

基于一维卷积神经网络的电力系统 暂态稳定在线评估

齐放

(中国广核新能源控股有限公司, 北京 100000)

摘要:传统电力系统暂态稳定评估基于时域仿真计算,计算复杂度高,难以在线应用。提出一种基于一维卷积神经网络的电力系统暂态稳定在线评估,可极大提升暂态稳定在线评估速度。通过马尔可夫链蒙特卡洛抽样算法进行电力系统运行状态模拟,生成大规模运行数据。通过电力系统时域仿真计算确定发电机最大功角差。将电力系统运行数据作为一维卷积神经网络的输入,发电机最大功角差作为输出,训练一维卷积神经网络。在线应用场景下,一维卷积神经网络可基于当前运行数据快速计算发电机最大功角差,实现暂态稳定性在线评估。新英格兰39节点系统验证了所提在线评估算法的可行性。

关键词:电力系统;暂态稳定在线评估;一维卷积神经网络;马尔可夫链蒙特卡洛抽样算法;发电机最大功角差;新英格兰39节点系统

中图分类号:TM 721 文献标志码:A 文章编号:1003-6954(2021)04-0038-05

DOI:10.16527/j.issn.1003-6954.20210408

Online Transient Stability Assessment of Power System Based on One-dimensional Convolutional Neural Network

Qi Fang

(CGN New Energy Holdings Co., Ltd., Beijing 100000, China)

Abstract: Traditional transient stability assessment of power system is based on time domain simulation calculation, which has high computational complexity and is difficult to be applied online. An online transient stability assessment method based on one-dimensional convolutional neural network is proposed, which can greatly improve the speed of online transient stability assessment. Markov chain Monte Carlo sampling algorithm is used to simulate power system operation state and generate large-scale operation data. The maximum power angle difference of generator is determined by time domain simulation of power system. The operation data of power system is taken as the input of one-dimensional convolutional neural network, and the maximum power angle difference of generator is taken as the output to train the one-dimensional convolution neural network. In the online application scenario, one-dimensional convolutional neural network can quickly calculate the maximum power angle difference of generator based on the current operation data to realize online transient stability assessment. The New England 39 bus system verifies the feasibility of the proposed online evaluation algorithm.

Key words: power system; online transient stability assessment; one-dimensional convolutional neural network; Markov chain Monte Carlo sampling algorithm; maximum power angle difference of generator; New England 39 bus system

0 引言

近年来,由于暂态失稳所引发的电力系统事故时有发生,对社会和经济产生极大的危害。然而,传统电力系统暂态稳定计算基于时域仿真,包含复杂

的微分代数方程,在大电网中计算复杂,难以进行暂态稳定在线评估与风险预警^[1-4]。

近年来,机器学习技术被引入电力系统暂态稳定评估中,通过非线性方程替代复杂微分代数方程计算,加速暂态稳定评估速度,以满足在线应用需求。文献[5]提出了暂态稳定安全域的概念,并在

安全域下提出基于多支持向量机的综合电力系统暂态稳定评估方法,可减少暂态失稳场景的误判。文献[6]中离线数据通过相量测量单元 PMU 采集得到,并通过串行集成多棵回归树构建基于 XGBoost 的暂态稳定预测模型,实现暂态稳定特征重要度排序关系,提高了模型的可解释性。文献[7]将概率神经网络和径向基函数神经网络结合,形成复合神经网络,并用于故障临界切除时间裕度的预测,提升预测精度。文献[8]将深度置信网络作为黑盒模型拟合发电机出力和系统暂态稳定系数间映射关系,实现暂态稳定评估。文献[9]直接基于底层数据,将堆叠自动编码器引入电力系统暂态稳定评估中,采用“预训练-参数微调”的两阶段学习方法和稀疏化技术提升暂态稳定评估准确度。

下面提出一种基于一维卷积神经网络(one dimensional convolutional neural network, 1DCNN)的电力系统暂态稳定在线评估方法,将在图像学习中广泛应用的卷积神经网络(convolutional neural network, CNN)引入电力系统暂态稳定评估中,相较于传统神经网络方法,有更强的抽象拟合能力,并且 1DCNN 是传统 CNN 的一维形式,更适合电力系统数据的学习。

