基于人工智能的暂态稳定裕度精细化预测

邬春明^{1,2},任继红²

(1. 东北电力大学现代电力系统仿真控制与绿色电能新技术教育部重点实验室,吉林 吉林 132012;2. 东北电力大学 电气工程学院,吉林 吉林 132012)

摘要:人工智能算法在暂态稳定评估中得到了很好的应用。然而,电力系统是时变大系统,训练数据无法涵盖所有工况,模型需要在有限时间内更新;电力系统中稳定样本数远大于失稳样本数,导致模型对失稳样本学习不足。针对以上2点,提出了基于人工智能的暂态稳定裕度精细化预测方法。该方法将改进的极限梯度提升(XGBoost)树与双XGBoost回归树集成,平衡了2类样本数量差异对模型的影响,并实现了裕度预测。 当运行工况变化较大时,结合增量学习技术,以较少的样本和较短的时间对模型进行有效更新。在2套IEEE系统上的实验结果表明所提方法可应用于暂态稳定评估。

关键词:XGBoost算法;暂态稳定评估;增量学习;电力系统;代价敏感

中图分类号:TM 712

文献标志码:A

DOI:10.16081/j.epae.202108008

0 引言

近年来,广域量测系统被广泛应用于电力系统 中,以便更好地对电力系统进行安全评估。而暂态 稳定问题是各类稳定性研究中最基本的问题:传统 的时域仿真法^[1]通过求解系统完整的故障轨迹来进 行系统稳定性的判别,评估准确率高但计算耗时长; 直接法^[24]是基于能量观点进行暂态稳定分析的方 法,此方法有明确的物理意义,但存在计算结果保 守、构建能量函数困难等问题;人工智能法能够快速 地从大量数据中挖掘出系统的稳定状态,具有较高 的评估准确率,适用于大规模的电力系统。

文献[5]提出基于决策树 DT(Decision Tree)的 暂态稳定预防控制策略,以临界机组作为特征量构 造DT,求解以DT为发电机有功出力约束的最优潮 流模型,最终得到控制策略。文献[6]研究了极限梯 度提升XGBoost(eXtreme Gradient Boosting)算法用 于暂态稳定评估TSA(Transient Stability Assessment) 的过程。使用Logistic 函数将模型输出概率化以衡 量 XGBoost 模型输出的可靠程度,预防了部分误预 测。文献[7]针对传统暂态稳定评估模型不能在 线更新的不足,提出了一种支持向量机SVM(Support Vector Machine)增量学习的暂态稳定评估方法。文 献[8]提出了一种将SVM与长短期记忆网络相结合 的预测方法,实现了暂态功角稳定性及功角轨迹的 预测。文献[9]提出了一种基于堆叠降噪自动编码 器特征集成模型的暂态稳定评估方法,使用效用理 论对运行方式进行了严重度分级,使暂态稳定评估 结果更加直观。文献[10]提出了一种基于复合神经

收稿日期:2020-10-07;修回日期:2021-06-16

基金项目:国家自然科学基金资助项目(61901102)

Project supported by the National Natural Science Foundation of China(61901102)

网络的暂态稳定评估与故障临界切除时间 CCT (Critical Clearing Time)裕度预测新方法,将概率神 经网络和径向基函数网络相结合,提高了评估准确 率和故障 CCT裕度预测能力。文献[11]针对电力系 统稳定预防控制在线计算的复杂性,提出了一种基 于神经网络预测校核的在线评估方法。文献[12]针 对电力系统暂态稳定评估中稳定样本与不稳定样本 误分类代价不同的特点,提出了一种基于代价敏感 极端学习机的电力系统暂态稳定评估方法。

目前,人工智能法在暂态稳定评估中取得了较 多的成果,但大多数方法并没有提供完整的更新方 案。当电力系统的运行工况出现较大变化时,均需 要对模型进行重新训练,从而花费大量时间。值得 注意的是,很多方法仍存在复杂度高、训练时间慢、 无法持续应用于实际工况等问题。此外,电力系统 中失稳样本和稳定样本在数量上的差异会导致模型 在训练过程中对稳定样本的信息学习完备,忽略失 稳样本的信息,进而导致模型对稳定样本的识别精 度高,对失稳样本的识别精度低,判别结果具有倾 向性。

本文在现有预测方法的基础上进行补充,提出 一种基于人工智能的暂态稳定裕度精细化预测方 法。在分类阶段,引入权重系数对XGBoost算法进 行改进,消除判别结果的倾向性;在回归阶段,采用 双XGBoost回归树对不同类别的样本进行精细化裕 度预测。在线应用过程中,当电力系统有新运行工 况出现时,采用增量学习技术对模型进行更新,使模 型在短时间内能够恢复较高的评估性能。

1 算法介绍

1.1 梯度提升树的二阶近似

由于 XGBoost 算法采用了一种二阶近似的可加

性学习方案,因此需要采用与预测相关的损失函数的一阶导数和二阶导数来拟合模型。设*m*为数据的数量,*n*为特征的数量,*x*_i为输入,*y*_i为目标值; \hat{y}_i 为预测值,*z*_i为经过Sigmoid函数之前的预测值。根据文献[13],实际中使用的目标损失函数为:

$$L^{t} = \sum_{i=1}^{n} l(y_{i}, z_{i}^{(t-1)} + f_{t}(\boldsymbol{x}_{i})) + \Omega(f_{i})$$
(1)

