

基于 XGBoost 算法的电力系统暂态稳定评估

张晨宇¹, 王慧芳¹, 叶晓君²

(1. 浙江大学 电气工程学院, 浙江 杭州 310027; 2. 广东电网有限责任公司惠州供电局, 广东 惠州 516003)

摘要:针对暂态稳定评估问题的特点,在改进极限梯度提升(XGBoost)算法的基础上进行暂态稳定评估。根据电网物理特点,定义能够反映电力系统稳态运行状态的特征集;研究 XGBoost 算法用于暂态稳定评估的过程;针对暂态稳定预测中 2 类错误严重程度不同的特点,定义包含注意力系数的对数损失函数,使得模型对不稳定样本的误预测情况减少;使用 Logistic 函数将模型输出概率化,用于衡量 XGBoost 模型输出的可靠程度,预防部分误预测;给出针对任意系统随机产生样本集的方法。IEEE 39 节点系统仿真结果表明,XGBoost 算法在准确率上均高于其他几类常用机器学习算法,优化后的损失函数降低了不稳定样本错误分类的可能性,使该算法的召回率较优于其他方法,且概率化输出的形式有助于评估模型输出的可靠程度,降低了误预测的概率。

关键词:暂态;稳定性;XGBoost 算法;机器学习;人工智能;Logistic 函数

中图分类号:TM 712

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2019.03.012

0 引言

电力系统由于互联水平提高、负荷日益增加以及新能源接入等因素,其运行愈发接近稳定极限。电力系统的稳定运行的重要性日益凸显,因此暂态稳定评估 TSA(Transient Stability Assessment)问题更加受到人们的关注^[1]。传统的基于时域仿真的暂态稳定评估方法因受到计算速度的限制,故难以满足在线应用的需要。近年来,随着人工智能技术的快速发展,基于机器学习算法的暂态稳定评估成为学者的研究热点^[2-3]。

机器学习算法是一类数据驱动的建模方法,根据所用数据源的不同,基于机器学习方法的暂态稳定评估研究可分为两大类:第一类同时使用故障前和故障后的特征作为模型的数据输入^[4-6],第二类仅使用故障前的特征作为数据输入^[7-13]。故障前的特征即为系统处于稳态运行时可以检测到的特征,如线路潮流、节点电压等;故障后的特征,如发电机转子加速度等动态特征,仅在系统真正发生故障后才可以检测到。电力系统的暂态过程发展迅速,一旦系统发生故障,留给调度人员的反应时间非常少,所以,针对电力系统实际运行,指导意义更大的是使用第二类数据源的建模方法,根据其稳态运行时的各种信息,判别各类故障可能造成的后果,从而可以及时调整运行方式,起到故障预防作用,本文的研究内容集中在这一方面。

在该类研究中,文献[7]使用支持向量机 SVM(Support Vector Machine)进行大系统的暂态稳定评

估;文献[8]使用极限学习机算法进行系统暂态稳定评估,并且针对该算法的特点,引入 Fisher 算法进行了特征选择;文献[9-10]采用集成学习的思想,利用数据训练多个机器学习模型,可以在一定程度上克服单个模型泛化能力差的缺点;文献[11]采用深度学习方法进行电力系统故障之后暂态稳定的在线评估,并且利用稳定域概念解释模型学习到的分类边界的物理意义;文献[12]认为主导失稳机群的特征对暂态稳定有重要影响,在辨识该类主导机群的基础上,提出融合了拓扑和运行方式信息的特征集,进而采用 k 近邻 kNN(k-Nearest Neighbors)算法评估暂态稳定性;文献[13]使用深度学习中堆叠降噪自动编码器提取特征,训练支持向量机模型用于暂态稳定评估,且并利用效用理论对运行方式进行严重程度分级。

在这一领域的研究中仍然有待解决的问题主要有 3 个方面:第一,模型的评估准确度仍有提升空间,近年来,一些新的机器学习算法在准确度上有着超出传统机器学习算法的表现,使用该类新算法进行暂态稳定评估有望进一步提升准确度;第二,机器学习算法均难以达到百分之百的准确率,往往不可避免地会有一些错误,对于电力系统运行,错误的模型输出可能给运行人员带来错误引导,从而引发严重的误操作事故,现有文献的分析大多围绕算法准确度,对于被错误分类的样本没有专门的统计研究,然而,对于非机理性的机器学习算法,如何有效避免模型的可能失误也是一个重要问题;第三,暂态稳定预测问题中 2 类错误严重程度不同^[10],需要根据这一场景特点有针对性地对机器学习算法进行修改。极限梯度提升 XGBoost(eXtreme Gradient Boosting)算法是 2016 年成型的一种基于树

收稿日期:2018-06-04;修回日期:2018-12-11

基金项目:广东电网公司科技项目(GDKJQQ20153014)

Project supported by the Science and Technology Project of Guangdong Power Grid Corporation(GDKJQQ20153014)

模型的机器学习算法^[14], 由于其在 Kaggle、KDD (Knowledge Discovery in Database) 等一系列大数据算法竞赛中的优异表现^[15], 引发了大量的关注。XGBoost 模型不仅在算法准确度上较传统算法表现出色, 同时, 算法框架的可修正性较好, 可根据实际问题场景做出有针对性的优化。本文使用 XGBoost 算法进行电力系统暂态稳定评估。针对暂态稳定预测中 2 类错误严重程度不同的特点, 定义了包含注意力系数的对数损失函数, 减少针对不稳定样本的误分类情况。同时, 在算法基础上, 引入 Logistic 函数将模型输出概率化用于评估模型预测的可靠程度, 可以在一定程度上避免误分类问题。

