

数据驱动的无精确建模含源配电网无功运行优化

顾洁, 孟璐, 朱瞳彤, 刘书琪, 金之俭

(上海交通大学 电子信息与电气工程学院 大数据工程技术研究中心, 上海 200240)

摘要:分布式光伏的接入使得配电网无功电压运行控制需求及解决措施与传统配电网差异较大。针对配电网测量设备安装不全、网架参数难以准确获取,无法进行精确数学建模的问题,提出了无精确建模的含分布式光伏的配电网电压优化控制模型。以节点电压合格为优化目标,使用高速公路神经网络拟合网架节点注入功率与关键节点电压之间的映射关系;考虑分布式光伏的出力约束,进而采用定向寻优策略和反馈机制对优化模型进行求解;通过改变分布式电源逆变器出力来控制电网电压,实现全局系统电压控制。以不同规模的配电网实际数据为例,验证了所提优化运行控制模型的有效性。对比分析了采用普通神经网络和高速公路神经网络的电压拟合精度及收敛速度,证明高速公路神经网络应用于解决无精确建模的多节点含源配电网无功运行问题,可以实现拟合精度和拟合速度的双重优化。

关键词:配电网;数据驱动;分布式光伏;无功运行优化;高速公路神经网络

中图分类号:TM 712

文献标志码:A

DOI:10.16081/j.epae.202011031

0 引言

随着配电网规模扩大、结构复杂化,10 kV及以下电压等级配电网因难以获取完整的结构与运行参数,无法进行精确的建模。同时,配电网高级量测体系(AMI)的建设使得配电网运行中时刻都会有海量数据生成及采集入库,为使用数据驱动方法进行配电网无功优化研究及应用提供了可能。

配电变电站无功电压控制的目标是有效保障节点电压的稳定性,主要控制对象有3类:传统的并联电容器、有载调压抽头(OLTC)等;新型无功补偿设备,如分布式储能装置和静止同步补偿器(STATCOM)等;具有无功调节能力的分布式光伏。

在操作实践中,传统的电容器投切和OLTC调节有一个明显缺点:其切换频率受到严格限制,且只能整组投切,可能会造成过/欠补偿。STATCOM虽然投切方便且控制精准,但需额外安装而且价格不菲。接入电网的可再生能源发电装置,如光伏逆变器等,自身具有无功控制功能,可以为电网电压提供支撑。由于分布式光伏的无功控制并没有传统无功调节装置的频率限制和整组投切限制,响应速度快、灵活性强,因此成为含源配电网无功调节的一种新手段。

另一方面,目前配电网信息化建设程度良莠不齐,特别是对于中低压配电网,数据采集系统覆盖率不高造成量测数据不够客观完整,大量伪量测数据的加入^[1]和数据采集过程中噪声污染的产生等导致

部分量测数据质量较低;此外,数据采集系统的量测没有统一的时标也导致采集到的数据所对应的时间断面有较大的差别^[2]。因此亟需利用数据挖掘等技术通过对采集到的局部数据进行处理与建模,得到具体的优化策略,从而实现对全局系统的控制。

神经网络在图像识别^[3]、自然语言处理^[4]、语音识别^[5]及其他领域取得了很多成果。尤其是近几年兴起的深层神经网络,实现了拟人脑的高层抽象信息提取,挖掘数据中蕴含的深层逻辑关系和信息。文献[6]利用神经网络建立人工智能辅助决策模型,对光伏调控量粗略计算模型进行修正,提高了电网优化调控精度。文献[7]通过神经网络进行日前无功负荷预测,进一步实现无功潮流的优化调度。虽然神经网络通过拟合输入与输出之间的关系克服了通信条件和建模精度的限制,让无功优化与系统精确建模过程剥离,但人工神经网络的物理解释问题和训练收敛问题依然没有得到很好的解决^[8-9]。人工神经网络在无功优化领域的研究仍处于初级阶段。

本文针对配电网(主要研究了中压配电网)遥测设备安装不全、网架参数难以获取、量测数据质量参差不齐,难以进行精确数学建模的问题,提出了无精确建模的含分布式光伏的配电网电压控制模型,以节点电压合格为优化目标,用深度高速公路神经网络拟合关键节点电压,在此基础上考虑分布式光伏出力的约束,对优化模型进行求解得到分布式光伏逆变器出力指令,实现全局系统电压控制。由于实际操作过程中,仅靠整组投切的电容器和OLTC调节装置不能实现无功的平滑补偿,需要加入连续补偿装置,造成补偿成本明显增加。本文提出的数据驱动的无功运行优化方法通过调节光伏逆变器的出力,在电容器和OLTC根据一定规则动作之后仍然

收稿日期:2020-06-08;修回日期:2020-09-25

基金项目:国家重点基础研究计划项目(2016YFB0900100);上海市科委科研计划资助项目(18DZ1100303)

Project supported by the National Key Research Program of China(2016YFB0900100) and the Project Funded by Shanghai Science and Technology Commission(18DZ1100303)