式中: $l(\cdot, \cdot)$ 为目标值 y_i 与预测值 z_i 之间的损失; $f_i(\cdot)$ 代表回归树, $f_i(\mathbf{x}_i)$ 为第t棵树对数据集中第i个样本 \mathbf{x}_i 的计算分数; $\Omega(\cdot)$ 为模型的复杂度。将树加性拟 合为 $z_i^{(i)}=z_i^{(i-1)}+f_i(\mathbf{x}_i)$,其中t表示训练过程的第t次 迭代。

模型训练的最终目标是找到第*t*次迭代下的 *f_i*(·)来优化式(1),为了实现这一目标,将方程式(1) 进行二阶泰勒展开得到:

$$L^{t} \approx \sum_{i=1}^{n} \left[g_{i} f_{t}(\boldsymbol{x}_{i}) + \frac{1}{2} h_{i} (f_{t}(\boldsymbol{x}_{i}))^{2} \right] + \Omega(f_{i}) \qquad (2)$$

式中: $g_i = \frac{\partial L}{\partial z_i} \pi h_i = \frac{\partial^2 L}{\partial z_i^2}$ 分别为目标损失函数的一阶

和二阶导数项,且 g_i 和 h_i 都是标量。

1.2 加权损失函数

由于XGBoost算法不提供自动分类,因此选择 Sigmoid函数作为加权损失函数的激活函数。本文 所提出的α-XGBoost的加权交叉熵损失函数可表 示为:

$$L_{w} = -\sum_{i=1}^{m} \left[\alpha y_{i} \ln \hat{y}_{i} + (1 - y_{i}) \ln (1 - \hat{y}_{i}) \right]$$
(3)

式中:α为稳定样本的权重系数。权重系数α的引入 影响了模型对临界情况的判别结果:若α>1,则将稳 定样本预测为失稳样本时会计算额外损失;若α<1, 则将失稳样本预测为稳定样本时会计算额外损失。 加权损失函数的一阶导数如下:

$$\frac{\partial L_{w}}{\partial z_{i}} = -\alpha^{y_{i}}(y_{i} - \hat{y}_{i})$$

$$\tag{4}$$

该导数与普通交叉损失项 ∂L/∂z相似,它增加了 一个 α^x·项来控制参数的出现。再次对z_i求导,得到 二阶导数如下:

$$\frac{\partial^2 L_{\rm w}}{\partial z_i^2} = -\alpha^{y_i} (1 - \hat{y}_i) \hat{y}_i \tag{5}$$

1.3 增量学习技术

增量学习是一种机器学习方法,其输入的数据 被不断用于扩展现有模型的知识,即进一步训练模 型^[14],目的是将一个在源域中训练的模型适应到新 的任务中,同时能够保留以前获取的知识。

当电力系统运行过程中出现较大变化时,离线 训练的暂态稳定评估模型的评估性能势必会下降。 而对于一个静态的暂态稳定评估模型,并不能从新 获取的数据中学到新知识,无法进行持续的在线应 用。因此,本文将增量学习技术与所提方法相结合, 使模型能够连续地从新数据中获取知识,以保持较好的评估性能。在暂态稳定评估中引入增量学习技术主要有以下优点:①使模型可以从新样本集中高效地学习新知识;②无需使用原始数据集重新训练模型;③模型对旧知识具有记忆功能,不会出现灾难性遗忘。

2 暂态稳定评估模型

2.1 模型的离线训练和在线应用

在电力系统中,基于机器学习的暂态稳定评估 方法一般包含离线训练和在线评估2个部分。为了 同时实现暂态稳定评估和裕度预测,本文采取了将 α -XGBoost与双XGBoost进行集成的方式,首先使用 α-XGBoost 判别系统的稳定性,然后采用双 XGBoost 回归树分别建立了稳定程度和失稳程度预测模型, 对α-XGBoost模型确定为稳定和失稳的样本进行进 一步评估。模型的整体构建流程如图1所示。在离 线训练阶段,使用训练集中全部样本对 α -XGBoost 进行训练,构建分类模型。同时,根据暂态稳定 指数[11]将训练集样本分为稳定和失稳样本,分别对 XGBoost_1和XGBoost_2进行训练,构建2类样本的 精细化裕度预测模型。模型在线应用时,所获取的 未知场景下的实时数据与训练集数据具有差异性, 导致离线训练集下构建的暂态稳定评估模型不能准 确预测未知场景下的系统状态。因此,模型需要定 期地进行更新,以保持良好的评估性能。本文结合 增量学习技术,提出了一套具有记忆功能的快速更





新方案。当模型在线应用时,根据实时的调度计划 来选择更新模型所采用的数据。若调度计划未出现 变化,则使用当前时段的实时数据对模型进行更新。 如果在下一个时段调度计划出现发电机投退、线路 投退或负荷水平变化,立即针对未知的运行工况进 行仿真,生成少量的新数据,以对模型进行更新。