1 样本生成

1.1 马尔可夫链蒙特卡洛抽样

马尔可夫链是一个序列模型,其中数据样本之间存在依赖关系,且时刻 t 的状态概率只与前一时刻 $t-1$ 的状态有关。在马尔可夫链中有状态转移矩阵,状态概率矩阵本身通过一定次数的矩阵乘法后,转移矩阵每一行的概率会趋向于稳定的值,称为马尔可夫链的平稳分布,即^[10-12]:

$$P(x_i | x_{i-1}, x_{i-2}, \dots, x_1) = P(x_i | x_{i-1}) \quad (1)$$

$$\lim_{n \rightarrow \infty} P^n = \pi(x) \quad (2)$$

式中: P 为状态转移矩阵; x 为样本; π 为平稳概率分布; n 为转移次数,当接近无穷时, P 接近 π ,即达到平稳分布。

马尔可夫链蒙特卡洛抽样算法(Markov chain Monte carlo sampling algorithm, MCMC)是马尔可夫链和蒙特卡洛抽样的结合。设给定的初始样本为 x_0 ,根据马尔可夫链的收敛性质,经过一定次数的矩阵连乘后, x 的采样概率都会收敛到一个平稳分布,

设为 $\pi(x)$,则后续所有样本均服从概率分布 $\pi(x)$ 。MCMC 是从 x_{n+1} 开始的采样(设 n 为矩阵连乘次数):

$$\pi_{i+1}(x^*) = \int_x \pi_i(x) P(x^* | x) dx \quad (3)$$

式中, x^* 为新样本。 $\pi_{i+1}(x^*)$ 和 $\pi_{i+1}(x)$ 同分布。

实际中采用经典的 MCMC 采样的 Metropolis Hasting 算法进行采样:

1) 初始化:初始化 t_0 时刻样本为 x_0 ,所需抽样的样本总数为 M 。

2) 循环:

(1) 从均匀分布 $U(0, 1)$ 中采样 u ;

(2) 从概率分布 $q(x^* | x_i)$ 中采样样本 x^* ;

(3) 如果: $u < \min\left(1, \frac{\pi(x^*)q(x | x^*)}{\pi(x)q(x^* | x)}\right)$,

则 $x_{i+1} = x^*$, 否则 $x_{i+1} = x_i$;

(4) 当所生成样本数达到 M ,结束循环。

3) 结束:得到基于 MCMC 采样的 Metropolis Hasting 算法采样结果。

1.2 基于 MCMC 的电力系统运行数据生成

电力系统包括 PV 节点、PQ 节点和 V θ 节点,以电力系统潮流计算和时域仿真计算的初始参数为所需抽样的特征参数,因此所考虑的电力系统特征包括:发电机有功出力、发电机节点电压、有功负荷和无功负荷。根据所研究电力系统模型的特征,设置各个特征变量的取值范围,然后通过 MCMC 抽样算法抽样海量的电力系统运行数据。基于 MCMC 的抽样结果可以使电力系统特征在取值范围内分布更加均匀,增加样本的代表性,有助于提高 1DCNN 模型的泛化性能。

根据以往经验,对系统模型设置短路类型、故障位置以及故障切除时间,并执行时域仿真计算,得到对应的发电机最大功角差。最大功角差超出 180° 即视为失稳,否则认为系统稳定。若故障数量为 N ,则单个电力系统运行数据包括 N 个最大功角差,分别对应不同的故障^[13]。

2 基于 1DCNN 的暂态稳定评估

2.1 一维卷积神经网络

CNN 是一种前馈神经网络,它的人工神经元可以对一定覆盖范围内的输入特征进行响应,在大型图像处理中性能突出。CNN 由一个或多个卷积层、

线性整流层、池化层和顶端的全连通层组成。1DCNN 是 CNN 的一维形式,被普遍应用于序列数据识别中,更适合电力系统状态特征向量的识别,相比于传统神经网络方法,具有更高的拟合准确度和更好的泛化性能等优点^[14-16]。