1 基于机器学习的暂态稳定评估问题

对于特定电力系统的某种稳态运行方式, 当故障信息 (如故障位置、故障时间、故障类型) 确定时, 系统的暂态稳定后果是唯一的, 因此可以使用机器学习方法自动学习电力系统的稳态特征与暂态稳定后果之间的映射关系。在这一建模过程中, 需要确定与暂态稳定后果有关的稳态特征集以及暂态稳定后果标签。

1.1 电力系统的稳态特征集

电力系统稳态运行时, 能量管理系统会实时采集网络中的电气量信息, 这些能够反映电力系统运行状态的电气量信息如表 1 所示, 这些信息可以组成电力系统的稳态特征向量 \mathbf{x} 。

表 1 稳态电气量特征

Table 1 Electrical quantity features at steady state

特征符号	特征含义
V^i, θ^i	节点 i 的电压幅值、相角
$\Delta\theta^{i-j}$	发电机节点 i, j 之间的功角差
P_G^i, Q_G^i	发电机节点的有功、无功出力
P_L^i, Q_L^i	负荷节点的有功、无功负荷需求
P_B^{i-j}, Q_B^{i-j}	线路 $i-j$ 传输的有功和无功功率

1.2 电力系统的暂态稳定后果评价

当电力系统发生故障后, 其稳定性由一段时间内电力系统中各发电机之间的功角差 δ 来衡量, 根据 δ 是否发散, 可将系统故障后果分为暂态稳定和暂态不稳定^[16]。当系统最大发电机功角差不超过 180° 时, 系统往往不会失去稳定; 当系统最大发电机功角差超过 180° 时, 往往出现功角差发散现象, 系统将无法继续保持稳定运行。因此给定电力系统稳定性标记 y 的评估标准如式 (1) 所示。

$$y = \begin{cases} 0 & 0^\circ < \max(\delta) \leq 180^\circ \\ 1 & \max(\delta) > 180^\circ \end{cases} \quad (1)$$

其中, $\max(\delta)$ 为故障后一段时间内系统任意 2 台发电机之间功角差的最大值。

2 用于暂态稳定评估问题的 XGBoost 算法

2.1 XGBoost 算法

对于给定的具有 N 个样本和 M 个特征的训练样本集 $D = \{(\mathbf{x}_i, y_i)\} (i = 1, 2, \dots, N, \mathbf{x}_i \in \mathbf{R}^M, y_i \in \mathbf{R})$, XGBoost 算法的最终训练结果是一个由 K 个 CART (Classification And Regression Tree) 决策树^[17] 函数相加得到的集成模型:

$$y_i^* = \varphi(\mathbf{x}_i) = \sum_{k=1}^K f_k(\mathbf{x}_i) \quad f_k \in F \quad (2)$$

其中, y_i^* 为 XGBoost 模型的输出; $F = \{f(\mathbf{x}) = \mathbf{w}_{q(\mathbf{x})}\} (q: \mathbf{R}^M \rightarrow T, \mathbf{w} \in \mathbf{R}^T)$ 为 CART 决策树的集合, 一个 CART 决策树由树结构 q 和 T 个叶节点组成, 每个叶节点 j 都有一个连续值与之对应, 称为叶节点的权重 w_j , 所有权重构成该树的权重向量 $\mathbf{w} \in \mathbf{R}^T$ 。

树结构 q 通过属性判别可以将任意具有 M 维特征的样本映射到其某一个叶节点上。每一个决策树函数 f_k 对应一个特有的树结构 q 以及对应的叶节点权重向量 \mathbf{w} 。对于一个样本, XGBoost 模型获取最终的预测值 y_i^* 的过程为: 在每一棵决策树上将该样本映射到对应的叶节点上, 再将该样本对应的 K 个叶节点的权重相加。

有监督学习模型均会定义损失函数, 用于衡量模型的预测值与真实值之间的偏差, 模型训练目标即使得损失函数的值尽可能的小。XGBoost 模型的损失函数形式如式 (3) 所示。

$$L(\varphi) = \sum_{i=1}^N l(y_i^*, y_i) + \sum_{k=1}^K \Omega(f_k) \quad (3)$$

其中, $l()$ 为训练损失函数, 根据机器学习问题类型的不同可选用对数损失函数、均方误差损失函数等, 用于衡量预测值 y_i^* 与标签值 y_i 之间的偏差; $\Omega()$ 为正则项, 用于控制模型复杂度, 使模型保证在训练样本上准确度的同时, 不至于过度复杂, 从而可以避免过拟合, 增强泛化能力, 其定义如式 (4) 所示。

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (4)$$

等号右侧的第一项用于控制树模型中叶子节点的个数, 使树结构 q 尽可能简单; 第二项用于控制叶节点的权重分布, 避免权重向量 \mathbf{w} 出现过大的值。 γ 和 λ 两参数用于调节正则项中两部分之间的比例, 一般将 λ 取为 1, 仅对参数 γ 做必要的调整。

根据定义的损失函数, 可以使用训练样本对 XGBoost 模型进行训练。在 XGBoost 算法中, 训练是以树模型迭代增加的方式进行的, 即训练过程中的每一步增加一个 CART 决策树函数 f , 使得损失函数进一步减小。假定 $y_i^{*(t)}$ 表示第 t 步时对第 i 个样本的预测值, 此时, 为了进一步优化模型, 需要增加最

优的树结构 f_t 来最小化此时的目标函数 $L^{(t)}$ 。

$$L^{(t)} = \sum_{i=1}^N l(y_i^{*(t)}, y_i) + \sum_{k=1}^t \Omega(f_k) = \sum_{i=1}^N l(y_i^{*(t-1)} + f_t(\mathbf{x}_i), y_i) + \Omega(f_t) + C \quad (5)$$