未达到无功平衡的情况下实现对无功的连续补偿,实现了灵活调节与经济性的平衡。

1 无精确建模的含源配电网电压控制模型

针对无精确建模的含分布式光伏的中低压配电网,本节分析了分布式光伏调压原理,并借鉴输电网中二级电压控制模型提出了无精确建模的含源配电网无功电压控制模型。

1.1 光伏逆变器参与无功调压原理

光伏逆变器可以利用无功输出对电网起到电压支撑的作用。光伏逆变器容量往往设计为光伏额定装机容量的1.1倍^[10],其无功可调范围与逆变器容量之间的关系为:

$$Q_{PV}^2 + P_{PV}^2 \leq S_{PV}^{\max} \quad (1)$$

其中, Q_{PV} 、 P_{PV} 分别为光伏逆变器输出无功和有功实际值; $S_{PV}^{\max}$ 为逆变器额定容量。

光伏逆变器无功容量调节范围示意图如图1所示。图中, A 点对应光伏额定有功功率 $P_{PV}^{\max}$, 在逆变器最大容量输出的情况下, 对应无功为 $-Q_{PV}^{\max, 1}$ 和 $Q_{PV}^{\max, 1}$; B 点对应光伏实际功率 P_{PV}^{cut} , 在逆变器最大容量输出的情况下, 对应无功为 $-Q_{PV}^{\max, 2}$ 和 $Q_{PV}^{\max, 2}$ 。因此逆变器无功调节范围为 $[-Q_{PV}^{\max, 2}, -Q_{PV}^{\max, 1}] \cup [Q_{PV}^{\max, 1}, Q_{PV}^{\max, 2}]$ 。




图1 光伏逆变器P-Q容量示意图

Fig.1 Diagram of photovoltaic inverter P-Q capacity

参考文献[11], 得出调节光伏逆变器对电网无功电压影响的基本规律如下:

(1) 逆变器输出功率的改变首先影响接入节点电压, 再通过潮流影响全局电压;

(2) 逆变器输出功率对电网的节点电压分布的影响随着光伏接入点与平衡节点之间距离的增大而减小, 越靠近平衡节点, 分布式光伏出力的改变对全局电压的影响越小, 反之越大;

(3) 逆变器以滞后功率因数运行时抬高接入点电压, 以超前功率因数运行时降低接入点电压;

(4) 逆变器输出功率越大、功率因数越小, 对电网节点电压分布的影响越大。

1.2 输电网二级电压控制模型

输电网二级电压控制模型^[12]的核心为电网电压

集中式控制方式, 保证各节点电压符合运行要求。在先导节点位置处安装集中控制器, 通过控制全局的其他无功装置维持先导节点电压稳定。先导节点电压偏移为0时, 全网各节点电压偏移最小。模型的数学表达式为式(2), 即通过控制无功补偿装置出力保证全网节点电压在电压波动范围内。

$$\begin{cases} \varepsilon_s = \min(\max(V_p - V_{\max}^{\text{ref}}, 0) + \max(V_{\min}^{\text{ref}} - V_p, 0)) \\ V_p = f(P_{PV}, Q_{PV}, P_o, Q_o, \theta) \\ P_{PV} = [P_{PV, 1}, \dots, P_{PV, i}, \dots, P_{PV, m}] \\ Q_{PV} = [Q_{PV, 1}, \dots, Q_{PV, i}, \dots, Q_{PV, m}] \end{cases} \quad (2)$$

$$\text{s.t.} \begin{cases} Q_{PV}^{\min} \leq Q_{PV, i} \leq Q_{PV}^{\max} \\ P_{PV}^{\min} \leq P_{PV, i} \leq P_{PV}^{\max} \\ Q_{PV, i}^2 + P_{PV, i}^2 \leq S_{PV}^{\max} \end{cases} \quad (3)$$

其中, ε_s 为电压偏差衡量指标; V_p 为先导节点电压, V_p 为其幅值; $P_{PV, i}$ 、 $Q_{PV, i}$ 分别为第 i 个光伏逆变器接入节点的有功负荷和无功负荷, 全网 m 个光伏逆变器接入节点的负荷组成向量 P_{PV} 和 Q_{PV} ; P_o 、 Q_o 分别为其他节点的有功负荷和无功负荷向量; θ 为节点电压的相角向量; $Q_{PV}^{\max}$ 、 $Q_{PV}^{\min}$ 分别为光伏逆变器输出无功的上、下限; $P_{PV}^{\max}$ 、 $P_{PV}^{\min}$ 分别为光伏逆变器输出有功的上、下限; $V_{\max}^{\text{ref}}$ 、 $V_{\min}^{\text{ref}}$ 分别为允许电压的上、下限。

将输电网二级电压控制模型直接应用于无精确建模的含源配电网中存在如下局限性:

(1) 我国中低压配电网一般呈辐射状运行, 分布式光伏的接入加剧了配电网电压分布的复杂性, 因此难以使用1个节点代表整个网络的电压情况;

(2) 建立我国中低压配电网网架精确数学模型的难度较大, 无法确定先导节点位置;

(3) 在无精确建模的含源配电网中, 难以通过潮流计算得到节点有功、无功数据与配电网电压之间的关系, 即 $V_p = f(P_{PV}, Q_{PV}, P_o, Q_o, \theta)$ 无法求解。