1) 输入层

CNN 的输入层用于接收输入数据,其中 1DCNN 的输入层的输入参数为一维数据,在这里为发电机有功出力、发电机节点电压、有功负荷和无功负荷组成的向量。

2) 卷积层

卷积层的功能是对输入数据进行特征提取,内部包含多个卷积核,并且含有权重和偏置需要进行训练更新。卷积核比输入参数维度小,对于 1DCNN,卷积核也为一维,并且会在输入参数上进行滑动,对其范围内参数进行特征提取和映射,并且需要设置每次滑动步长。

3) 激活函数

对卷积层得到的特征进行非线性化处理,增加模型的拟合能力,常用的激活函数有 ReLU、Sigmoid 等。

$$\text{ReLU} = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (4)$$

$$\text{Sigmoid} = \frac{1}{1 + e^{-x}} \quad (5)$$

式中, x 为激活函数的输入。

所选用的激活函数为 ReLU 函数,如图 1 所示。




图 1 ReLU 函数

4) 池化层

池化层的作用是对数据进行降维,其会设定池化区域,在该区域内进行降维,常用的池化操作有:

(1) 最大值池化:在池化区域内取最大值作为最终的特征。

(2) 平均值池化:在池化区域内取均值作为最终的特征。

设滑动步长为 2,卷积核长度为 4,对长度为 9 的向量卷积结果如图 2 所示。

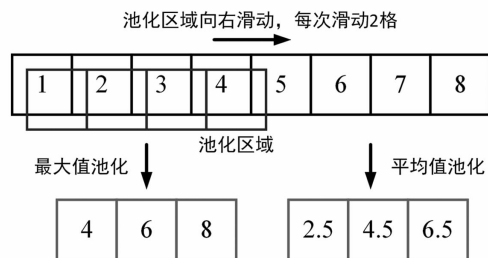


图 2 最大值池化和平均值池化

5) 全连接层

CNN 中的全连接层等价于传统前馈神经网络中的隐含层,包括前向传播和反向传播两部分。

前向传播中,数据从输入到输出,第 l 层的输出为

$$a_l = \sigma(z_l) = \sigma(W_l a_{l-1} + b_l) \quad (6)$$

式中: σ 为激活函数; W_l 为权重, b_l 为偏置; z_l 为未激活前输出; a_l 为输出。

反向传播由输出向输入传播,并逐层更新权重和偏置,更新的依据为 1DCNN 的正向输出结果和时域仿真计算结果的偏差,偏差的表达式为

$$J(W, b, x, y) = \frac{1}{2} \| a_l - y \|_2^2 \quad (7)$$

式中: x 为样本输入; y 为样本真值; J 为偏差。

J 对 W 和 b 求梯度为:

$$\frac{\partial J(W, b, x, y)}{\partial W_l} = \frac{\partial J(W, b, x, y)}{\partial z_l} \frac{\partial z_l}{\partial W_l} \quad (8)$$

$$\frac{\partial J(W, b, x, y)}{\partial b_l} = \frac{\partial J(W, b, x, y)}{\partial z_l} \frac{\partial z_l}{\partial b_l} \quad (9)$$

得到梯度后,使用随机梯度下降法更新 W 和 b ,减小偏差。

6) 输出层

输出层为 CNN 的最终输出结果,1DCNN 的最终输出结果为所有故障的最大功角差。

除此之外,在训练 1DCNN 的过程中使用了 L2 正则化仿真过拟合:

$$J(W, b) = \frac{1}{2m} \sum_{i=1}^m \| a_i - y \|_2^2 + \frac{\lambda}{2m} \sum_{j=1}^l \| w \|_2^2 \quad (10)$$

式中, λ 为 L2 正则化的超参数。

1DCNN 在 Tensorflow 框架上进行搭建,搭建好的 1DCNN 的模型如图 3 所示。

2.2 基于 1DCNN 的暂态稳定评估

1DCNN 模型搭建好之后,将 MCMC 产生的运




图 3 1DCNN 结果

行场景(发电机有功出力、发电机节点电压、有功负荷和无功负荷)作为 1DCNN 的输入参数,将所有故障的最大功角差作为输出参数,并对 1DCNN 进行训练,所提 1DCNN 结构如图 4 所示。