其中, C 为独立于变量树结构 f_t 的常数, 即第 t 步之前已经获得的 CART 函数对应的正则项, 这些正则项已是定值。新的树结构 f_t 使得此时的预测输出变为 $y_i^{*(t-1)} + f_t(\mathbf{x}_i)$ 。选取树结构 f_t 的标准, 即使得损失函数 $L^{(t)}$ 的减小幅度最大。将上式展开成如式(6)所示的二次泰勒级数的形式。

$$L^{(t)} \approx \sum_{i=1}^N \left[l(y_i^{*(t-1)}, y_i) + g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t^2(\mathbf{x}_i) \right] + \Omega(f_t) + C \quad (6)$$

其中, $g_i = \partial_{y_i^{*(t-1)}} l(y_i^{*(t-1)}, y_i)$ 、 $h_i = \partial_{y_i^{*(t-1)}}^2 l(y_i^{*(t-1)}, y_i)$ 分别为损失函数 $l(\cdot)$ 在展开点 $y_i^{*(t-1)}$ 处的一阶和二阶导数; $l(y_i^{*(t-1)}, y_i)$ 为第 t 步之前得到的所有 CART 函数的输出 $y_i^{*(t-1)}$ 与样本标签 y_i 构成的损失函数, 也是一个定值。由于损失函数的减小幅度与常数项无关, 因此, 去掉上式中的常数项, 可以得到第 t 步时简化的目标函数 $L_{\beta}^{(t)}$ 。

$$L_{\beta}^{(t)} = \sum_{i=1}^N \left[g_i f_t(\mathbf{x}_i) + \frac{1}{2} h_i f_t^2(\mathbf{x}_i) \right] + \Omega(f_t) \quad (7)$$

定义 $I_j = \{i \mid q^t(\mathbf{x}_i) = j\}$ 为所有被树结构 q^t 映射到第 j 个叶节点的样本编号集合, 则上述简化目标函数可进一步被化简。

$$L_{\beta}^{(t)} = \sum_{j=1}^T \left[\left(\sum_{i \in I_j} g_i \right) w_j + \frac{1}{2} \left(\sum_{i \in I_j} h_i + \lambda \right) w_j^2 \right] + \gamma T \quad (8)$$

将该式对 w_j 求导, 可得对于一个特定的树结构 q^t , 其最优的叶节点权重为:

$$w_j^* = - \frac{\sum_{i \in I_j} g_i}{\sum_{i \in I_j} h_i + \lambda} \quad (9)$$

将其代入损失函数公式, 得到此特定树结构 q^t 对应的最优损失函数为:

$$L_{\text{opt}\beta}^{(t)} = - \frac{1}{2} \sum_{j=1}^T \frac{\left(\sum_{i \in I_j} g_i \right)^2}{\sum_{i \in I_j} h_i + \lambda} + \gamma T \quad (10)$$

$L_{\text{opt}\beta}^{(t)}$ 可以衡量任意树结构 q^t 的好坏, $L_{\text{opt}\beta}^{(t)}$ 越小, 说明此树结构 q^t 可以使模型的损失函数下降更多。

至此, 可以将 XGBoost 模型的实际训练过程表述如下: 以迭代的方式增加 CART 函数, 当树模型的继续增加使得模型的准确度提升幅度小于 s 时, 停

止迭代, 不再继续增加树模型的个数 K , 获得最终的

XGBoost 模型 $\varphi(\mathbf{x}_i) = \sum_{k=1}^K f_k(\mathbf{x}_i)$; 在每一轮迭代过程中, 为得到一个新的函数 f_t , 从一个单一的叶节点开始, 每次将一个叶节点增加一个树分叉, 在所有可能的树增长方案中(扫描所有的可分叉处和所有的可用特征), 选取使得最优损失函数 $L_{\text{opt}\beta}^{(t)}$ 最小化的方案, 如此循环进行。树的停止分裂可以由 2 个参数控制: 当树的最大深度 d_{\max} 达到规定值时, 或者当全部分裂节点的方案均无法使损失函数获得大于 γ 的下降时, 树停止分裂, 计算此树结构 q^t 对应的最优权重向量 \mathbf{w} , 从而可得到新的树函数 f_t 。

2.2 概率化输出

理论上, XGBoost 模型的输出 $y_i^* = \varphi(\mathbf{x}_i)$ 可以是 $(-\infty, \infty)$ 之间的任意值, 对于暂态稳定评估这种二分类问题, 在此输出值之后引入如式(11)所示的 Logistic 函数, 将输出转化到 $(0, 1)$ 范围之内。

$$y_i^e = \frac{1}{1 + e^{-y_i^*}} \quad (11)$$

其中, y_i^e 为概率化输出, 选取阈值 $\alpha = 0.5$, 可以获得最终的预测结果。

$$y_i^{\text{pred}} = \begin{cases} 0 & y_i^e \leq \alpha \\ 1 & y_i^e > \alpha \end{cases} \quad (12)$$

这种方式可将 XGBoost 模型的输出转化为暂态稳定与暂态不稳定 2 类, 并且概率输出 y_i^e 的大小能够反映模型预测的“可靠程度”, 可以认为: 当 y_i^e 越接近 1 时, 模型将该样本分类为 1 的确定程度越高; 当 y_i^e 越接近 0 时, 模型将该样本分类为 0 的确定程度越高。后续的算例分析表明, 针对暂态稳定评估问题, 根据测试集上被误分类样本的概率化输出分布定义不确定区间, 有助于判定模型预测的可靠程度。

2.3 暂态稳定损失函数定义

对于暂态稳定评估问题, 模型的最终目标是进行二分类, 因此损失函数 $l(\cdot)$ 取为如式(13)所示对数损失函数。

$$l(y_i^*, y_i) = y_i \ln(1 + e^{-y_i^*}) + (1 - y_i) \ln(1 + e^{y_i^*}) \quad (13)$$