因此, 需对输电网二级电压模型进行改进以有效应用于配电网中, 在光伏逆变器输出功率的限制下实现配电网无功调压。

1.3 无精确建模的含源配电网电压控制模型

基于上述分析, 对输电网二级电压控制模型做出如下改进, 以得到无精确建模的含源配电网电压控制模型。

(1) 在含分布式光伏的城市配电网中, 分布式光伏并网点电压波动性较大, 而线路末端电压容易出现电压不合格的现象。类比输电网二级电压控制方法中的先导节点概念, 选择分布式光伏并网点和线路末端节点作为系统保持电压稳定的关键节点, 若关键点电压不超过电压波动允许上、下限, 则全网节点电压一般也不会超过电压波动允许上、下限。

(2)在无精确建模的配电网中,无法通过潮流计算得到关键节点电压。因此本文构建基于高速公路神经网络的电压拟合模型,通过训练高速公路神经网络得到关键节点电压。

潮流方程可以用以下函数关系表示^[13]:

$$f(P, Q, \theta, V) = 0 \quad (4)$$

其中, P 、 Q 和 V 分别为节点的有功向量、无功向量和节点电压的幅值向量。

雅可比矩阵 $J = \frac{\partial f}{\partial [\theta, V]}$,且 J 是可逆的。根据隐函数定理,存在从 P 、 Q 到 V 的唯一且连续可微函数:

$$V = g(P, Q) \quad (5)$$

在网架结构确定的情况下, P 、 Q 与 V 间的函数关系唯一确定。文献[14]提出,对于任意的有限输入,提供足够多的隐藏单元,标准多层神经网络是一个通用的函数逼近器,可对函数及其导数进行任意精确的逼近,因此可用深度神经网络拟合关键节点电压与节点负荷间的函数关系(简称电压拟合模型)。

无精确建模的含源配电网电压控制模型表达式如下(约束条件同式(3)):

$$\begin{cases} \varepsilon_s = \min \left(\sum_{k=1}^n \left(\max(V_k - V_{\max}^{\text{ref}}, 0) + \max(V_{\min}^{\text{ref}} - V_k, 0) \right) \right) \\ V = g(P, Q) \\ P_{\text{PV}} = [P_{\text{PV},1}, \dots, P_{\text{PV},i}, \dots, P_{\text{PV},m}] \\ Q_{\text{PV}} = [Q_{\text{PV},1}, \dots, Q_{\text{PV},i}, \dots, Q_{\text{PV},m}] \\ V_{\text{key}} = [V_1, \dots, V_k, \dots, V_n] \end{cases} \quad (6)$$

其中, V_k 为第 k 个关键节点的电压; V_{key} 为 n 个关键节点电压构成的向量。

2 基于高速公路神经网络的电压拟合模型

2.1 高速公路神经网络

大量的理论与经验证据表明,深度是神经网络成功学习数据之间关系的关键因素之一^[15]。随着神经网络隐含层深度的增加,梯度消失和梯度爆炸现象阻碍了网络的收敛。因此简单的堆叠隐含层层数无法实现提高拟合精度的目标。

Rupesh Kumar Srivastava于2015年提出了高速公路神经网络框架^[16],借鉴了长短期记忆(LSTM)循环神经网络中的“遗忘门”结构,使用自适应门控单元控制神经网络前馈网络的结构,门控单元允许信息沿着某些路径时可以跨层畅通无阻地流动。高速公路神经网络这种层级连接方式为Shortcut连接,也可以认为是一条“信息高速公路”。

普通前馈神经网络一般有 L 层,其中第 l ($l \in \{1, 2, \dots, L\}$)层实现了 X 输入非线性函数 $H(X, W_l)$ 并生成其输出 y_l 。

$$y_l = H(X, W_l) \quad (7)$$

其中, W_l 为普通神经网络权重参数。

高速公路神经网络定义了2个自适应门控单元:转换门 $T(X, W_T)$ 和便携门 $C(X, W_C)$ 。其输出可由下式确定:

$$y_l = H(X, W_l) \cdot T(X, W_T) + X \cdot C(X, W_C) \quad (8)$$

其中, W_T 和 W_C 分别为转换门和便携门的网络权重参数。

经过转换门的信息需要经过普通前馈神经网络非线性函数 $H(X, W_l)$ 变换,经过便携门的信息不需要经过非线性函数变换,无衰减地通过“信息高速公路”流动。为了简化神经网络参数,文献[16]在高速公路神经网络模型框架中简化定义 $C=1-T$,则式(8)可以简化为:

$$y_l = H(X, W_l) \cdot T(X, W_T) + X \cdot (1 - T(X, W_T)) \quad (9)$$

显然,高速公路神经网络模型是普通神经网络的改进模型,当 $T(X, W_T)=1$ 时,高速公路神经网络退化成普通神经网络;当 $T(X, W_T)=0$ 时,高速公路神经网络信息不经过任何处理直接传递,实现了跳层传递。