图 4 1DCNN 结构

以发电机最大功角差是否超过 180° 作为判断系统是否失稳的标准,并且只要有一个故障下的最大功角差超过 180° ,即认为系统失稳。因此准确度定义为 1DCNN 模型成功判断系统稳定性的百分比。

3 算例分析

3.1 测试系统

选取新英格兰 10 机 39 节点系统进行算例测试,该系统包括 39 个节点、10 台火力发电机、34 条输电线路、12 台两绕组变压器和 19 个负荷,该系统的示意图如图 5 所示^[17]。

3.2 电力系统运行数据仿真

设置发电机有功出力在基础出力的 $80\% \sim 120\%$ 、发电机节点电压的标幺值在 $0.95 \sim 1.1$ 、有功负荷和无功负荷均在 $80\% \sim 120\%$ 之间波动。通过 MCMC 算法抽样 5000 个样本,作为电力系统运行场景。

设置 39 节点系统的故障类型为输电线路三相短路故障,故障位置为线路中心,故障数量为 15 条输电线路,故障持续时间为 0.5 s ,在电力系统工具箱 PST 中进行时域仿真计算,得到不同故障下发电机的最大功角差,将其与对应的运行场景结合,作为

训练 1DCNN 的样本数据。

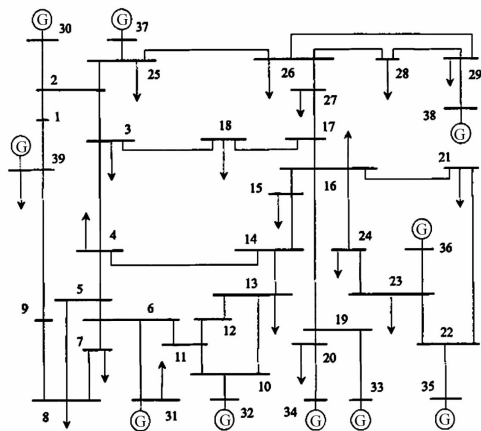


图 5 新英格兰 10 机 39 节点系统

3.3 基于 1DCNN 的暂态稳定评估结果

样本数据生成后,对 1DCNN 模型进行训练,将 MCMC 产生的运行场景(发电机有功出力、发电机节点电压、有功负荷和无功负荷)作为 1DCNN 的输入参数,输入参数的维度为 58;将所有故障的最大功角差作为输出参数,输出参数的维度为 15。设置输入层、卷积层、激活函数、池化层、全连接层和输出层数量各为 1,共 6 层。设置每批次训练样本数量为 500,训练次数为 100,训练集数量为 4000,测试集数量为 1000,对 1DCNN 进行训练,其在训练过程中的误差曲线如图 6 所示。




图 6 训练集损失曲线

从图 6 可以看出,随着训练迭代次数增加,损失逐渐降低,表明 1DCNN 实现了基于运行场景的暂态稳定拟合。

1DCNN 的准确率如图 7 所示。由图 7 可以看出,随着迭代周期的增加,1DCNN 的准确度持续增加,并且在末端保持在 90% 以上的准确度,表明所提算法实现了暂态稳定的准确评估。

训练好 1DCNN 模型后,可进行在线的暂态稳定评估,与传统基于时域仿真的暂态稳定评估相比,在评估速度上得到极大提升,评估时间对比如表 1 所示。




图 7 训练集准确率曲线

表 1 算法评估时间对比 单位:s

方法	单次故障时间	所有故障时间
基于时域仿真的暂态稳定评估	35	525
基于 1DCNN 的暂态稳定评估	0.1	0.1

从表 2 可以看出基于 1DCNN 的暂态稳定评估算法在计算时间上相较于传统时域仿真方法有极大提升,并且可以同时得到所有故障的暂态稳定评估结果,故障数量越多,算法在评估时间上的优势越明显。