等号右边第一项和第二项分别对应标签为 1 和标签为 0 的样本的标签值与预测值之间的偏差。当概率输出 y_i^e 与样本标签 y_i 越接近时, 损失函数越接近 0, 即对于标签为 1 的样本, XGBoost 输出 y_i^* 是一个较大的正值时, 或者对于标签为 0 的样本, XGBoost 输出 y_i^* 是一个较小的负值时, 损失函数趋向于 0。概率输出 y_i^e 与标签值 y_i 之间的偏差越大, 损失函数越大。对于暂态稳定评估问题, 标签为 1 和标签为 0 的样本被误分类对电力系统运行不利影

响的程度是不同的,文献[10]定义了错误分类和遗漏分类的概念,错误分类指不稳定样本($y_i = 1$)被分类为稳定样本,而遗漏分类指稳定样本($y_i = 0$)被分类为不稳定样本。对于运行中的电力系统,错误分类将会导致不稳定情况被忽视,使得运行人员错过调整运行方式的最佳时间,为安全稳定留下隐患,而遗漏分类虽然也是错误情况,但是仍然可以通过时域仿真等手段对后果进行进一步确认,其对于电力系统运行的影响相对较小。因此在模型训练时,错误分类应比遗漏分类获得更多的重视。文献[10]训练多个机器学习模型,当多个模型的输出均为稳定时样本才被预测为稳定,通过该方式增加了被模型判断为不稳定样本的个数,从而降低了错误分类的可能,然而该文献并没有提出针对这一问题如何改进机器学习算法。本文为了使得 XGBoost 模型在训练过程中更加重视被错误分类的样本,引入注意力系数 μ 改进算法,定义如式(14)所示暂态稳定损失函数。

$$l(y_i^*, y_i) = \mu y_i \ln(1 + e^{-y_i^*}) + (1 - y_i) \ln(1 + e^{y_i^*}) \quad (14)$$

当 $\mu > 1$ 时,损失函数中第一项占据的比例将更大,模型的训练过程将更加重视被错误分类的样本,从而使得训练出的模型更加不容易发生错误分类的问题。

3 数据集获取与评价指标及算法流程

机器学习建模依赖于能够有效表征系统特性的数量充足且具有代表性的样本数据。针对暂态稳定评估问题,当系统运行方式变化时,某一特定位置的同一类型的故障,其暂态稳定后果也会发生变化,这是由于运行方式的变化引发网络中节点电压、线路潮流等的改变,某一特定故障对整个系统造成的影响会相应变化。为此,采用如下方式来获取能够反映系统各类运行方式特点的样本集。对于一个包含 c 个发电机节点以及 z 个负荷节点的系统,考虑一种基础运行方式,在这种方式下,各发电机的出力为 $P_{G_{basei}}、Q_{G_{basei}} (i = 1, 2, \dots, c)$,各负荷节点的需求为 $P_{L_{basej}}、Q_{L_{basej}} (j = 1, 2, \dots, z)$ 。 $\rho_j (j = 1, 2, \dots, z)$ 以及 $\tau_i (i = 1, 2, \dots, c)$ 分别为在 $[-0.35, 0.35]$ 和 $[-0.3, 0.3]$ 范围内独立产生的随机数,通过这些随机数可以使用式(15)和式(16)产生不同的发电机出力和负荷需求,求解稳态潮流后即可获得不同的运行方式。

$$\begin{cases} P_{L_j} = P_{L_{basej}}(1 + \rho_j) \\ Q_{L_j} = Q_{L_{basej}}(1 + \rho_j) \end{cases} \quad j = 1, 2, \dots, z \quad (15)$$

$$\begin{cases} P_{G_i} = P_{G_{basei}}(1 + \tau_i) \\ Q_{G_i} = Q_{G_{basei}}(1 + \tau_i) \end{cases} \quad i = 1, 2, \dots, c \quad (16)$$

在求解稳态潮流的过程中,总负荷与总出力之间的不平衡情况可由系统的平衡节点进行补偿,在模拟出的各类运行方式之下,可以收集各类故障对

应的样本数据。

针对暂态稳定评估中错误分类和遗漏分类重要性不同的问题,在机器学习的模型评价方面,采用准确率 $I_{accuracy}$ 和召回率 I_{recall} 这两个指标评价模型效果,具体定义如下。

$$I_{accuracy} = \frac{\sum_{i=1}^R G(y_i^{pred} = y_i)}{R} \quad (17)$$

$$I_{recall} = \frac{\sum_{i=1}^R G(y_i^{pred} = 1 \cap y_i = 1)}{\sum_{i=1}^R G(y_i = 1)} \quad (18)$$

其中, R 为测试集样本个数; $G()$ 为逻辑函数,当括号内的表达式为真时,取值为 1,当括号内的表达式为假时,取值为 0。准确率 $I_{accuracy}$ 定义为在所有 R 个测试样本中预测正确的个数所占的比例,该指标用于衡量模型的整体表现。召回率 I_{recall} 的定义中,分子表示实际为不稳定样本、预测结果也为不稳定样本的个数,分母表示测试集中总的不稳定样本的个数,该指标用于衡量模型在预测不稳定样本避免错误分类时的能力。