模型的更新过程的启动有以下2种模式:①常规维护模式是模型的更新按周期进行,更新周期需要根据负荷的变化规律和系统的规模拟定;②异常维护模式是当系统检测到有发电机投退、线路投退等动作时,均需要额外启动一次更新。模型更新的时序关系如图2所示。



Fig.2 Time-sequence relationship of model updating

每个时段的模型更新都基于初始模型。对于已 训练好的树模型而言,旧训练样本决定了模型的结 构,即选择哪些特征及分裂点,而新加入的样本决定 最终的结果,即叶节点的权重和新加入的树。因此, 本文设计了以下3种不同更新方案,分别在未知负 荷和未知拓扑结构情况下进行实验:方案1,保持初 始模型中全部树的结构、数量和叶子节点权重不变, 在该结构的基础上增加新树,最后调整全部树之间 的权重系数;方案2,保持初始模型中全部树的结 构、数量不变,在该结构上对叶子节点的权重进行调 节,但不添加新的树;方案3,将新数据库与初始数 据库合并,重新训练模型。其中方案1和方案2为增 量学习方法,方案3为批量学习方法。

2.2 模型的输入与输出

本文的输入特征采用一组暂态稳定特征集^[15-16], 如附录A表A1所示。表中的特征均为系统特征,而 非单机特征,因此特征维数不随系统规模的变化而 变化,可以满足大系统暂态稳定评估的需要。尤其 是在拓扑结构变化的情况下,模型不会因为特征维 数减少或增加而不能使用,为本文提出的基于增量 学习技术的更新方案的实现提供了保障。此外,随 着广域测量技术的进一步发展,分布在发电厂和变 电站中的能量管理单元将有望直接或间接获取上述 特征。

设在样本集中稳定样本标签为1,失稳样本标 签为0,利用式(6)表征系统的CCT裕度。

$$T_{\rm sm} = T_{\rm cct} - (T_{\rm c} - T_{\rm s}) \tag{6}$$

式中: T_{sm} 为CCT裕度; T_{eet} 为线路的CCT,可由时域 仿真获得; T_s 为故障开始时间; T_e 为故障切除时间。

2.3 模型评价指标

在α-XGBoost训练过程中,选择以下4个评价指标对模型进行评估:

$$P_{\rm acc} = (I_{\rm TP} + I_{\rm TN}) / (I_{\rm TP} + I_{\rm TN} + I_{\rm FP} + I_{\rm FN})$$
(7)

$$P_{\rm TSR} = I_{\rm TN} / (I_{\rm TN} + I_{\rm FP}) \tag{8}$$

$$P_{\rm TFR} = I_{\rm TP} / (I_{\rm TP} + I_{\rm FN}) \tag{9}$$

$$G_{\text{mean}} = \sqrt{P_{\text{TSR}} P_{\text{TFR}}} \tag{10}$$

式中:*I*_{TP}为正确分类的稳定样本的数量;*I*_{TN}为正确分 类的不稳定样本的数量;*I*_{FN}为错误分类的不稳定样 本的数量;*I*_{FP}为错误分类的稳定样本的数量;*P*_{acc}为 总体准确率;*P*_{TSR}为正确识别不稳定样本的准确率; *P*_{TFR}为正确识别稳定样本的准确率;*G*_{mean}为*P*_{TSR}与*P*_{TFR} 的几何平均值,表示模型的整体性能。本文将以 *G*_{mean}值作为重要指标。

在评估具有2类样本的双XGBoost回归树裕度 预测模型时,本文采用最大误差*E*_m、平均误差*E*_r和 CCT裕度预测误差小于0.01 s样本的比例*R*_a来评估 模型,并以两XGBoost回归树的加权平均值作为最 终评估结果,具体如下:

$$E_{\rm m} = \max\left\{ \left| p_k - t_k \right| \right\} \quad k = 1, 2, \cdots, N^*$$
 (11)

$$E_{r} = \frac{1}{N^{*}} \sum_{k=1}^{N^{*}} \left| p_{k} - t_{k} \right|$$
(12)

$$R_a = u/N^* \times 100\%$$
 (13)

式中: N^* 为样本总数; p_k 和 t_k 分别为第k个样本的CCT 裕度预测值和真实值;u为CCT裕度预测误差小于 0.01 s的样本数。

3 算例分析

3.1 数据集生成

本文所使用的编程语言为Python语言,机器学 习框架选择Sklearn库,计算机配置为Intel Corei5-6200CPU / 8 GB。仿真系统采用IEEE 10机 39节点 系统(简称10机系统)和IEEE 16机 68节点系统(简 称16机系统)。仿真平台为PSD-BPA。分别在80%、 85%、…、120%负荷水平下改变发电机出力。假定 系统中输电线路发生三相短路故障,故障位置分别 位于线路首端及线路的20%、50%、80%处。设故 障发生时刻为零时刻,故障切除时间在0.1~0.5 s内 取值。利用BPA计算各场景下系统的 T_{cet} 和 T_{sm} 。在 10机系统上,共生成7560个样本;在16机系统上, 共生成10869个样本。两系统的训练集和测试集分 布如表1所示。