最后,对比所提方法与其他文献方法的评估准确度,结果如表 2 所示。

表 2 评估准确度对比

模型	模型识别准确度/%
1DCNN	91.2
DBN	91.0
SVM	85.7
BP	88.9

从表 2 可以看出所提方法在准确度上明显优于其他方法,可以实现更加精准的电力系统暂态稳定评估。

4 结 语

上面提出了一种基于 1DCNN 的电力系统暂态稳定在线评估算法。该算法将 1DCNN 引入电力系统暂态稳定评估和安全风险辨识中,通过 MCMC 算法生成算例模型海量可能的运行场景,并通过时域仿真计算暂态稳定指标,通过 1DCNN 实现暂态稳定性能快速评估。并在新英格兰 10 机 39 节点系统中进行了算例验证,算例结果表明了所提算法的可行性和先进性。通过算例分析,得到如下结论:

1) 利用马尔科夫链和蒙特卡洛抽样算法结合的 MCMC 算法对电力系统运行场景进行抽样,所生成样本可以很好反映系统运行特征,提高 1DCNN

的泛化性能;

2) 将 1DCNN 引入电力系统暂态稳定评估中,将系统运行场景作为输入参数,将所有故障的最大功角差作为输出,对 1DCNN 进行训练,实现了基于 1DCNN 的电力系统暂态稳定快速评估,并且从算例结果可以看出所提算法评估时间满足在线应用的需求。

参考文献

- [1] 刘念,谢驰,滕福生. 电力系统安全稳定问题研究[J]. 四川电力技术,2004,27(1):1-6.
- [2] 周士琼,王倩,吕潇,等. 含大规模风电场电力系统暂态稳定性分析[J]. 四川电力技术,2016,39(5):9-13.
- [3] 刘挺坚,苟竞,胥威汀,等. 基于支路能量时空特征的电力系统暂态稳定性分析[J]. 四川电力技术,2017,40(1):9-13.
- [4] 陈振,韩晓言,范成围,等. 融合智能代理模型和改进微分进化算法的电力系统暂态稳定预防控制[J]. 四川电力技术,2019,42(4):1-6.
- [5] 戴远航,陈磊,张玮灵,等. 基于多支持向量机综合的电力系统暂态稳定评估[J]. 中国电机工程学报,2016,36(5):1173-1180.
- [6] 陈明华,刘群英,张家枢,等. 基于 XGBoost 的电力系统暂态稳定预测方法[J]. 电网技术,2020,44(3):1026-1034.
- [7] 姚德全,贾宏杰,赵帅. 基于复合神经网络的电力系统暂态稳定评估和裕度预测[J]. 电力系统自动化,2013,37(20):41-46.
- [8] 苏童,刘友波,沈晓东,等. 深度学习驱动的电力系统暂态稳定预防控制进化算法[J]. 中国电机工程学报,2020,40(12):3813-3824.
- [9] 朱乔木,陈金富,李弘毅,等. 基于堆叠自动编码器的电力系统暂态稳定评估[J]. 中国电机工程学报,2018,38(10):2937-2946.
- [10] 朱晨曦,张焰,严正,等. 采用改进马尔科夫链蒙特卡洛法的风电功率序列建模[J]. 电工技术学报,2020,35(3):577-589.
- [11] Christophe Andrieu, Nando De Freitas, Arnaud Doucet, et al. An Introduction to MCMC for Machine Learning[J]. Machine Learning, 2003, 50(1-2):5-43.
- [12] 朱晓荣,王羽凝,金绘民,等. 基于马尔科夫链蒙特卡洛方法的光伏电站可靠性评估[J]. 高电压技术,2017,43(3):1034-1042.
- [13] 朱乔木,党杰,陈金富,等. 基于深度置信网络的电力系统暂态稳定评估方法[J]. 中国电机工程学报,2018,38(3):735-743.

说明了所提方法可以有效处理低压脉冲法的测试结果,无需人为进行脉冲识别即可完成缺陷的定位和类别辨识。




图10 实测中时间反演处理结果

4 结 语

前面将时间反演技术用于低压脉冲电缆故障测试中,解决了原有方法需要人为干预分离脉冲和无法直观确定故障点位置等问题。仿真结果表明,所提方法可以在无需人为识别脉冲的前提下有效确定电缆中的故障点,并对该故障进行类别辨识。实测结果也表明,所提方法可以有效定位真实电缆中故障点,并且受采样设备垂直分辨率的影响较小。

参 考 文 献

[1] 饶显杰,周凯,李明志,等. 基于电力电缆绝缘去极化电流的扩展 Debye 等效电路参数辨识[J]. 高电压技术, 2020, 46(3): 1037 - 1043.

