差/(10 ⁻² p. u.)		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	0. 356 9	1. 275 7	0. 042 9
SE-CNN	0. 472 5	1. 385 4	0. 052 4
FA-BiLSTM	0. 453 3	1. 392 1	0. 056 1
WLS	0. 900 5	3. 263 7	0. 116 4

表 8 含坏数据的 150—200 截面相角状态估计结果指标

Tab. 8 Indicator of the state estimation results at the 150th—200th cross-section containing bad data

方法	节点 30 电压相角误差/(10 ⁻² (°))		
	平均绝对值误差	最大绝对值误差	均方根误差
本文方法	21. 663 9	53. 432 9	2. 635 3
SE-CNN	27. 125 3	66. 096 4	3. 216 6
FA-BiLSTM	25. 305 2	63. 415 7	3. 032 9
WLS	41. 330 5	112. 185 3	5. 157 7

表9 非高斯噪声下150—200截面整体MAE值
Tab. 9 Overall MAE values of 150th—200th cross-section
under non-Gaussian noise

方法	尺度参数 β	幅值误差/(10^{-2} p. u.)	相角误差/ $10^{-2}(\circ)$
本文方法	1	0.219 1	12.304 9
	2	0.320 1	18.866 9
SE-CNN	1	0.268 4	14.930 5
	2	0.397 0	26.453 5
FA-BiLSTM	1	0.268 0	14.227 8
	2	0.386 1	28.258 9
WLS	1	0.324 9	17.943 4
	2	0.599 4	35.750 4

文方法的幅值误差相比 SE-CNN、FA-BiLSTM、WLS 分别减小了 19.37%、17.09%、46.59%。结果表明,在非高斯噪声中本文方法相比其他3种方法精度更高,具有更好的适应性。

4.4 计算效率

计算效率是评价状态估计方法性能的重要因素,本文基于数据驱动的理念,通过提取历史数据中的重要特征,训练得到量测量与状态量的映射关系,构建电力系统状态估计模型。而传统算法是基于电力系统内部机理构建目标函数求解,随着系统规模的扩大以及对状态估计性能更高的要求,传统算法的目标函数变得复杂多样,其计算效率受影响较大。本文方法略去了对电力系统内部机理分析的过程,以解决传统算法计算复杂度偏高的问题。

在不同系统上分别用两种方法测试单一数据截面估计时间。当测试系统从33节点系统提高到118节点系统时,本文方法估计时间从0.046 9 s 变成0.056 6 s,增加了20.68%,传统WLS算法估计时间从0.032 1 s 变成0.094 1 s,增加了193.14%。由此可知,随着系统规模扩大,基于物理模型的WLS的估计时间变化较大;而本文方法受规模变化的影响较大的是离线训练时间,在线估计时间变化不大,而离线训练时间过长可以用多线程处理的方法解决。由此表明,在大规模的电力系统状态估计中本文方法会比传统方法效率更高。

5 结论

本文提出了一种基于DA-CNN-BiLSTM的电力系统状态估计方法。通过搭建DA-CNN-BiLSTM模型来对历史数据中的空间特征与时序特征进行深度

挖掘,实现了对于电力系统的状态估计。通过在IEEE标准系统上本文方法与其他算法进行算例仿真对比,得到以下结论。

1)本文方法通过在历史数据中挖掘量测量与状态量的映射规律训练模型,能够有效利用历史数据中的有效信息,进行实时状态估计并且具有良好的估计精度与鲁棒性。

2)本文模型在模拟实际量测与含坏数据情况下测试,充分验证了该模型在估计精度与鲁棒性上优于传统WLS算法以及其他数据驱动算法。

3)本文方法在线估计的计算时间受系统规模扩大的变化较小,而传统方法计算时间变化较大,表明本文算法在计算效率上更适合大规模电网状态估计的需求。

本文的状态估计方法属于静态状态估计,且并未考虑电力系统中因量测设备不同的数据融合应用。在后续研究中考虑将数据驱动方法与动态状态估计、数据融合结合应用,使该研究具有更长远的应用价值。

参考文献

- [1] 周原冰,杨方,余潇潇,等.中国能源电力碳中和实现路径及实施关键问题[J].中国电力,2022,55(5):1-11.
ZHOU Yuanbing, YANG Fang, YU Xiaoxiao, et al. Realization pathways and key problems of carbon neutrality in China's energy and power system[J]. Electric Power, 2022, 55(5): 1-11.
- [2] 秦博宇,李恒毅,张哲,等.地下空间支撑下的电力能源系统:构想、挑战与展望[J].中国电机工程学报,2022,42(4):1321-1332.
QIN Boyu, LI Hengyi, ZHANG Zhe, et al. Underground space supported electric energy systems: conceptions, challenges, and prospects[J]. Proceedings of the CSEE, 2022, 42(4): 1321-1332.
- [3] CHEN Y, CHEN H, JIAO Y, et al. Data-driven robust state estimation through off-line learning and on-line matching[J]. Journal of Modern Power Systems and Clean Energy, 2021, 9(4): 897-909.
- [4] ENDSLEY M R, CONNORS E S. Situation awareness: state of the art[C]//2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century, July 20-24, 2008, Pittsburgh, USA. New York: IEEE, 2008: 1-4.
- [5] 陈艳波,于尔铿.电力系统状态估计[M].北京:科学出版社,2021.
- [6] 于尔铿,胡锡龙,刘广一,等.实时网络状态分析[J].电网技术,1991(2):47-51,7-72.
YU Erkeng, HU Xilong, LIU Guangyi, et al. Real time network state analysis[J]. Power System Technology, 1991(2): 47-51, 7-72.