3.2 修改损失函数对模型的影响

为了验证损失函数对评估结果的影响,本实验 将权重系数α设置在0~1范围内,步长为0.1。在10 机系统和16机系统进行测试,实验结果如图3所示。 由图可知,随着稳定样本权重系数的减小,P_{TSB}不断

Description of training and testing sets Table 1 训练集 测试集 测试 总样 失稳 稳定 总样 失稳 稳定 系统 本数 样本数 样本数 本数 样本数 样本数 10 机系统 6048 2016 4032 1512 504 1008 16 机系统 8695 2174 966 $1\,208$ 3864 4831 100 100平价指标 / % 评价指标 / % 98 99 96 98 94 97 92 90 96 1.00 0.10 0.55 1.00 0.10 0.55 α α (a) 10 机系统 (b) 16 机系统 $-P_{\rm acc}$, $P_{\text{TSR}}, \dots P_{\text{TFR}},$ $--G_{mean}$

表1 训练集和测试集的描述



增加。对于10机系统和16机系统,当α=0.5 和α= 0.8时G_{mean}值最高,模型的性能最好。在表1所示的 训练数据中,10机系统的失稳样本数与稳定样本数 之比为2016/4032≈0.5,16机系统的失稳样本数与 稳定样本数之比为3864/4831≈0.8。由此可知,在训 练数据中,损失函数中稳定样本权重系数α的最优 值和失稳样本数与稳定样本数的比值非常接近。因 此,在训练数据不平衡且失稳样本数量较少的情况 下,可直接使用失稳样本数量与稳定样本数量的比 值作为稳定样本权重系数α。

3.3 算法对比

同样采用表1中的数据对另外4个分类器SVM、 DT、随机森林RF(Random Forest)、XGBoost进行训 练,并与所提方法进行对比,结果如附录A表A2所 示。其中,SVM使用径向基函数作为核函数,采用网 格法和五折交叉验证进行相关参数寻优;DT采用 C5.0算法。对于10机系统,XGBoost采用120棵树 集成;对于16机系统,XGBoost采用150棵树集成。 表A2展示了不同分类器下两系统的测试数据集的 性能。对比可知,XGBoost算法比SVM、DT、RF的 评估准确率更高,而本文所提的α-XGBoost方法对 失稳类样本的评估准确率有所提升。在训练时间 方面,α-XGBoost比SVM、RF所需的时间更短。虽然 α-XGBoost相比DT和XGBoost需要更多训练时间, 但 α -XGBoost 的 G_{mean} 优于 DT,略优于 XGBoost,且 α -XGBoost 对失稳样本的识别精度高,更符合暂态稳 定评估中误分类代价不同的原则。

将本文所提方法与其他的裕度预测算法如人工 神经网络ANN(Artificial Neural Network)^[17]、弹性 网络(Elastic Net)^[18]和未经α-XGBoost集成的回归树 进行对比。在10机系统上,设置ANN层数为4层, 各层节点数为{50,90,70,20},使用Sklearn库中的 ElasticNetCV接口对Elastic Net进行参数最优化,参 数 alphas 的寻优区间设置为 {0.0001,0.0005,0.001, 0.01,0.1,1},参数11_ratio的寻优区间设置为{0.001, 0.01,0.1,0.5,0.9,0.99 。其中, alphas 用来调节惩罚 项的参数,取值在0~1之间;11 ratio用来调节L1和L2 正则化凸组合的参数。在16机系统上,设置ANN层数 为5层,各层节点数为{50,70,90,70,20},Elastic Net 中,参数 alphas 的寻优区间设置为 {0.0001,0.0005, 0.001,0.01,0.1,1,10},参数11_ratio的寻优区间设置 为{0.001,0.01,0.1,0.5,0.9,0.99}。最终结果如附录 A表A3所示。从测试结果可以看出,本文所提方法 的暂态稳定裕度评估性能优于 ANN、Elastic Net 和 未经 α -XGBoost集成的回归树。

3.4 不同更新方案的对比

在10机系统和16机系统进行测试,对比3种更 新方案的有效性。根据负荷水平不同,分别将2套 系统生成的数据分为两部分:①负荷水平为90%~ 110%(共5种负荷水平),用来训练初始模型,将所 有样本按照8:2的比例划分为训练集和测试集, 用以训练和测试模型的评估性能;②负荷水平为 80%~85%和115%~120%(共4种负荷水平),用来 进行模型更新,将所有样本按照7:3的比例划分为 增量集和测试集,用以增量训练和测试增量训练 后模型的评估性能。2套系统上样本集划分如表2 所示。

在暂态稳定评估的实际应用中,训练样本可能 逐个或逐批次地到达。因此,在实验过程中每进行 一次更新就要新增一批样本。在本实验中,3种更 新方案均采用相同的增量集。对于10机系统和16 机系统,增量集每轮均新增100个样本。考虑到抽 样的随机性,所有方案均进行50次随机抽样,并以 50次测试集评估结果的平均值作为最终评估和预

表2 样本集划分

		Tab	ble 2 Division of	f sample set		
		离线训练			模型更新	
测 讯 玄弦	(负荷水平为90%~1	10%)	(负荷水	平为80%~85%和11	5%~120%)
示机	样本总数	训练集样本数	测试集样本数	样本总数	增量集样本数	测试集样本数
10机系统	4 2 0 0	3 3 6 0	840	3 3 6 0	2352	1 008
16机系统	5260	3682	1578	5 609	3927	1682