[2] 周凯,陈泽龙,李天华,等. 运行老化 XLPE 电缆导体屏蔽层侧绝缘缺陷分析[J]. 高电压技术, 2020, 46(1): 187 - 194.

[3] 袁燕岭,李世松,董杰,等. 电力电缆诊断检测技术综述[J]. 电测与仪表, 2016, 53(11): 1 - 7.

[4] 唐忠,杨建. 交叉互联电缆行波故障测距的研究[J]. 电测与仪表, 2016, 53(5): 64 - 69.

[5] 谢敏,周凯,赵世林,等. 新型基于反射系数谱的电力电缆局部缺陷定位方法[J]. 电网技术, 2017, 41(9): 3083 - 3089.

[6] Shi Q, Kanoun O. A New Algorithm for Wire Fault Location Using Time - domain Reflectometry[J]. IEEE Sensors Journal, 2014, 14(4): 1171 - 1178.

[7] 黄振峰,袁大海,毛汉领,等. 电力电缆绝缘损伤的非线性辨识及故障定位[J]. 广西大学学报(自然科学版), 2018, 43(5): 1747 - 1755.

[8] 李露. 船用电力电缆故障诊断的仿真研究[D]. 大连:大连理工大学, 2017.

[9] Abboud L, Cozza A, Pichon L. A Matched - pulse Approach for Soft - fault Detection in Complex Wire Networks[J]. IEEE Transactions on Instrumentation and Measurement, 2012, 61(6): 1719 - 1732.

[10] Razzaghi R, Lugrin G, Manesh H M, et al. An Efficient Method Based on the Electromagnetic Time Reversal to Locate Faults in Power Networks[J]. IEEE Transactions on Power Delivery, 2013, 28(3): 1663 - 1673.

[11] Fink M, Prada C. Acoustic Time - reversal Mirrors[J]. Inverse Problems, 2001, 17(1): R1 - R38.

[12] 谢敏,周凯,赵世林,等. 考虑相速度频变特性的改进互相关算法局部放电定位[J]. 电网技术, 2018, 42(5): 1661 - 1667.

[13] 谢敏,周凯,何珉,等. 基于时间反演技术的电力电缆局部放电定位方法[J]. 中国电机工程学报, 2018, 38(11): 3402 - 3409.

[14] 饶显杰,周凯,谢敏,等. 基于频域反射法的特征时域波形恢复技术[J/OL]. 高电压技术: 1 - 7[2020 - 10 - 25]. <https://doi.org/10.13336/j.1003-6520.hve.20200570729>.

[15] 周志强. 基于宽频阻抗谱的电缆局部缺陷诊断方法研究[D]. 武汉:华中科技大学, 2015.

作者简介:

沈智飞(1981),男,硕士,高级工程师,从事输电电缆生产方面的工作。 (收稿日期:2021-03-27)

=====

(上接第42页)

[14] 王伟,李开成,许立武,等. 基于一维卷积神经网络多任务学习的电能质量扰动识别方法[J/OL]. 电测与仪表:1 - 10[2021 - 04 - 14]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20210114.1618.006.html>.

[15] 王挺韶,季天瑶,姜雨滋,等. 基于降噪自动编码器与一维卷积网络的风机故障诊断方法[J/OL]. 电测与仪表:1 - 9[2021 - 04 - 14]. <http://kns.cnki.net/kcms/detail/23.1202.TH.20201222.1503.009.html>.

[16] 何成兵,王润泽,张霄翔. 基于改进一维卷积神经网络

的汽轮发电机组轴系扭振模态参数辨识[J]. 中国电机工程学报, 2020, 40(增1): 195 - 203.

[17] 杨德友,邵致远,王博. 基于动态模式分解的发电机惯量及阻尼系数评估方法[J/OL]. 电网技术:1 - 10[2021 - 04 - 15]. <http://kns.cnki.net/kcms/detail/11.2410.tm.20210412.1546.009.html>.

作者简介:

齐放(1983),男,硕士研究生,从事电力系统运行与运营工作。 (收稿日期:2021-04-27)