- [7] BIAN X, LI X R, CHEN H, 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.
- [8] BIAN X, LI X R, CHEN H, et al. Joint estimation of state and parameter with synchrophasors—part II : parameter tracking [J]. IEEE Transactions on Power Systems, 2011, 26(3): 1209 – 1220.
- [9] WEI H, SASAKI H, KUBOKAWA J, et al. An interior point method for power system weighted nonlinear L-1 norm static state estimation [J]. IEEE Transactions on Power Systems, 1998, 13(2): 617 – 623.
- [10] BALDICK R, CLEMENTS K A, PINJODZIGAL Z, et al. Implementing nonquadratic objective functions for state estimation and bad data rejection [J]. IEEE Transactions on Power Systems, 1997, 12(1): 376 – 382.
- [11] 吴文传, 郭烨, 张伯明. 指数型目标函数电力系统抗差状态估计[J]. 中国电机工程学报, 2011, 31(4): 67 – 71.
WU Wenchuan, GUO Ye, ZHANG Boming. A robust state estimation method with exponential objective function [J]. Proceedings of the CSEE, 2011, 31(4): 67 – 71.
- [12] 俞文帅, 黄蔓云, 卫志农, 等. 基于动态分区和多估计准则的电力系统自适应鲁棒状态估计[J]. 电力系统自动化, 2021, 45(19): 173 – 180.
YU Wenshuai, HUANG Manyun, WEI Zhinong, et al. Adaptive robust state estimation for power system based on dynamic partitioning and multiple estimation criteria [J]. Automation of Electric Power Systems, 2021, 45(19): 173 – 180.
- [13] 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.
- [14] 厉超, 卫志农, 倪明, 等. 基于变量代换内点法的加权最小绝对值抗差状态估计[J]. 电力系统自动化, 2015, 39(6): 48 – 52, 106.
LI Chao, WEI Zhinong, NI Ming, et al. WLAV robust state estimation based on variable substitution interior point method [J]. Automation of Electric Power Systems, 2015, 39(6): 48 – 52, 106.
- [15] 张明, 嵇文路, 潘小辉, 等. 基于矩阵变换的双线性WLAV状态估计[J]. 电力系统保护与控制, 2019, 47(19): 1 – 6.
ZHANG Ming, JI Wenlu, PAN Xiaohui, et al. Bilinear WLAV state estimation based on matrix transformation [J]. Power System Protection and Control, 2019, 47(19): 1 – 6.
- [16] 宋亚奇, 周国亮, 朱永利. 智能电网大数据处理技术现状与挑战[J]. 电网技术, 2013, 37(4): 927 – 935.
SONG Yaqi, ZHOU Guoliang, ZHU Yongli. Present status and challenges of big data processing in smart grid [J]. Power System Technology, 2013, 37(4): 927 – 935.
- [17] 李明节, 陶洪铸, 许洪强, 等. 电网调控领域人工智能技术框架与应用展望[J]. 电网技术, 2020, 44(2): 393 – 400.
LI Mingjie, TAO Hongzhu, XU Hongqiang, et al. The technical framework and application prospect of artificial intelligence application in the field of power grid dispatching and control [J]. Power System Technology, 2020, 44(2): 393 – 400.
- [18] 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.
- [19] YU J, 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.
- [20] WENG Y, NEGI R, ILIC M D. Probabilistic joint state estimation for operational planning [J]. IEEE Transactions on Smart Grid, 2019, 10(1): 601 – 612.
- [21] 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.
- [22] 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.
- [23] 刘晓莉, 曾祥晖, 黄翊阳, 等. 联合粒子滤波和卷积神经网络的电力系统状态估计方法[J]. 电网技术, 2020, 44(9): 3361 – 3367.
LIU Xiaoli, ZENG Xianghui, HUANG Yiyang, et al. State estimation based on particle filtering and convolutional neural networks for power systems [J]. Power System Technology, 2020, 44(9): 3361 – 3367.
- [24] 朱凌建, 荀子涵, 王裕鑫, 等. 基于CNN-BiLSTM的短期电力负荷预测[J]. 电网技术, 2021, 45(11): 4532 – 4539.
ZHU Lingjian, XUN Zihan, WANG Yuxin, et al. Short-term power load forecasting based on CNN-BiLSTM [J]. Power System Technology, 2021, 45(11): 4532 – 4539.
- [25] 邱锡鹏. 神经网络与深度学习[M]. 北京: 机械工业出版社, 2020: 111 – 114.
- [26] 苏向敬, 周汶鑫, 李超杰, 等. 基于双重注意力LSTM神经网络的可解释海上风电出力预测[J]. 电力系统自动化, 2022, 46(7): 141 – 151.
SU Xiangjing, ZHOU Wenxin, LI Chaojie, et al. Interpretable offshore wind power output forecasting based on dual-stage attentional long short-term memory [J]. Automation of Electric Power Systems, 2022, 46(7): 141 – 151.
- [27] 李世春, 刘佳昌, 刘蒙恩, 等. 基于BiLSTM多算法混合神经网络模型的季节性等效惯量短期预测[J]. 南方电网技术, 2026, 20(2): 39 – 52.
LI Shichun, LIU Jiachang, LIU Meng'en, et al. Short-term prediction of seasonal equivalent inertia based on BiLSTM multi-algorithm hybrid neural network model [J]. Southern Power System Technology, 2026, 20(2): 39 – 52.
- [28] 何振武, 姜飞, 欧阳卫, 等. 基于自适应分区和SFVMD-LSTM伪量测建模的新型配电系统抗差状态估计[J]. 电力建设, 2024, 45(10): 78 – 89.
HE Zhenwu, JIANG Fei, OUYANG Wei, et al. Novel distribution system robust state estimation based on adaptive partitioning and SFVMD-LSTM pseudo-measurement modeling [J]. Electric Power Construction, 2024, 45(10): 78 – 89.
- [29] 张玉敏, 张涌琛, 叶平峰, 等. 基于集合经验模态分解的增强