测结果。图4展示了3种方案的对比结果。图中左 侧两图描述的是α-XGBoost分类精度变化,右侧两 图描述的是双XGBoost回归树预测精度变化。由图 可知,采用方案2进行更新时,模型的评估性能未得 到显著的提升。这是由于该方案在增量学习过程中 保持了原有分类器的结构,无法有效地学习新数据, 导致模型的评估性能下降。方案1和方案3的Gmean 都很高,但当达到较高的Gmean时,方案1仅需要少量 样本,而方案3则需要更多的样本。较大的样本量 会增加更新时间,在系统规模继续扩大时,两者的差 距将会进一步增大。



Fig.4 Comparison of assessment performance among three updating schemes

以α-XGBoost为基准,将采用两方案更新时所 需样本数进行对比。其中,所需样本数由模型精度 的上升幅度决定,当样本数增加,而精度不再大幅 度上升时,即为所需样本数。在10机和16机系统 上采用方案1进行更新,所需样本数分别为1100和 2000,而采用方案3进行更新时,所需样本数分别为 1800和2700。以方案1与方案3所需样本数分别为 1800和2700。以方案1与方案3所需样本数分别为 1800和2700。以方案1与方案3所需样本数分准, 对比2种方案的更新时间,结果如表3所示,其中更 新时间包括时域仿真时间和模型训练时间。由表3 可知,本文采用的输入特征维数较少,所以可以忽略 使用不同更新方案的模型训练时间差距。但由于方 案3所需样本数较多,所以其在时域仿真上耗时更 多。综上所述,无论从模型的评估性能还是更新时 间角度,方案1均优于其余2种方案,因此选择方案 1作为所提方法的在线更新方案。

表3 更新时间对比

Table 3 Comparison of updating time

测试	所需棒	羊本数	时域仿真	€时间∕s	模型训练	际时间∕s
系统	方案1	方案3	方案1	方案3	方案1	方案3
10机系统	1 1 0 0	1800	266.5	415.5	1.01	1.95
16机系统	2000	2700	387.0	706.3	2.32	2.74

对于方案1,在10机系统上,采用1100个增量 样本时,α-XGBoost的G_{mean}上升速度放缓并趋于平 稳;而通过精细化分类后,双XGBoost回归树仅在 950个增量样本时,E_r的下降速度就开始放缓。在 16机系统上,α-XGBoost在1900个增量样本时,G_{mean} 的上升速度放缓并趋于平稳;而通过精细化分类后, 双XGBoost回归树仅在1200个增量样本时,E_r的下 降速度开始放缓。由此可知,所提的集成模型可以 提升整体更新的效果。

4 所选方案对模型的影响

在多数情况下,调度中心对于负荷水平或拓扑 结构的预测是准确的。但随着新能源不断并网以及 交直流混联的规模逐渐扩大,电力系统运行参数的 不可预测性增大,突发事件出现的频率增加。这要 求更新方案可以使得模型有效学习未知场景的同 时,也不能遗忘从初始数据库中学到的知识。为验 证更新方案1的记忆性和有效性,本实验分别采用 未知负荷和未知拓扑的数据进行测试。

1)对于未知负荷,采用3.4节相同的数据进一步 仿真,实验结果如附录A表A4所示。由表可知,更 新后的模型在已知测试集和未知测试集均展现了优 越的评估性能。这表明应用方案1可以使模型具有 较好的更新效率和记忆能力。

2)对于未知拓扑,两系统上均使用完整拓扑的 所有负荷数据进行离线训练。将完整拓扑更改为相 应的 N-1或 N-2 拓扑进行仿真,得到未知拓扑下的 数据集。将此数据集按照 7:3 的比例划分为增量集 和测试集,实验结果如附录 A 表 A5 和表 A6 所示。 由表可知,当系统拓扑发生变化时,方案1仍有效。

综合附录A表A4—A6可知,即便调度计划以 外的拓扑变化和负荷变化突然发生,初始模型仍具 有一定的鲁棒性,能满足基本评估性能要求。通过 立即启动异常维护模式可以让模型快速恢复良好的 评估性能。针对不同的电力系统,进行增量更新时 所需样本数有所差异。对于给定系统,可通过仿真 来确定需要多少样本进行增量更新。首先,随机选 取5条关键线路进行 N-1 数据仿真。其中,关键线 路的选择主要由其传输功率决定,传输功率越大,线 路的重要性越高。然后,分别对选取的5条线路的 N-1 拓扑下的数据进行增量训练,确定使每条线路 达到最佳更新效果的增量样本数量。最后,取5条 线路最佳增量样本数量的均值为该系统的最佳增量 样本数量。在线更新时,增量样本时域仿真的条件 设置如下:故障位置应覆盖所有线路,负荷水平根据 调度中心的计划来具体设置。

