

DOI: 10.19783/j.cnki.pspc.240132

基于失稳模式自适应捕捉的暂态稳定评估方法

张诗熠¹, 王怀远¹, 李剑², 卢国强²

(1. 新能源发电与电能变换重点实验室(福州大学), 福建 福州 350108; 2. 国网青海省电力公司, 青海 西宁 810001)

摘要: 在电力系统暂态稳定评估(transient stability assessment, TSA)问题中, 普通机器学习算法数据挖掘能力的有限性阻碍了 TSA 模型评估精度的进一步提高。针对此问题, 以电力系统数据的不同失稳模式为切入点, 提出了基于失稳模式自适应捕捉的 TSA 方法, 构建了由多个子评估模型和一个失稳模式判别模型组成的自适应判稳组合模型。首先, 根据失稳模式的不同对原始数据集进行分类, 分别训练多个针对不同失稳模式的子评估模型。然后, 利用失稳模式判别模型输出的权重值对子评估模型进行集成, 自适应完成对输入数据失稳模式的捕捉。最后, 在 IEEE39 节点系统和华东电网系统中进行测试验证。仿真结果表明, 所提方法在降低不稳定样本漏报率的同时进一步提高了模型评估精度, 验证了该方法的有效性。

关键词: 深度学习; 暂态稳定评估; 失稳模式; 集成学习; 自适应评估

Transient stability assessment method based on adaptive capture of instability patterns

ZHANG Shiyi¹, WANG Huaiyuan¹, LI Jian², LU Guoqiang²

(1. Key Laboratory of New Energy Generation and Power Conversion (Fuzhou University), Fuzhou 350108, China;
2. State Grid Qinghai Electric Power Company, Xining 810001, China)

Abstract: In the transient stability assessment (TSA) problem of a power system, the limited data mining ability of common machine learning algorithms prevents further improvement of TSA model evaluation accuracy. To solve this problem, taking different instability patterns of power system data as the entry point, a TSA method based on adaptive capture of instability patterns is proposed. An adaptive stability judgment combination model is constructed, one which is composed of multiple sub-evaluation models and an instability pattern discrimination model. First, the original data set is classified according to the different instability patterns, and several sub-evaluation models are trained for different instability patterns. Then, the weight value of the instability pattern discrimination model output is used to integrate the sub-evaluation model, and the instability pattern of the input data is captured adaptively. Finally, a case study is performed on the IEEE39-bus system and the East China power grid system. Simulation results show that the proposed method can reduce the negative rate of unstable samples and further improve model evaluation accuracy, which verifies the effectiveness of the proposed method.

This work is supported by the Natural Science Foundation of Fujian Province (No. 2022J01113).

Key words: deep learning; transient stability assessment; instability pattern; ensemble learning; adaptive evaluation

0 引言

随着现代电网互联规模的扩大、交直流输电线路混合运行和新能源比例的增加, 电力系统的安全稳定运行面临着新的挑战^[1-3]。进行快速准确的暂态稳定评估(transient stability assessment, TSA)是保证

电力系统安全稳定运行的重要手段, 通过对发生故障后的电力系统进行 TSA, 并根据 TSA 预测结果实施紧急控制措施, 尽可能避免发生大规模停电事故。传统的暂态稳定分析方法主要包括时域仿真法和直接法^[4], 因其计算效率低和难以适应复杂系统的缺点, 无法适应 TSA 在线应用的要求。

随着同步相量测量装置(phasor measurement unit, PMU)的快速发展^[5-6], 电网控制中心可实时获取系统动态响应数据, 为基于数据驱动的机器学习 TSA

基金项目: 福建省自然科学基金项目资助(2022J01113); 国网青海省电力公司科技项目资助(522800230001)

方法^[7-8]奠定了基础,如支持向量机(support vector machine, SVM)^[9-10]、K最近邻算法(k-nearest neighbor, KNN)^[11]、极端学习机(extreme learning machine, ELM)^[12]和决策树(decision tree, DT)^[13]等。相较于需要人工设计和选择合适特征的传统机器学习方法,深度学习具有更强大的数据挖掘能力,通过神经网络自动对数据进行高维抽象学习,省略了特征筛选的过程。电力系统 TSA 问题常用的深度学习模型有卷积神经网络(convolutional neural network, CNN)^[14]、深度置信网络(deep belief network, DBN)^[15]、长短记忆网络(long short-term memory, LSTM)^[16-17]、门控循环单元(gated recurrent unit, GRU)^[18]和堆叠稀疏自编码器(stacked sparse autoencoder, SSAE)^[19]等。其中, CNN 在图像和视频处理领域表现出色,擅长捕捉空间和时间的局部特征; DBN 能够在无监督学习框架内捕获数据的深层次特征; SSAE 通过引入稀疏性约束,提高了自编码器在特征学习中的效率和有效性,对于降维和去噪任务有良好效果。而 LSTM 和 GRU 都是循环神经网络的变体,能够解决梯度消失和梯度爆炸问题,适用于处理需要长期依赖关系的序列数据,如时间序列分析等。文献[17]提出由不同评估时刻 LSTM 的集成分类器和多阶段阈值评估规则构成的时间自适应电力系统暂态稳定评估方法,以平衡评估模型的准确性和及时性。文献[20]提出一种计及漏判和误判代价的两阶段集成 CNN 电力系统暂态稳定预测方法,在尽可能减少漏判样本的同时也大幅减少了误判带来的实际损失。