基于 XGBoost 算法的电力系统暂态稳定评估方法流程图如图 1 所示。

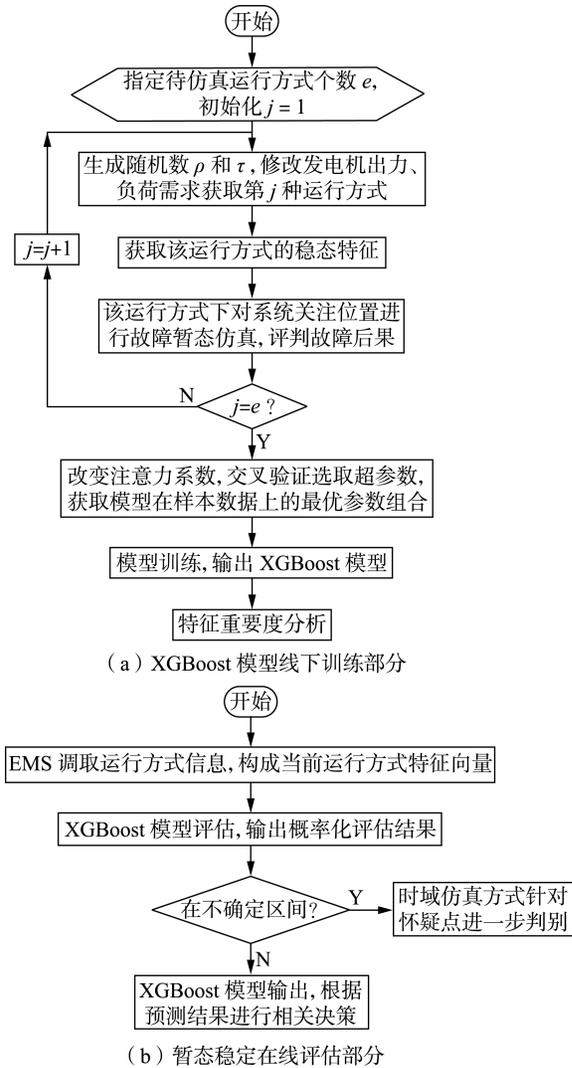
4 算例分析

在 IEEE 39 节点系统上对本文方法进行验证,该系统包含 10 个发电机节点、19 个负荷节点以及 46 条线路,系统图见附录中图 A1。

首先,使用第 3 节介绍的方法随机产生系统的 3 000 种不同运行方式,使用电力系统稳态分析工具包 Matpower^[18] 进行稳态计算,从而提取出每种运行方式下系统对应的稳态特征集;然后,针对每种运行方式,在不同位置的节点、线路设置三相短路接地故障,使用暂态分析工具包 PSAT^[19] 仿真该系统的暂态过程,获取该运行方式下不同位置故障的暂态稳定后果作为标签。表 2 列出了 4 种故障的样本情况。在暂态稳定仿真中,发电机采用了四阶模型,故障发生于 1.0 s 时,持续指定时间后切除相应线路,对故障发生后 7 s 内的暂态过程进行仿真,统计各发电机功角情况,确定暂态稳定标签。

4.1 训练样本数量的确定

XGBoost 算法是一种适用于大数据情景的算法,对于同一场景,理论上训练样本越丰富 XGBoost 模型性能越好。而实际中,模型性能随着训练样本数量的增加会出现饱和,即训练样本的进一步加大对模型性能的提升不明显。以节点 14 的 3 000 种运行方式下的故障样本为例,按照 0.85:0.15 的比例分为训练集和测试集,个数分别为 2 550 和 450。采用未引入注意力系数的普通对数损失函数训练模型说



(a) XGBoost 模型线下训练部分

(b) 暂态稳定在线评估部分

图 1 算法流程图

Fig.1 Flowchart of proposed algorithm

表 2 故障样本描述

Table 2 Fault sample description

故障编号	故障位置	持续时间/s	切除线路	稳定样本数量	不稳定样本数量
1	节点 14	0.145	13-14	1 193	1 807
2	节点 4	0.140	3-4	1 695	1 305
3	线路 16-24 中点	0.140	16-24	1 180	1 820
4	线路 3-18 中点	0.140	3-18	1 529	1 471

明样本个数对模型准确率的影响。图 2 为样本数从训练集总数的 30% 变化到 100% 时得到的测试集准确率。

可见,随着训练样本数量的增多,测试集准确率得到优化,但是样本数据量达到一定程度后,准确率提升不再明显。

4.2 注意力系数对模型效果的影响

继续以节点 14 的故障为例,说明暂态稳定损失函数中注意力系数的作用。随机选择 2 550 个样本训练模型,剩余的 450 个样本进行测试并统计 $I_{accuracy}$

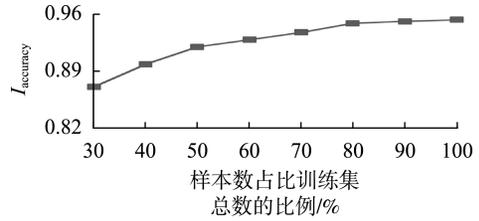


图 2 不同训练样本个数下测试集准确率

Fig.2 Accuracy rate of test set with different training sample sizes

指标和 I_{recall} 指标。在随机分得的 450 个测试样本中不稳定样本(标签为 1)的个数为 256 个,稳定样本(标签为 0)的个数为 194 个。迭代阈值取 $s=0.001$, 即当树函数的增加无法使得测试集准确率提升超过 0.001 时,迭代停止。改变 μ 的值,给定其变化范围为 1~8,间隔为 0.5;同时,以交叉验证^[20]的方式改变超参数 d_{max} 和 γ 的值,统计在各种超参数情况下每一种 μ 所对应的测试集准确率的最大值以及对应的召回率,即为该 μ 值对应的 XGBoost 模型的最佳结果,如图 3 所示。