5 结论

暂态稳定样本的分类问题是实现电力系统动态

安全性分析和评估的关键。本文将 α -XGBoost与双 XGBoost进行集成来实现暂态稳定的评估和裕度预 测。在第一阶段,本文引入了权重系数对XGBoost 算法进行改进,实现了对电力系统暂态稳定的评估。 其中,引入权重系数的主要目的是克服模型在训练 过程中因电力系统暂态稳定数据中稳定样本和失稳 样本在数量上的不平衡引起的对失稳样本信息学习 不足的问题。在第二阶段,为进一步给后续预防和 紧急控制提供参考信息,本文采用了双XGBoost回 归树分别建立了稳定程度和失稳程度预测模型,对 第一阶段α-XGBoost模型确定为稳定和失稳的样本 进行进一步评估。在模型更新阶段,采用了增量学 习技术,大幅提高了模型在线更新的效率,这是对电 力系统暂态稳定评估方法的一种新探索。算例分析 表明,本文所提方法对失稳样本具有更高的识别度, 能够精确地预测CCT裕度,并进行高效更新,有望在 电力系统安全性评估中发挥重要的作用。

附录见本刊网络版(http://www.epae.cn)。

参考文献:

- [1] 薛巍,舒继武,严剑峰,等.基于集群机的大规模电力系统暂态 过程并行仿真[J].中国电机工程学报,2003,23(8):38-43.
 XUE Wei,SHU Jiwu,YAN Jianfeng, et al. Cluster-based parallel simulation for power system transient stability analysis[J].
 Proceedings of the CSEE,2003,23(8):38-43.
- [2] 刘笙. 电力系统暂态稳定分析的能量函数方法[J]. 电网技术,1995,19(2):11-17.
 LIU Sheng. Transient energy function analysis for power system stability[J]. Power System Technology,1995,19(2):11-17.
- [3] CHIANG H D, WU F F, VARAIYA P P. A BCU method for direct analysis of power system transient stability[J]. IEEE Transaction on Power Systems, 1994, 3(3):1194-1208.
- [4] 蔡泽祥,倪以信.考虑暂态稳定紧急控制的扩展等面积法[J]. 中国电机工程学报,1993,13(6):20-24.
 CAI Zexiang,NI Yixin. The Extended Equal Area Criterion (EEAC) including transient stability emergency control[J]. Proceedings of the CSEE,1993,13(6):20-24.
- [5] XU Yan, DONG Zhaoyang, ZHANG Rui, et al. A decision treebased on-line preventive control strategy for power system transient instability prevention[J]. International Journal of Systems Science, 2014, 45(2):176-186.
- [6]张晨宇,王慧芳,叶晓君.基于XGBoost算法的电力系统暂态 稳定评估[J].电力自动化设备,2019,39(3):77-83,89.
 ZHANG Chenyu, WANG Huifang, YE Xiaojun. Transient stability assessment of power system based on XGBoost algorithm[J]. Electric Power Automation Equipment,2019,39(3): 77-83,89.
- [7] 叶圣永,王晓茹,刘志刚,等. 基于支持向量机增量学习的电力 系统暂态稳定评估[J]. 电力系统自动化,2011,35(11):15-19.
 YE Shengyong, WANG Xiaoru, LIU Zhigang, et al. Power system transient stability assessment based on support vector machine incremental learning method[J]. Automation of Electric Power Systems,2011,35(11):15-19.
- [8] 刘俐,李勇,曹一家,等. 基于支持向量机和长短期记忆网络的暂态功角稳定预测方法[J]. 电力自动化设备,2020,40(2): 129-139.

LIU Li,LI Yong,CAO Yijia,et al. Transient rotor angle stability prediction method based on SVM and LSTM network[J]. Electric Power Automation Equipment,2020,40(2):129-139.

- [9] 尹雪燕,闫炯程,刘玉田,等.基于深度学习的暂态稳定评估与 严重度分级[J].电力自动化设备,2018,38(5):64-69.
 YIN Xueyan, YAN Jiongcheng, LIU Yutian, et al. Deep learning based transient stability assessment and severity grading
 [J]. Electric Power Automation Equipment,2018,38(5):64-69.
- [10] 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. YAO Dequan,JIA Hongjie,ZHAO Shuai. Power system transient stability assessment and stability margin prediction based on compound neural network[J]. Automation of Electric Power Systems,2013,37(20):41-46.
- [11] 杨跃,刘友波,刘俊勇,等. 基于神经网络预测校核的暂态稳定 预防控制[J]. 电网技术,2018,42(12):4076-4084.
 YANG Yue,LIU Youbo,LIU Junyong, et al. Preventive transient stability control based on neural network security predictor[J]. Power System Technology,2018,42(12):4076-4084.
- [12] 陈振,肖先勇,李长松,等. 基于代价敏感极端学习机的电力系统暂态稳定评估方法[J]. 电力自动化设备,2016,36(2):118-123.
 CHEN Zhen,XIAO Xianyong,LI Changsong, et al. Power system transient stability assessment based on cost-sensitive extreme learning machine[J]. Electric Power Automation Equipment,2016,36(2):118-123.
- [13] CHEN T, GUESTRIN C. XGBoost: a scalable tree Boosting system[C]//Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining. San Francisco, USA: ACM, 2016:785-794.
- [14] CAUWENBERGHS G, POGGIO T. Incremental and decremental support vector machine learning[J]. Advances in Neural Information Processing Systems, 2001, 13(2):147-158.
- [15] 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.
 ZHU Qiaomu,DANG Jie,CHEN Jinfu, et al. A method for power system transient stability assessment based on deep belief networks[J]. Proceedings of the CSEE,2018,38(3):735-743.
- [16] RAHMATIAN M, CHEN Y C, PALIZBAN A, et al. Transient stability assessment via decision trees and multivariate adaptive regression splines[J]. Electric Power Systems Research, 2017,142(1);320-328.
- [17] KARAMI A, ESMAILI S Z. Transient stability assessment of power systems described with detailed models using neural networks[J]. International Journal of Electrical Power & Energy Systems, 2013, 45(1):279-292.
- [18] 宓登凯,王彤,相禹维,等. 基于 Elastic Net 的暂态稳定裕度在 线评估[J]. 电网技术,2020,44(1):19-26.
 MI Dengkai, WANG Tong, XIANG Yuwei, et al. Elastic Net based online assessment of power system transient stability margin[J]. Power System Technology,2020,44(1):19-26.