面对暂态稳定评估问题,任何微小的评估误差都可能导致电力系统出现安全隐患,而现有机器学习方法的数据挖掘能力有限,在实现模型评估精度最后 3%的提升方面面临较大困难,尚不能满足电力系统实际应用的需求。因此,寻找提升 TSA 机器学习模型评估精度的有效方法是十分有必要的,本文以此为目标展开了相关研究工作。样本数据是机器学习模型训练的基础,对模型的性能有着关键影响,基于机器学习的暂态稳定评估方法所使用的数据是大量电力系统故障样本。传统的机器学习 TSA 方法不对原始数据进行分类,将所有工况数据无差别地用于模型训练,得到的单一机器学习模型难以学习到合适的决策边界,处理复杂工况能力不足,并且在面对一些特定工况时准确率较差,存在欠拟合的缺点,阻碍模型评估精度的进一步提高,这种问题源于电力系统故障的多样性和复杂性。而单一工况的样本数据具有相似的特征分布和简单的变化趋势,针对单一工况的样本训练得到的机器学习模型对该工况下的故障样本拟合程度较好,可更加精

确地挖掘出该类数据特征信息,易习得针对该类数据的精确分类边界,获得更高的评估精度。故本文从电力系统数据的失稳模式出发,针对不同失稳模式数据训练不同的子评估模型。当输入扰动数据时,采用集成学习的思想,通过一个失稳模式辨识模型将子模型的结果进行加权,得到适应不同失稳模式的组合模型。

本文提出了一种基于集成学习的失稳模式自动捕捉 TSA 方法,主要贡献总结如下。

1) 根据失稳模式的不同对原始数据集进行分类,分别训练针对各类失稳模式的多个子评估模型。当输入某一失稳模式的数据时,可在相应的子评估模型上获得精度较高的暂态稳定评估结果。

2) 提出了一种捕捉实际输入数据失稳模式的方法,通过失稳模式判别模型输出的权值,对子评估模型进行加权集成,建立自适应判稳组合模型。当输入不同失稳模式的真实数据时,组合模型能够自适应输出高置信度的结果。

1 失稳模式自适应捕捉的 TSA 框架

物理驱动的暂态稳定评估方法需按照受扰系统的实际失稳模式,将机组分为超前机群和落后机群,以便多机系统进行分群等值操作。在实际电网中,故障类型、故障位置、负荷水平等因素的不同会导致受扰系统呈现出不同的失稳模式。而数据驱动模型具有一定的特征提取能力和非线性拟合能力,将采集到的所有工况数据输入模型进行训练,能够得到电气特征输入量和暂态稳定状态输出之间的映射关系,进而可根据实际数据的特征分布判别其暂态稳定性。传统的数据驱动 TSA 方法不对原始数据的失稳模式进行分类,未将失稳模式判别这一步骤考虑到训练过程中,将所有工况数据无差别地作为模型训练过程中的输入,得到的模型在大部分工况下准确率较高,但在面对一些特定工况时准确率不足,存在欠拟合的缺点。

这些在传统数据驱动 TSA 模型上准确率不足的场景,可能包含电力系统中经常发生的工况,或是对系统稳定性危害较大的故障工况。若无法对其暂态稳定性进行准确判断,则系统不能及时采取紧急控制措施使其恢复稳定运行。因此,为了提高 TSA 方法在电力系统特定工况下的评估精度,本文聚焦于电力数据的失稳模式,设计了基于失稳模式自适应捕捉的 TSA 方法。

考虑到原始数据集中包含多类失稳模式数据,为了更加有针对性地学习各类数据的特征分布,将原始训练集进行划分,失稳模式相同的归为同一类。

然后, 针对每一类数据训练一个子评估模型, 以更加精确地挖掘各类数据对应的决策边界。采用集成学习的思想, 利用各子评估模型对应的权值, 捕捉输入数据的失稳模式, 权值越大, 说明输入数据失稳模式与对应子评估模型针对的失稳模式越相似。最后, 通过各子评估模型对应的权值, 对各子评估模型的预测结果进行加权, 得到最终的预测结果, 弥补单个子评估模型分类缺陷, 提高泛化能力。