当隐含层层数较少时,普通神经网络可以表现出非常好的性能,但是当隐含层数目增加时,高速公路神经网络的收敛速度明显快于普通神经网络;同时,高速公路神经网络在神经网络层数较多时能够达到更加精确的拟合效果。

2.2 基于高速公路神经网络的电压拟合模型

在网架确定的情况下,关键节点电压与节点负荷之间存在唯一的映射关系(见式(5)),因此本节搭建高速公路神经网络拟合该函数关系。高速公路神经网络模型由输入层、隐含层和输出层3层构成。

(1)输入层。

对于一个有 $N+1$ 个节点(含平衡节点)、 s 条线路的配电网网架,其中 m 个节点安装了分布式光伏,高速公路神经网络的输入神经元个数为 $2N$,即:

$$X = [P_{\text{PV},1}, \dots, P_{\text{PV},m}, P_{\text{PQ},1}, \dots, P_{\text{PQ},N-m}, Q_{\text{PV},1}, \dots, Q_{\text{PV},m}, Q_{\text{PQ},1}, \dots, Q_{\text{PQ},N-m}] \quad (10)$$

其中, $P_{\text{PQ},i}$ 、 $Q_{\text{PQ},i}$ ($i=1, 2, \dots, N-m$)分别为第 i 个未接入分布式光伏节点的有功功率和无功功率。

(2)隐含层。

附录中图A1对比了普通神经网络和高速公路神经网络隐含层信息传递过程。

在普通神经网络中,激活函数 $\sigma(x)$ 的数学模型可以表示为:

$$a^l = \sigma(wa^{l-1} + b) \quad (11)$$

其中, l 为网络层数标记; a^{l-1} 为输入信息; a^l 为输出

信息; w 为隐含层参数; b 为隐含层偏置量。

在高速公路神经网络中,激活函数 $\sigma(x)$ 的数学模型可以表示为:

$$\begin{cases} a^l = \sigma(x) = za^{l-1} + (1-z)h \\ h = \sigma_h(w_h a^{l-1} + b_h) \\ z = \sigma_T(w_T a^{l-1} + b_T) \end{cases} \quad (12)$$

其中, z 为门控单元函数; h 为隐含层输出; $\sigma_h(x)$ 为隐含层神经元激活函数; $\sigma_T(x)$ 为门控单元激活函数; w_h 为神经元权值参数; b_h 为神经元偏置参数; w_T 为门控单元的权值参数; b_T 为门控单元的偏置参数。

隐含层神经元激活函数选择relu激活函数 $f_{\text{relu}}(x)$,偏置参数 b_h 取0.1。

$$\sigma_h(x) = f_{\text{relu}}(x) = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (13)$$

门控单元激活函数选择sigmoid激活函数 $f_{\text{sigmoid}}(x)$,门控单元的偏置参数 b_T 初始化为-0.1,门控单元偏置参数初始化为负值是为了减小sigmoid激活函数值,使网络初始化时可以从“高速公路通道”直接传递更多信息。

$$\sigma_T(x) = f_{\text{sigmoid}}(x) = \frac{1}{1 + e^{-x}} \quad (14)$$

门控单元函数控制Shortcut连接:当 $z=0$ 时,当前隐含层退化为普通神经网络隐含层;当 $z=1$ 时,信息可以跳层传递,即自动消除该层。因此高速公路神经网络隐含层实际层数是自动优化的。

(3)输出层。

输出数据为 n 个关键节点的电压,因此输出神经元个数为 n 。

$$Y = [V_1, \dots, V_k, \dots, V_n] \quad (15)$$

输出层使用identity激活函数 $f_{\text{identity}}(x)$ 。

$$y = f_{\text{identity}}(x) \quad (16)$$

基于高速公路神经网络的电压拟合模型示意图如附录中图A2所示。由图可知,基于高速公路神经网络的电压拟合模型的输入为节点有功负荷和无功负荷数据,输出为关键节点电压数据,通过梯度下降方法优化神经网络参数 W ,拟合输入与输出之间的映射关系。

3 无精确建模的含源配电网电压控制模型求解

本文通过深度继承思想训练基于高速公路神经网络的电压拟合模型,采用定向寻优和反馈方法求解配电网电压控制模型(见式(6))得到分布式光伏出力指令,实现无精确建模的含源配电网无功优化运行。

3.1 高速公路神经网络电压拟合模型训练

考虑到城市配电网负荷场景多样,高速公路神经网络电压拟合模型需要不断更新以保证模型持续有效。若利用全部历史数据对模型进行重新训练则耗时漫长,本文借鉴深度继承^[17]的思想训练基于高速公路神经网络的电压拟合模型。

基于高速公路神经网络的电压拟合模型的训练流程如附录中图A3所示。首先用历史数据训练电压拟合基础模型;定期收集新的运行数据,进行预处理后形成新生样本集,使用新生样本集对电压拟合模型进行进一步训练,修正电压拟合模型内部参数,在初始模型基础上进行模型更新。根据配电网实时要求,新采集到的有效数据积累到初始模型训练数据的10%,或在地区网架模型改变(如新增配电线路或者变电站增容扩建)时启动模型更新。