作者简介:



邬春明

任继红(1996—), 女, 吉林吉林人, 硕士 研究生, 主要研究方向为人工智能在电力系统 暂态分析中的应用(**E-mail**: 1491235676@qq. com)。

Refined prediction of transient stability margin based on artificial intelligence

WU Chunming^{1,2}, REN Jihong²

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology,

Ministry of Education, Northeast Electric Power University, Jilin 132012, China;

2. Department of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China)

Abstract: The artificial intelligence algorithm has been well applied in transient stability assessment. However, the power system is a time-varying system, so the training data cannot cover all the working conditions, and the model needs to be updated within a limited time. The number of stable samples in power system is much larger than the number of unstable samples, which leads to the lack of learning from unstable samples. In view of the above two points, the refined prediction method of transient stability margin based on artificial intelligence is proposed. This method integrates the improved XGBoost (eXtreme Gradient Boosting) tree with the double XGBoost regression tree, so that the effects on the model caused by the difference number of two types of samples are balanced, and the margin prediction is realized. When the operating conditions change greatly, the incremental learning technology is combined to effectively update the model with fewer samples and shorter time. Experimental results on the two IEEE systems show that the proposed method can be applied in transient stability assessment.

Key words: XGBoost algorithm; transient stability assessment; incremental learning; electric power systems; cost sensitive

(上接第86页 continued from page 86)

New decentralized V2G mode of electric vehicles based on blockchain technology

KANG Kai¹,SHI Nian¹,WANG Yanpeng¹,ZHANG Yunlong¹,LIN Xiangning²,WANG Tao²,

LI Zhengtian², PAN Shuaiqi³

(1. Power China Hubei Electric Engineering Co., Ltd., Wuhan 430074, China;

2. State Key Laboratory of Advanced Electromagnetic Engineering and Technology,

Huazhong University of Science and Technology, Wuhan 430074, China;

3. School of Electrical and New Energy, Three Gorges University, Yichang 443002, China)

Abstract: From the perspective of sharing economy, a new decentralized V2G (Vehicle-to-Grid) mode based on blockchain technology is proposed. Taking advantage of the natural complementarity between blockchain technology and V2G technology, the electric vehicles connected to the network package the surplus electricity into futures goods with reasonable price, and spread the electricity sales information to the whole network through point-to-point technology. Meanwhile, the electric vehicles that need emergency charging buy the futures goods with the lowest price during the charging period and reach temporary contracts, the transactions will be formally reached after the security check of power grid, the power transaction information is stored in the form of smart contract, and the value is transferred automatically when it is due, which realizes the purpose of self-matching and direct bilateral transaction between the two parties in the electricity market of electric vehicles. On this basis, a feasible transaction theoretical model is built. The simulation and analysis based on 150 electric vehicles in two communities verify the economy and feasibility of the proposed transaction strategy.

Key words: blockchain; V2G; futures contract; sharing economy; network crossing cost

附录 A
表 A1 暂态稳定特征集
Table A1 Transient stability feature set

特征	特征描述	特征	特征描述
<i>x</i> ₁	t _f 时刻系统中所有发电机机械功率的平均值	<i>x</i> ₁₁	t _{cl} 时刻起发电机转子角度最大值与最小值之差
<i>x</i> ₂	to时刻起最大的发电机转子相对加速度	<i>x</i> ₁₂	t _{cl} 时刻起发电机转子角速度最大值与最小值之差
<i>x</i> ₃	to时刻起最小的发电机转子相对加速度	<i>x</i> ₁₃	t _{el} 时刻起系统中发电机转子的动能增量最大值
<i>X</i> 4	to时刻起最大加速度发电机初始相对转子角度	<i>x</i> ₁₄	tel时刻起系统中动能变化最大发电机的相对转子角
<i>x</i> ₅	to时刻起发电机初始加速度平均值	<i>x</i> ₁₅	t _{cl} 时刻起最大角度的发电机转子加速度
<i>x</i> ₆	to时刻起最大的发电机有功功率冲击	<i>x</i> ₁₆	系统中最超前与最滞后机组的转子动能之差
<i>x</i> ₇	to时刻起最小的发电机有功功率冲击	<i>x</i> ₁₇	故障期间转子角度增量最大值
<i>x</i> ₈	to时刻起发电机转子角度最大值与最小值之差	<i>x</i> ₁₈	t _{cl} 时刻起系统中转子角度最大值对应的发电机的动能
<i>X</i> 9	to时刻起发电机转子角速度最大值与最小值之差	<i>x</i> ₁₉	t _{cl} 时刻起系统中全部发电机的转子动能平均值
<i>x</i> ₁₀	to时刻起发电机转子角加速度的标准误差	x ₂₀	tcl时刻起系统的总能量调整