失稳模式自适应捕捉的集成学习 TSA 框架如图 1 所示, 由各子评估模型和失稳模式判别模型共同构成自适应判稳组合模型, 可得到在各类失稳模式数据上均有较高评估精度的强分类器。本文接下来需要探讨的主要有两个问题: (1) 如何训练针对特定失稳模式的子评估模型; (2) 如何对各子评估模型进行权重分配和加权集成。

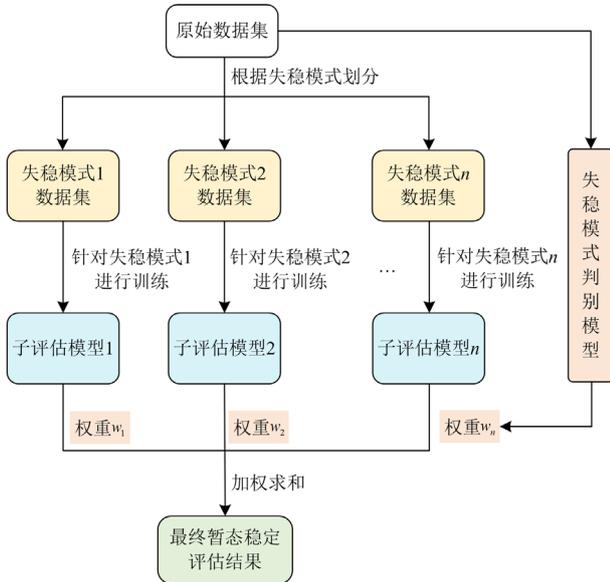


图 1 失稳模式自适应捕捉的集成学习框架

Fig. 1 Ensemble learning framework for adaptive capture of instability patterns

2 针对特定失稳模式诊断的 TSA 子模型

门控循环单元 GRU 是一种用于处理序列数据的循环神经网络结构, 能够解决梯度消失和梯度爆炸问题。GRU 通过引入更新门和重置门来控制信息的流动, 其中更新门帮助模型决定在当前状态保留多少历史信息, 而重置门决定遗忘多少历史信息。本文处理的电力系统暂态特征量属于时序数据, 因此选择 GRU 训练针对特定失稳模式数据的子评估模型。

提高子评估模型对特定失稳模式的判别精度, 主要有数据处理和损失函数构造两种方法。第一种

方法是通过对数据集的处理, 改变子评估模型训练集中不同类别样本的比例, 使其针对的类别样本在数量上占比最高, 以增加模型对该类别评估规则的挖掘能力。但是, 当原始数据集中存在各类样本数量不均衡的情况时, 某类样本的数量可能相对较少, 若采用此方法提高子评估模型对该类别样本的评估精度, 则构造的训练集样本数量较少, 训练得到的子评估模型容易出现过拟合问题, 导致模型的泛化性能较差。第二种方法是通过构造损失函数, 在模型训练过程中调整不同类别样本的损失权重, 增加目标类别的损失权重, 更精确地指导模型学习, 提高模型对该类别的关注度。通过该方法训练得到的模型, 不仅在特定失稳模式数据上表现出较高的评估精度, 而且对其他失稳模式的数据也具有良好的泛化能力。故本文采用第二种方法。

各子评估模型均采用原始数据集, 不同模型中各类别样本损失权重不同, 在提高子评估模型对目标失稳模式数据的评估精度时, 保证其泛化能力。若原始训练集中有 n 类失稳模式, 则需要训练 n 个子评估模型, 其中针对失稳模式 i 的子评估模型训练过程如图 2 所示。在子评估模型训练过程中采用代价敏感法, 引入放大因子 k , 修正子评估模型针对的特定失稳模式样本的损失函数值 L , 如式(1)所示, 使得该类样本的误分类代价大于其他类别样本, 提高子评估模型对该类样本的拟合程度。

$$L = \sum_{i=1}^m \beta_i (-y_i \log \tilde{y}_i - (1 - y_i) \log(1 - \tilde{y}_i)) \quad (1)$$