3.2 无精确建模的含源配电网电压控制方法实现

以更新后的高速公路神经网络模型为基础,保持模型参数不变,利用定向寻优策略和反馈控制输出配电网中分布式光伏的出力指令。无精确建模的含源配电网电压控制流程图如附录中图A4所示。首先在比较器中输入电压合格区间,将当前时刻实际关键节点电压输入比较器,若全网关键节点电压均合格,则不输出分布式光伏出力修正指令;若出现电压越限情况,通过定向寻优改变分布式光伏出力,将当前负荷数据和分布式光伏模拟指令作为输入通过高速公路神经网络电压拟合模型,输出关键节点电压,返回比较器直到所有关键节点电压均合格,输出当前 Q_{PV} 、 P_{PV} 信号指令传送给全网分布式光伏。

无精确建模的含源配电网电压控制模型控制目标为式(6),其物理描述为所有关键节点电压均不超过电压上、下限,控制对象为有无功调压能力的分布式光伏机组。分布式光伏并网运行通过改变配电网潮流大小和方向进行电压调节。

根据光伏逆变器调压基本规律设计指令定向寻优策略,由以下7个规则描述。

(1)判断电压是否越限,若所有节点电压均不越限,保持上一次输出的出力指令。

(2)只改变电压越限点同一条出线上的分布式光伏出力。

(3)遵从“由近及远”的优先级顺序:先改变离电压越限点较近的分布式光伏出力,再改变较远的分布式光伏出力。

(4)遵从“先无功再有功”的优先级顺序:为了保证分布式光伏消纳率,先改变分布式光伏无功出力,再改变分布式光伏有功出力。

(5)遵从“先严重再轻微”的优先级顺序:始终以电压偏离上下限最多的节点作为调节的目标节点。

(6)遵从“先末端再始端”的优先级顺序:对离电

压越限节点距离相近的分布式电源,先调节靠近线路末端的分布式电源。

(7)若节点电压越上限,通过减少分布式光伏无功输出和有功输出的方式来降低电压;若电压越下限,通过增加分布式光伏无功输出和有功输出的方式来提高电压。

综合上述指令定向寻优策略,无精确建模的含源配电网电压控制模型求解流程图见附录中图 A5。

3.3 无精确建模的含源配电网电压控制方法检验

本文所提配电网电压控制模型的输出结果为 P_{PV} 、 Q_{PV} ,忽略信息传递时间和分布式光伏逆变器实际出力误差,若基于高速公路神经网络的电压拟合模型有效,则实际电网量测关键节点电压 V_r 与基于高速公路神经网络的电压拟合模型输出 V_{cal} 的差值 ε_{net} 应在工程允许范围内。若无精确建模的配电电压控制模型有效,则式(6)中 ε_s 应等于 0。本文将采用此判据对模型效果进行检验,检验示意图如图 2 所示,图中 $g(\cdot, W)$ 为神经网络传递函数。




图2 无精确建模的含源配电网电压控制模型检验示意图

Fig.2 Schematic diagram of testing voltage control model in source distribution network without accurate modeling

4 算例与分析

4.1 算例说明

算例设计主要包括网架电气结构设计和负荷设计,算例网架在真实网架基础上增加了分布式光伏。

4.1.1 算例网架

算例网架选取如图 3 所示的某示范区电网,该电网以单辐射架空线路为主,电缆化率较高,假定在节点 4、8、11、18、21 处加入分布式光伏。假定分布式光伏额定容量为 1 500 kW,额定功率因数为 0.95,




图3 地区 10 kV 配电网结构图

Fig.3 Structure diagram of a regional 10 kV distribution network

逆变器视在功率为 2 000 kV·A。

4.1.2 算例负荷

所有负荷的负荷需求点使用 SCADA 系统中记录的实际网架负荷。典型的分布式光伏日出力曲线见附录中图 A6。夏季日照时间长,日照强度大,光伏出力大;冬季日照时间短,日照强度低,光伏出力小。夜间光伏不出力,正午日照最强烈时出力最大。

由于算例网架在实际网架基础上进行了改进,无法使用历史数据训练高速公路神经网络。由负荷数据通过潮流计算得到电压数据,代替实际电网量测系统中存储的历史负荷和电压数据。基于高速公路神经网络的电压拟合模型训练数据包括 2018 年节点有功数据、无功数据、关键节点电压数据,共 35 040 条数据,其中 70 % 的数据作为训练集,30 % 的数据作为测试集。

4.2 基于高速公路神经网络的电压拟合模型训练结果

本文使用 tensorflow 训练高速公路神经网络,采用随机梯度下降法训练高速公路神经网络参数,降低测试集拟合误差 ε_{net} 。

高速公路神经网络代码训练环境为 8 核 gtx1080 GPU 服务器。设训练样本数为 50,学习速率为 0.01。损失函数为均方误差(MSE),其表达式如下:

$$\delta_{MSE}(V_r, V') = \frac{\sum_{i=1}^n (V_{ri} - V'_{i})^2}{n} \quad (17)$$