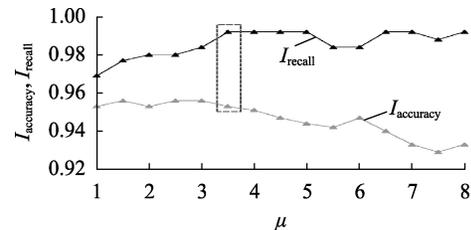


图 3 不同 μ 值下 XGBoost 模型表现

Fig.3 Performance of XGBoost model for different values of μ

可见,随着 μ 的增加,暂态稳定损失函数中错误分类部分所占的比重越来越大,模型训练过程中的关注度逐渐移向被错误分类的样本,训练出的模型将更不容易出现该类错误,召回率有上升的趋势,由最开始的 0.969 (错误分类 8 个样本)变为最高的 0.992 (错误分类 2 个样本);然而,注意力系数 μ 不能无限地增加,这是由于当 μ 过大时,暂态稳定损失函数将几乎完全被其第一项所占据,模型将难以从被遗漏分类的样本中学习到有用的信息,学习的稳定与不稳定之间的边界不清晰,反而会导致模型准确率的下降。根据图 3 中的结果,选择 $\mu=3.5$ 的情况为最佳,此时的召回率上升达到最高,同时准确率也可以达到较高的 0.953,尚未出现明显下降。对于其余故障,也采用这种方式寻找到最佳的注意力系数。

4.3 模型准确率与召回率

针对表 2 所示 4 种故障,使用改进损失函数后的 XGBoost 算法与支持向量机、逻辑回归 LR (Logistic Regression)、随机森林 RF (Random Forest)、kNN 算法分别进行暂态稳定评估,验证模型效果。

在使用各对比算法进行建模时,为保证各算法

达到最优效果,需要寻找各算法的最优超参数组合。超参数确定过程如下:对算法各参数组合情况进行“网格搜索”,遍历各参数不同值的组合情况,在训练集上进行模型训练,在测试集上验证算法效果,选取测试集效果最优的参数组合作为该算法最终的参数取值。各算法需要调节的超参数参见文献[21]介绍的机器学习开源框架 Scikit-learn。使用改进损失函数后的 XGBoost 算法和各对比算法得到的训练集准确率、召回率分别见附录中表 A1、A2,测试集准确率、召回率分别见表 3 和表 4。

表 3 测试集准确率

Table 3 Accuracy rate of test set

算法	测试集准确率			
	故障 1	故障 2	故障 3	故障 4
XGBoost	0.953	0.967	0.960	0.960
SVM	0.920	0.962	0.951	0.951
LR	0.909	0.940	0.933	0.933
RF	0.931	0.964	0.953	0.951
kNN	0.920	0.951	0.933	0.927

表 4 测试集召回率

Table 4 Recall rate of test set

算法	测试集召回率			
	故障 1	故障 2	故障 3	故障 4
XGBoost	0.992	0.978	0.989	0.978
SVM	0.941	0.952	0.961	0.965
LR	0.934	0.909	0.951	0.929
RF	0.953	0.946	0.982	0.969
kNN	0.898	0.914	0.933	0.903

有监督机器学习算法的训练过程是在给出的训练集上根据训练样本进行参数优化,使得训练出的模型在训练样本上的预测误差尽可能的小。在此过程中,训练集准确率理论上可以达到很高。然而,训练集性能过高常导致模型过拟合,即在未参与训练的新样本上,模型的预测能力不足。为保证模型的泛化能力,常见的机器学习算法均加入了防止过拟合的正则项措施控制训练集上的性能,因此常用机器学习算法均无法在训练集合上达到 100% 的训练精度。而由附录中的表 A1 和表 A2 可见,尽管几类算法均有正则项设计,XGBoost 和 RF 这 2 种基于树模型的算法对训练样本进行了更好的拟合,训练集上的准确率和召回率明显高于其他算法。这是由于这 2 种算法同属于基于树的集成模型,对大量样本复杂特征的拟合能力更强。然而,相比于训练集性能,测试集的表现更能说明算法性能。由表 3、表 4 可以发现,在测试集上,XGBoost 算法在准确率和召回率上均高于其他算法,这是由于 XGBoost 在算法设计上更好地兼顾了学习能力与泛化能力。在基于树的集成模型的思想中,树的个数 K 理论上可以任意大,这使得 XGBoost 算法可以非常好地对训练样本进行拟合,从样本中学习尽可能多的信息。同时,XG-

Boost 算法在正则项上既考虑了单个树模型规模 T ,同时也对叶节点权重 w 进行了平滑,使模型更加不容易过拟合,因此在训练集之外有更好的泛化能力,具有更高的测试集准确率。在此基础上,针对暂态稳定预测问题场景,经过对对数损失函数的改进,模型在测试集召回率上也显著高于其他模型。

4.4 预测可靠程度评估

对 4 种故障的误分类情况进行统计,测试集样本总共有 1 800 个,其中样本标签为 1 的有 952 个,样本标签为 0 的有 848 个。样本标签为 1 并且被正确分类的样本共有 938 个,XGBoost 模型给出的这些样本的概率输出的平均值为 0.97,其中,大于 0.9 的个数有 852 个,占到 90.8%;样本标签为 0 且被正确分类的样本共 790 个,XGBoost 模型给出的这些样本的概率输出的平均值为 0.058,小于 0.2 的个数有 704 个,占到 89.1%。这说明 XGBoost 模型对于较有把握的不稳定样本,其概率输出相对很大,一般在 0.9 以上,对于较有把握的稳定样本,其概率输出相对很小,一般在 0.2 以下。另一方面,被误分类的样本总数为 72 个(其中错误分类 14 个,遗漏分类 58 个),其 XGBoost 模型给出的概率输出情况如图 4 所示。