注: tf为故障前某一时刻; to为故障开始时刻; tcl为故障清除时刻。

表 A2 不同评估方法性能对比

Table A2 Comparison of different assessment methods

	$P_{\rm ac}$	_c /%	P _{TS}	_R /%	P_{TF}	_R /%	$G_{\rm mes}$	_{an} /%	训练时	付间∕s
评估方法	10 机	16 机	10 机	16 机	10 机	16 机	10 机	16 机	10 机	16 机
	系统	系统	系统	系统	系统	系统	系统	系统	系统	系统
SVM	98.17	95.38	96.55	94.27	98.96	96.30	97.75	95.29	4.07	5.62
RF	97.77	97.51	94.42	96.01	99.41	98.83	96.89	97.41	1.49	2.25
DT	97.38	95.28	95.21	97.51	98.43	97.51	96.81	96.30	1.03	1.60
XGBoost	98.43	98.28	96.41	97.54	99.41	98.58	97.90	98.06	0.52	1.02
α -XGBoost	98.54	98.48	98.63	98.51	98.41	97.88	98.52	98.19	1.11	2.04

表 A3 不同预测方法性能对比

Table A3 Comparison of different predicted methods

证件主计		E _m /s		E _m /s		$R_{\rm a}$ /%	핸	练时间/s
匠旧刀石	10 机系统	16 机系统	10 机系统	16 机系统	10 机系统	16 机系统	10 机系统	16 机系统
ANN	0.0159	0.0279	0.0004	0.0024	98.18	90.01	5.20	10.09
Elastic Net	0.0220	0.0101	0.0010	0.0008	95.40	97.33	4.02	4.51
XGBoost	0.0128	0.0065	0.0003	0.0005	98.50	98.49	0.95	4.94
本文方法	0.0044	0.0041	0.0002	0.0001	98.80	99.43	1.94	2.54

表 A4 方案1 在未知负荷数据上的结果

Table A4 Result of Scheme 1 on unknown load data

		10	机系统		16 机系统					
评价	已知测	试数据	未知测	试数据	已知测	试数据	未知测	试数据		
指标	(90%~11	0%负荷)	(80%~85%&11	5%~120%负荷)	(90%~11	0%负荷)	(80%~85%&11	5%~120%负荷)		
	未更新模型	更新模型后	未更新模型	更新模型后	未更新模型	更新模型后	未更新模型	更新模型后		
$P_{\rm acc}$ /%	98.66	97.61	96.25	98.41	98.70	97.65	96.78	98.33		
$G_{ m mean}/\%$	98.64	97.58	96.06	98.31	98.69	97.87	96.24	98.31		
$E_{\rm r}/{ m s}$	0.0004	0.0012	0.0018	0.0004	0.0005	0.0019	0.0021	0.0006		
$R_{\rm a}$ /%	98.48	97.62	96.36	98.52	0.9838	95.64	95.65	97.52		

表 A5 10 机系统上方案 1 对于未知拓扑结构的结果

	Table A5 Results of Scheme 1	l on unknown	topology of	10-machine system
--	------------------------------	--------------	-------------	-------------------

在基在均本化	_	未更新	模型			更新模	型后	
细肝细的文化	$P_{\rm acc}$ /%	$G_{\rm mean}/\%$	$E_{\rm r}/{\rm s}$	R_a /%	$P_{\rm acc}$ /%	$G_{\rm mean}/\%$	$E_{\rm r}/{\rm s}$	$R_{\rm a}/\%$
线路 5-8	98.12	97.87	0.0036	95.26	98.45	98.05	0.0006	97.50
发电机 35 停运	96.42	95.36	0.0010	96.02	97.50	97.19	0.0008	96.91
发电机 35 和线路 5-8 停运	97.81	97.51	0.0010	96.40	97.97	97.67	0.0005	97.91

Table A6 Results of Scheme 1 on unknown topology of 16-machine system											
拓扑结构变化	未更新模型				更新模型后						
	$P_{\rm acc}$ /%	$G_{\rm mean}$ /%	$E_{\rm r}/{\rm s}$	$R_{\rm a}$ /%	$P_{\rm acc}$ /%	$G_{\rm mean}$ /%	$E_{\rm r}/{\rm s}$	$R_{\rm a}$ /%			
线路 4-5	98.76	97.92	0.0013	95.34	99.16	99.07	0.0006	97.69			
发电机 60 停运	96.63	95.73	0.0016	94.14	98.94	98.75	0.0007	97.21			
线路 30-31 和发电机 67 停运	95.78	93.42	0.0019	93.53	98.51	98.39	0.0005	97.82			

表 A6 16 机系统上方案 1 对于未知拓扑结构的结果