其中, V_r 为节点电压实际值向量; V' 为节点电压预测值向量; V_{ri} 、 V'_{i} 分别为第 i 个关键节点的电压实际值和预测值。

图 4 为损失函数曲线(图中平均误差为标幺值,后同)。当已知所有节点数据时,高速公路神经网络经 800 次迭代后收敛,普通神经网络经 2 000 次左右的迭代后收敛,且拟合效果不如高速公路神经网络。当已知部分节点数据时,高速公路神经网络和普通神经网络经 2 000 次左右的迭代后收敛,但高速公路神





图4 神经网络训练损失函数曲线

Fig.4 Curve of training loss function by neural network

经网络的拟合效果更优。已知全部节点数据时高速公路神经网络在测试集上的测试误差为 6×10^{-6} p.u., 平均到每个关键节点, 其误差为 3×10^{-4} p.u.; 已知部分节点数据时高速公路神经网络在测试集上的测试误差为 1.61×10^{-5} p.u.。工程需求均得到满足。

本算例网架结构相对简单, 高速公路神经网络与普通神经网络均能在工程允许误差范围内拟合。

为了验证高速公路神经网络模型在拟合无功调压函数方面的优越性, 本文使用 IEEE 69 节点及仿真数据进行训练, 损失函数对比曲线如图 5 所示。




由图 5 可以看出, 随着深度的增加, 普通神经网络的优化变得更加困难, 而 100 层的高速公路神经网络可以仍然可以实现更好的优化精度。另外, 使用 IEEE 69 节点数据训练高速公路神经网络模型花费的时间在 1 min 以内, 满足实时性要求。因此在节点较多的配电网中, 高速公路神经网络可以得到更快的收敛速度以及更好的优化精度。

4.3 电压控制效果

为了验证本文所提出的基于高速公路神经网络的无功调压方法的有效性, 模拟了正午和凌晨 2 个场景, 比较恒功率因数的分布式光伏跟踪最大功率控制模型 S_1 和基于高速公路神经网络的无功电压调节模型 S_2 的控制效果。


图 6 为 24 h 内馈线负荷变化曲线。由图可知, 凌晨时负荷处于较低水平, 正午时负荷明显增大。



4.3.1 场景 1

场景 1 为天气多云转晴, 各节点分布式光伏出力逐渐增大, 正午气温持续攀升, 负荷增大, 关键节

点 4 电压越上限, 分别采用 2 种模型的电压控制策略, 模型 S_1 和 S_2 关键节点电压分别如图 7 中实线和虚线所示, 图中电压为标幺值。模型 S_2 每 15 min 监测一次全网电压, 若电压有越限情况, 则通过反馈调节输出分布式光伏出力指令。



由图 7 可见, 模型 S_2 在 13:30 时检测到电压越限之后, 下发参考功率指令, 在电网运行状态的可行域范围内优化了分布式光伏无功出力。电网变电站母线电压合格区间为 $[0.95, 1.05]$ p.u., 可见模型 S_2 的电压相比 S_1 更加稳定。场景 1 中网损变化曲线如图 8 所示, 表明模型 S_2 的网损更低。场景 1 中分布式光伏的具体调整策略如表 1 所示。

以节点 4 为例介绍场景 1 在 13:30 时检测到电压越上限后, 基于高速公路神经网络的无功电压




表1 场景1中分布式光伏出力的调整策略

Table 1 Adjustment strategy of distributed photovoltaic output under Scenario 1

时刻	分布式光伏出力 / kvar				
	节点4	节点8	节点11	节点18	节点21
13:30	-j930	-j767	-j398	-j314	-j521
13:45	-j930	-j767	-j308	-j414	-j521
14:00	-j891	-j656	-j478	-j407	-j513
14:15	-j825	-j693	-j398	-j410	-j596
14:30	-j926	-j959	-j543	-j423	-j594

调节策略:13:30和13:45时,分布式光伏发出感性无功930 kvar;14:00时,分布式光伏发出感性无功891 kvar;14:15时,分布式光伏发出感性无功825 kvar;14:30时分布式光伏发出感性无功926 kvar。

4.3.2 场景2

凌晨至日出,各分布式光伏出力由0逐渐增大,负荷较低,多个关键节点电压都发生越上限的情况,分别采用2种模型的电压控制策略,模型 S_1 和 S_2 关键节点电压分别如附录中图A7实线和虚线所示,网损变化曲线如图A8所示。模型 S_2 在07:00时下发一个新的参考功率指令,由于电网电压整体偏高,出现了无功调节容量不足的问题,因此策略下发指令不仅包括无功修正指令,而且包括有功修正指令,对于部分不上网的有功功率,可以利用储能进行存储。由图A7和图A8可知,基于高速公路神经网络的无功调压方法在稳定电压和降低网损方面有一定的优越性。场景2中分布式光伏出力的具体调整策略见附录中表A1。

仍以节点4介绍场景2在06:45时检测到电压越上限后,基于高速公路神经网络的无功电压调节策略:06:45时,节点4分布式光伏仅发出感性无功1839.1 kvar;07:00以后,电网整体电压偏高,无功调节容量不足,分布式光伏需要同时改变无功出力和有功出力,故07:00时,分布式光伏吸收有功102.36 kW并发出感性无功1934.16 kvar。