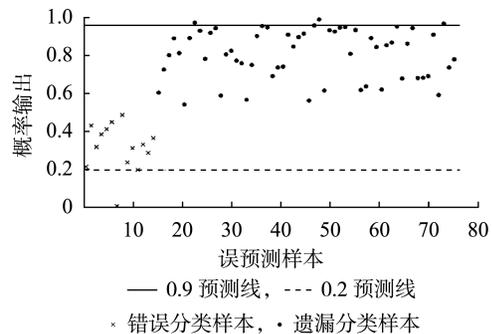


图 4 XGBoost 模型误分类样本概率输出

Fig.4 Probabilistic output of misclassified samples of XGBoost model

可以发现,被误预测的样本的概率输出大多集中在 0.2~0.9 之间,相比于被正确分类的样本,概率输出值更加偏离 1 或 0。因此,一个可以用于评估 XGBoost 模型预测可靠程度的策略是:将 $[0.2, 0.9]$ 作为不确定区间,当概率输出在该区间内时,表示其把握程度较低,此时可以寻求其他方式进行进一步的稳定性判别,例如可以直接进行对应故障的时域仿真;当概率化输出不在不确定区间内时,可以直接依靠 XGBoost 模型的输出进行暂态稳定判别,可以发现大多数样本均属于这种情况。尽管任何机器学习模型都难以达到 100% 的正确率,但是以概率方式可以捕捉模型对较为确定的预测以及相对不确定的预测之间的差别,从而可以避免模型的一部分误输出。

5 结论

本文使用 XGBoost 算法进行电力系统暂态稳定评估,算例表明,相比于其他方法,本文的优势与创新主要包括以下几点:

a. 针对暂态稳定评估中 2 类错误重要程度不同的特点,引入注意力系数修正了 XGBoost 算法的损失函数,使模型训练更加有针对性,算例表明,这种方式可以有效提高模型的召回率;

b. 与几类常用机器学习算法的对比结果显示,改进后的 XGBoost 算法在准确率和召回率上均有一定的优势;

c. 在输出部分引入 Logistic 函数将输出概率化,不仅可以满足二分类的需求,对算例中正确和错误预测的样本的统计结果表明概率输出的形式还可以在在一定程度上判断 XGBoost 模型预测的可靠程度。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] MAKAROV Y V, RESHETOV V I, STROEV A, et al. Blackout prevention in the United States, Europe, and Russia[J]. Proceedings of the IEEE, 2005, 93(11): 1942-1955.
- [2] 王同文,管霖,张尧. 人工智能技术在电网稳定评估中的应用综述[J]. 电网技术, 2009, 33(12): 60-65.
WANG Tongwen, GUAN Lin, ZHANG Yao. A survey on application of artificial intelligence technology in power system stability assessment[J]. Power System Technology, 2009, 33(12): 60-65.
- [3] 鞠平,周孝信,陈维江,等. “智能电网+”研究综述[J]. 电力自动化设备, 2018, 38(5): 2-11.
JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. “Smart Grid Plus” research overview [J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.
- [4] 段青,赵建国,马艳. 基于稀疏贝叶斯学习的电力系统暂态稳定评估[J]. 电力自动化设备, 2009, 29(9): 36-40.
DUAN Qing, ZHAO Jianguo, MA Yan. Power systems transient stability assessment based on sparse Bayesian learning [J]. Electric Power Automation Equipment, 2009, 29(9): 36-40.
- [5] WANG B, FANG B, WANG Y, et al. Power system transient stability assessment based on big data and the core vector machine[J]. IEEE Transactions on Smart Grid, 2016, 7(5): 2561-2570.
- [6] 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.
- [7] MOULIN L S, ALVESD S A P, EL-SHARKAWA M A, et al. Support vector machines for transient stability analysis of large-scale power systems[J]. IEEE Transactions on Power Systems, 2004, 19(2): 818-825.
- [8] XU Y, DONG Z Y, MENG K, et al. Real-time transient stability assessment model using extreme learning machine[J]. IET Generation, Transmission & Distribution, 2011, 5(3): 314-322.
- [9] XU Y, DONG Z Y, ZHAO J H, et al. A reliable intelligent system for real-time dynamic security assessment of power systems [J]. IEEE Transactions on Power Systems, 2012, 27(3): 1253-1263.
- [10] DAI Y, CHEN L, ZHANG W, et al. Multi-support vector machine power system transient stability assessment based on relief algorithm [C] // Power and Energy Engineering Conference. Brisbane, Australia: [s.n.], 2016: 1-5.
- [11] 胡伟,郑乐,闵勇,等. 基于深度学习的电力系统故障后暂态稳定评估研究[J]. 电网技术, 2017, 41(10): 3140-3146.
HU Wei, ZHENG Le, MIN Yong, et al. Research on power system transient stability assessment based on deep learning of big data technique[J]. Power System Technology, 2017, 41(10): 3140-3146.
- [12] 管霖,何楚瑶,曾毅豪,等. 基于模式匹配的智能稳定评估方法[J]. 电力自动化设备, 2016, 36(11): 107-111.
GUAN Lin, HE Chuyao, ZENG Yihao, et al. Intelligent stability assessment based on pattern recognition[J]. Electric Power Automation Equipment, 2016, 36(11): 107-111.
- [13] 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程度分级[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.
- [14] 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: [s.n.], 2016: 85-97.
- [15] XU Bing, ZHU Nan. Awesome XGBoost[EB/OL]. [2017-09-20]. <https://github.com/dmlc/xgboost/tree/master/demo#machine-learning-challenge-winning-solutions>.
- [16] 王锡凡. 现代电力系统分析[M]. 北京: 科学出版社, 2003: 292-295.
- [17] BREIMAN L I, FRIEDMAN J H, OLSHEN R A, et al. Classification And Regression Trees(CART) [J]. Encyclopedia of Ecology, 1984, 40(3): 582-588.
- [18] ZIMMERMANRD, MURILLO-SANCHEZ C E, THOMAS R J. Matpower: steady-state operations, planning, and analysis tools for power systems research and education [J]. IEEE Transactions on Power Systems, 2011, 26(1): 12-19.
- [19] VANFRETTI L, MILANO F. Application of the PSAT, an open source software, for educational and research purposes [C] // Power Engineering Society General Meeting. Tampa, USA: [s.n.], 2007: 24-28.
- [20] BROWNE M W. Cross-validation methods [M]. Salt Lake City, USA: Academic Press, Inc, 2000: 1-49.
- [21] PEDREGOSA F, GRAMFORT A, MICHEL V, et al. Scikit-learn: machine learning in Python [J]. Journal of Machine Learning Research, 2016, 12(10): 2825-2830.