核岭回归配电系统状态估计[J]. 中国电力, 2024, 57(9): 156 – 168.

ZHANG Yumin, ZHANG Yongchen, YE Pingfeng, et al. Enhanced kernel ridge regression and ensemble empirical mode decomposition based distribution network state estimation [J]. Electric Power, 2024, 57(9): 156 – 168.

- [30] 赵程栋, 庄继晖, 程晓鸣, 等. 基于特征注意力机制的RNN-Bi-LSTM 船舶轨迹预测[J]. 广东海洋大学学报, 2022, 42(5): 102 – 109.

ZHAO Chengdong, ZHUANG Jihui, CHENG Xiaoming, et

al. Ship trajectory prediction of RNN-Bi-LSTM based on characteristic attention mechanism [J]. Journal of Guangdong Ocean University, 2022, 42(5): 102 – 109.

收稿日期: 2024-06-19; 网络首发日期: 2024-12-13

作者简介:

张程(1982), 男, 通信作者, 教授, 博士, 研究方向为电力系统稳定性分析运行, zhangcheng@fjut.edu.cn;

林锦平(1999), 男, 硕士研究生, 研究方向为电力系统状态估计, 1697793012@qq.com。

(上接第 9 页 Continued from Page 9)

- [22] LI W, GREGOIRE L A, BELANGER J. A modular multilevel converter pulse generation and capacitor voltage balance method optimized for FPGA implementation[J]. IEEE Transactions on Industrial Electronics, 2015, 62(5): 2859 – 2867.

- [23] 程启明, 张梁, 王为涛, 等. 模块化多电平矩阵变换器的桥臂均压控制策略[J]. 南方电网技术, 2025, 19(12): 1 – 10, 31. CHENG Qiming, ZHANG Liang, WANG Weitao, et al. Bridge arm voltage equalization control strategy for modular multilevel matrix converter [J]. Southern Power System Technology, 2025, 19(12): 1 – 10, 31.

- [24] 马荣波. MMC 最近电平逼近调制分析及仿真[J]. 电子测试, 2021(8): 37 – 38, 59. MA Rongbo. Analysis and simulation of MMC nearest level approximation modulation [J]. Electronic Test, 2021(8): 37 – 38, 59.

- [25] 程启明, 马信乔, 江畅, 等. 模块化多电平矩阵变换器输入侧的无源控制策略[J]. 电力系统自动化, 2021, 45(11): 136 – 143.

CHENG Qiming, MA Xinqiao, JIANG Chang, et al. Passive control strategy for the input side of modular multilevel matrix converter[J]. Automation of Electric Power Systems, 2021, 45(11): 136 – 143.

收稿日期: 2025-01-05; 网络首发日期: 2025-03-26

作者简介:

程启明(1965), 男, 教授, 博士, 研究方向为新型发电过程控制、电力电子控制和微电网控制, chengqiming@sina.com;

张磊(1988), 男, 工程师, 硕士, 研究方向为电力市场运行与营销、新能源发电技术, shryam@163.com;

张梁(1999), 通信作者, 男, 硕士研究生, 研究方向为新能源发电控制、电力电子控制和电机控制, 2642036182@qq.com。

广 告

电网仿真重点实验室……………封二
南方电网科技创新中心……………封三
南网知识星球……………A1

南方电网电力科技股份有限公司……………A2
正泰电气股份有限公司……………A3
中电普瑞电力工程有限公司……………A4