本节通过构建2种场景,验证了所提出的无功电压优化方法能够实现全网电压调控和有效降低网损的功能。对于训练好的高速公路神经网络,其配电网的无功指令寻优计算时间可以忽略不计,因此可以有效应用于实际电网的电压调节。

5 结论

本文针对无法精确建模的10 kV配电网,提出了一种基于高速公路神经网络的数据驱动的无功电压优化方法。该方法以系统历史运行数据作为训练数据来训练高速公路神经网络,拟合关键节点电压,并设计了一套简单实用的无功指令寻优策略。

(1)基于高速公路神经网络的无功运行优化方法具有以下特点:该模型无需复杂的物理计算和数

学建模,通过历史数据训练高速公路神经网络来输出关键节点电压;配电网模型实际上是一个庞大的非线性系统,数据驱动的方法避免了建模时过度简化造成的模型误差,实现了没有精确数学模型的情况下的无功优化;无功指令寻优基于反馈调节输出配电网分布式光伏的出力指令,其控制逻辑简单实用,可以迅速输出分布式光伏出力指令,调节全局电压。

(2)以不同规模的配电网实际数据为例,对比分析采用普通神经网络和高速公路神经网络的电压拟合精度和收敛速度,证明了神经网络深度越深则训练精度越高,高速公路神经网络适用于多节点配电网,可以实现拟合精度和拟合速度的双重优化。

(3)通过2个场景模拟进行连续潮流仿真,证明了基于高速公路神经网络的无功电压控制模型不依赖复杂数学建模,不对电力系统进行物理简化,定向寻优过程简单有效,可以有效实现全网电压的调控并降低网损。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 陈瑛. 基于不确定量测信息的配电网状态估计方法研究[D]. 天津:天津大学,2018.
CHEN Ying. Research on distribution system state estimation based on uncertain measurement information[D]. Tianjin:Tianjin University,2018.
- [2] 赵红嘎,薛禹胜,高翔,等. 量测量的时延差对状态估计的影响及其对策[J]. 电力系统自动化,2004,28(21):12-16.
ZHAO Hongga,XUE Yusheng,GAO Xiang,et al. Impacts of the difference between measurement transmission delays on state estimation and the countermeasures[J]. Automation of Electric Power Systems,2004,28(21):12-16.
- [3] 王德文,李业东. 基于WGAN图片去模糊的绝缘子目标检测[J]. 电力自动化设备,2020,40(5):188-198.
WANG Dewen,LI Yedong. Insulator object detection based on image deblurring by WGAN[J]. Electric Power Automation Equipment,2020,40(5):188-198.
- [4] TOUTANOVA K,KLEIN D,MANNING C D,et al. Feature rich part-of-speech tagging with a cyclic dependency network[C]//Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology. Association for Computational Linguistics. Edmonton,Canada:[s.n.],2003:173-180.
- [5] SHEN H,SARKAR A. Voting between multiple data representations for text chunking[C]//Proceedings of the Conference of the Canadian Society for Computational Studies of Intelligence. Victoria,Canada:Springer Berlin Heidelberg,2005:389-400.
- [6] 窦晓波,蔡超,段向梅,等. 计及模型误差的分布式光伏配电网优化调控方法[J]. 电力自动化设备,2019,39(12):41-48.
DOU Xiaobo,CAI Chao,DUAN Xiangmei,et al. Optimal control method of distributed PV considering model errors in distribution network[J]. Electric Power Automation Equipment,2019,39(12):41-48.
- [7] 束娜,赵国生,周志勇,等. 基于负荷预测的变电站电压无功综合控制策略[J]. 电力系统及其自动化学报,2015,27(5):34-

- 38,50.
- SHU Na, ZHAO Guosheng, ZHOU Zhiyong, et al. Substations voltage and reactive power control strategy based on load forecasting[J]. Proceedings of the CSU-EPSA, 2015, 27(5): 34-38, 50.
- [8] GENG Guangfei, LIANG Jiaqi, HARLEY R G, et al. Load profile partitioning and dynamic reactive power optimization[C]//2010 International Conference on Power System Technology. Hangzhou, China: IEEE, 2010: 1-8.
- [9] HUANG Y, LI D, GAO L. Power system short-term load forecasting based on neural network with artificial immune algorithm[C]//IEEE Industrial Electronics Branch, IEEE Control System Association Harbin Branch; Editorial Department of Control and Decision Making. Shenyang, China: IEEE, 2012: 844-848.
- [10] LEC R M, MUSAVI M T, PENDSE H P, et al. Application of a radial basis function neural network to sensor design[J]. Proceedings of SPIE-The International Society for Optical Engineering, 1993, 1918: 440-448.
- [11] STETZ T, MARTEN F, BRAUN M. Improved low voltage grid-integration of photovoltaic systems in Germany[J]. IEEE Transactions on Sustainable Energy, 2013, 4(2): 534-542.
- [12] 裴晓娟. 分布式电源对配电网电压变化影响的研究[D]. 成都: 西南交通大学, 2011.
- PEI Xiaojuan. Impact of distributed generation on the change of voltage of distribution system[D]. Chengdu: Southwest Jiaotong University, 2011.
- [13] 代飞, 黄磊, 徐箭, 等. 基于二级电压控制的河南电网分区和主导节点选择[J]. 电力系统保护与控制, 2011, 39(24): 101-105.
- DAI Fei, HUANG Lei, XU Jian, et al. Voltage partitioning and pilot nodes selecting of Henan power grid based on secondary voltage control[J]. Power System Protection and Control, 2011, 39(24): 101-105.
- [14] DZAFIC I, JABR R A, HALILOVIC E, et al. A sensitivity approach to model local voltage controllers in distribution networks[J]. IEEE Transactions on Power Systems, 2014, 29(3): 1419-1428.
- [15] HORNIK K. Approximation capabilities of multilayer feedforward networks[J]. Neural Networks, 1991, 4(2): 251-257.
- [16] SRIVASTAVA R K, GREFF K, SCHMIDHUBER J. Highway networks[J]. Computer Science, 2015(7): 12-21.
- [17] AREL I, BERANT S. Application feedback in guiding a deep-layered perception model[C]//Biologically Inspired Cognitive Architectures 2010-Proceedings of the First Annual Meeting of the BICA Society. Washington DC, USA: [s.n.], 2010: 4-9.