作者简介:



张晨宇

张晨宇(1994—),男,河北保定人,硕士研究生,主要研究方向为电力系统数据挖掘(E-mail: 1099262824@qq.com);

王慧芳(1974—),女,浙江宁波人,副教授,博士,通信作者,主要研究方向为继电保护与控制、电网状态检修、电力系统数据挖掘(E-mail: huifangwang@zju.edu.cn)

(下转第 89 页 continued on page 89)

作者简介:



李建春

李建春(1979—),男,福建龙岩人,工程师,硕士,主要研究方向为特高压直流输电、柔性直流输电以及电力系统仿真技术(E-mail:lijc@nrec.com);

胡兆庆(1976—),男,湖北荆门人,高级工程师,博士,通信作者,主要从事特高压直流输电及柔性直流输电方面的研究工

作(E-mail:huzq@nrec.com);

殷冠贤(1986—),男,海南万宁人,工程师,硕士,主要从事柔性直流输电技术及大功率电力电子技术方面的研究工作;

卢宇(1977—),男,湖北宜昌人,高级工程师,硕士,主要从事特高压直流输电及柔性直流输电方面的研究工作;

李海英(1973—),男,内蒙古赤峰人,教授级高级工程师,硕士,主要从事特高压直流输电及柔性直流输电方面的研究工作。

Design and control of ±500 kV flexible HVDC valve section equivalent test

LI Jianchun, HU Zhaoqing, YIN Guanxian, LU Yu, LI Haiying

(Nanjing NR Electric Co., Ltd., Nanjing 211102, China)

Abstract: The working principle of multilevel converter arm bridge in ±500 kV flexible HVDC is analyzed, and the basic features of valve section steady-state operating conditions and the DC-side short circuit operating conditions are summarized. Based on the above analysis and the equivalent working principle of voltage stress, current stress and thermal stress of valve section in the steady-state and the short circuit operation conditions, a kind of equivalent test device circuit of power module is designed, which satisfies the requirement of the test with at least one power module of different power levels in steady-state and the short circuit operation conditions. In view of the equivalent test circuit, its control strategy is designed based on the analysis of model, and the protection and control system of the valve section based on a three-layer structure is designed. Two bridge arms composed of a five-module two-valve section system are built, and relevant tests are carried out. The test results show that the proposed equivalent test circuit of the power module test device and protection and control system of the valve section meet the test requirements, and the control method of the multi-valve section system is effective.

Key words: flexible HVDC power transmission; valve section; equivalent test circuit; control strategy; control and protection; modular multilevel converter

(上接第83页 continued from page 83)

Transient stability assessment of power system based on XGBoost algorithm

ZHANG Chenyu¹, WANG Huifang¹, YE Xiaojun²

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, China;

2. Huizhou Power Supply Company of Guangdong Power Grid Co., Ltd., Huizhou 516003, China)

Abstract: The TSA (Transient Stability Assessment) is carried out based on the improved XGBoost (eXtreme Gradient Boosting) algorithm according to the characteristics of TSA problem. The feature set that can reflect the stable operation state of power system is defined based on the physical characteristics of power grid. The TSA process with XGBoost is researched. Since the severities of two mistakes in TSA process are different, a logarithmic loss function containing the attention coefficient is defined to reduce the mistaken prediction situations of the model to unstable samples. The Logistic function is introduced to transform the model output into a probabilistic form, which is used to measure the reliability of model output to prevent part of mistaken prediction. A method to generate sample sets for any power system is given. The simulative results of IEEE 39-bus power system show that the accuracy of XGBoost is higher than that of other commonly used machine learning methods, the misclassification probability of unstable samples is reduced by the loss function after optimization, which makes the recall rate of the proposed algorithm better than other methods, and the probabilistic output format is helpful for evaluating the reliability of model output and reduces the probability of mistaken prediction.

Key words: transients; stability; XGBoost algorithm; machine learning; artificial intelligence; Logistic function

附录：

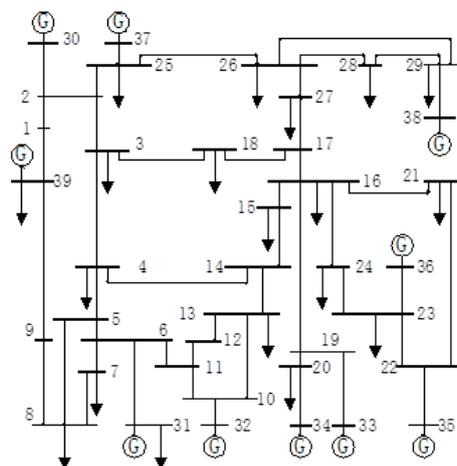


图 A1 IEEE 39 节点系统

Fig.A1 IEEE 39-bus system

表 A1 训练集准确率

Table 1 Accuracy rate of training set

算法	训练集准确率			
	故障 1	故障 2	故障 3	故障 4
XGBoost	0.994	0.985	0.998	0.999
SVM	0.950	0.972	0.986	0.982
LR	0.927	0.958	0.961	0.963
RF	0.999	0.998	0.998	0.998
KNN	0.903	0.951	0.998	0.998

表 A2 训练集召回率

Table 2 Recall rate of training set

算法	训练集召回率			
	故障 1	故障 2	故障 3	故障 4
XGBoost	0.996	0.990	0.999	0.999
SVM	0.952	0.960	0.986	0.980
LR	0.943	0.942	0.971	0.962
RF	0.998	0.998	0.999	0.998
KNN	0.887	0.912	0.997	0.999