作者简介:



顾洁

顾洁(1971—),女,江苏海安人,副教授,博士,主要研究方向为大数据与人工智能技术在电力系统中的应用、电力市场及电力系统优化规划(E-mail: gujie@sjtu.edu.cn);

孟璐(1997—),女,河南南阳人,硕士研究生,主要研究方向为大数据与人工智能技术在电力系统中的应用(E-mail: futuremeng@sjtu.edu.cn);

朱瞳彤(1995—),女,安徽芜湖人,硕士研究生,主要研究方向为电力系统优化规划(E-mail: xiaowo1822@sjtu.edu.cn)。

(编辑 李莉)

Data-driven optimization for reactive power operation in source distribution network without accurate modeling

GU Jie, MENG Lu, ZHU Tongtong, LIU Shuqi, JIN Zhijian

(Research Center for Big Data Engineering and Technologies, School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China)

Abstract: The access of distributed photovoltaic makes the requirement and solution of reactive power and voltage operation control for distribution network different from those of traditional distribution network. Aiming at the problems of incomplete installation of distribution network measurement equipment, difficulty in obtaining grid parameters accurately, and inability to carry out accurate mathematical modeling, a voltage optimization control model of distribution network with distributed photovoltaic is proposed without accurate modeling. Taking the qualified node voltage as the optimization goal, the highway neural network is used to fit the mapping between the injected power of grid nodes and the voltage of key nodes. Considering the output constraints of distributed photovoltaic, the directional optimization strategy and feedback mechanism are used to solve the optimization model. By changing the inverter output of distributed generation to control the grid voltage, the global system voltage control is realized. Taking the actual data of different scales of distribution networks as example, the effectiveness of the proposed optimal operation control model is verified. The voltage fitting accuracy and convergence speed of the common neural network and the highway neural network are compared and analyzed, which proves that the highway neural network can be used to solve the reactive power operation problem of the multi-node source distribution network without accurate modeling, and the double optimization of fitting accuracy and fitting speed can be realized.

Key words: distribution network; data-driven; distributed photovoltaic; reactive power operation optimization; highway neural network

附录




图 A1 普通神经网络和高速公路神经网络隐含层神经元信息传递对比图

Fig.A1 Comparison diagram of information transmission between ordinary neural network and hidden layer of highway neural network




图 A2 基于高速公路神经网络的电压拟合模型示意图

Fig.A2 Schematic diagram of voltage fitting model based on highway neural network




图 A3 基于高速公路神经网络的电压拟合模型训练流程图

Fig.A3 Training flowchart of voltage fitting model based on highway neural network




图 A4 无精确建模的含源配电网电压控制流程图

Fig.A4 Flowchart of voltage control for source distribution network without accurate modeling




图 A5 无精确建模的含源配电网电压控制模型求解流程图

Fig.A5 Solving flowchart of voltage control model in source distribution network without accurate modeling




图 A6 光伏日出力曲线

Fig.A6 Curve of photovoltaic power in a day





图 A7 场景 2 中关键节点电压变化曲线
Fig.A7 Voltage curve of critical bus under Scenario 2




Fig.A8 Curve of network loss under Scenario 2

表 A1 场景 2 下分布式光伏出力的调整策略

时刻	分布式光伏出力/kvar				
	节点 4	节点 8	节点 11	节点 18	节点 21
06:45	-j1 839.1	-j767.23	-j802.39	-j920.19	-j928.29
07:00	-102.36+(-j1 934.16)	-j663.25	-j701.17	-j916.59	-j1 020.36
07:15	-137.67+(-j1 829.43)	-j698.23	-j905.69	-j1 016.04	-j1 097.67
07:30	-154.97+(-j2 228.90)	-j964.42	-j1 004.15	-j915.95	-j898.97
07:45	-178.42+(-j2 032.95)	-j769.23	-j803.25	-j1 011.73	-j899.42