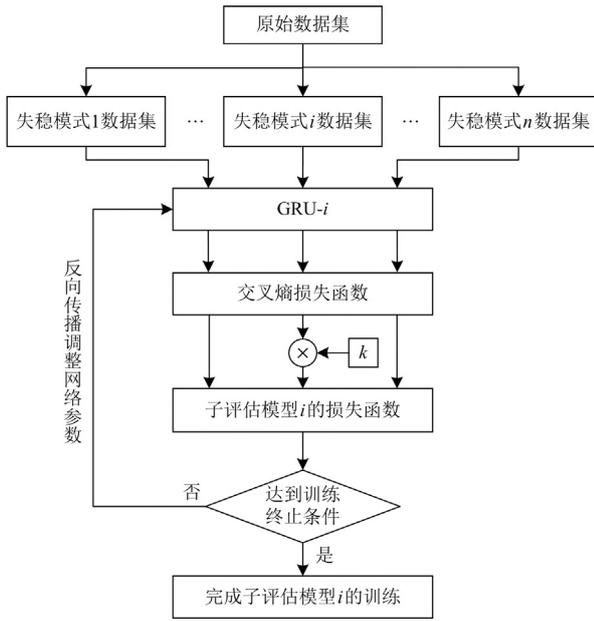
$$\beta_i = \begin{cases} k, & p_i = q \\ 1, & p_i \neq q \end{cases} \quad (2)$$

式中: m 为训练集样本数量; β_i 、 y_i 、 \tilde{y}_i 分别为第 i 个样本的代价敏感系数、真实标签、预测概率; p_i 为第 i 个样本的失稳模式类别; q 为子评估模型针对的失稳模式类别。

各子评估模型在不同失稳模式数据上均可获得较高的评估精度, 并且在针对的失稳模式上表现出相对更高的评估精度。

3 失稳模式捕捉模型

关于电力系统故障样本的失稳模式识别, 文献[21]采用注意力权重矩阵表示模型对样本中关键失稳机组的关注度, 机组的注意力权重直接反映了该机组特征量对模型评估的重要性, 机组对应的注意力权重值越高, 则代表模型对该机组的关注度越大, 进而正确识别样本的主导失稳模式, 以达到提升模型预测精度的效果。并且引入了注意力引导函数提

图2 针对失稳模式 i 的子评估模型训练过程Fig. 2 Training process of sub-evaluation model for instability pattern i

高对特定失稳模式关键机组的关注度，成功减少对于特定失稳模式样本的误判，说明机组的注意力权重分布与样本的失稳模式能够正确匹配。定义 \mathbf{S} 为样本的机组权重向量，如式(3)所示。

$$\mathbf{S} = [s_1, s_2, \dots, s_i, \dots, s_K] \quad (3)$$

式中： s_i 为系统中第 i 台发电机的权重； K 为电力系统中的发电机数量。 \mathbf{S} 中各发电机的权重分布反映了故障样本的失稳模式。

不同失稳模式样本的临界失稳机群不同，其机组权重向量也不同，通过对不同失稳模式的机组权重向量进行加权求和，可以得到实际输入数据的机组权重向量。若训练集中 n 类不同失稳模式样本的机组权重向量分别为 $\mathbf{S}^{(1)} - \mathbf{S}^{(n)}$ ，则实际样本的失稳模式 $\mathbf{S}^{(x)}$ 可以通过对不同已知失稳模式赋权来表示，如式(4)所示。

$$\mathbf{S}^{(x)} = \sum_{i=1}^n w_i \mathbf{S}^{(i)} \quad (4)$$

式中， w_i 为第 i 类失稳模式样本机组权重向量的赋权因子。

而本文针对不同失稳模式训练的不同子评估模型，在电气时序特征数据和暂态稳定预测概率之间建立了不同的非线性映射关系，均学习了对应的失稳模式信息。基于这些针对不同失稳模式的映射关系，当各子评估模型输入实际数据时，可输出不同数值的暂态稳定预测概率。当输入数据的失稳模

式与子评估模型针对的失稳模式相同或相似时，子评估模型能输出较精确的评估结果。如果两者失稳模式差异较大，则准确率有所下降。即各子评估模型之间存在一定的差异性，分类边界不同，故本文考虑将多个子评估模型进行集成，以得到更合理的分类边界，获得更高的评估精度和泛化能力，自适应输出高置信度的评估结果。关于子评估模型的集成方式，考虑到当样本输入各子评估模型时，若计算样本在各子评估模型中的机组权重向量，则此时对各子评估模型进行赋权，相当于对不同失稳模式的机组权重向量进行赋权，故根据式(4)采用加权求和的方法对子评估模型的预测结果进行集成，权重值的分配与输入数据的失稳模式有关，输入数据失稳模式与子评估模型针对的失稳模式越相似，对应子评估模型的权重值越大。对各子评估模型输出的预测概率进行加权处理，相当于通过权值的不同分配完成对输入数据失稳模式的捕捉，以得到更合理的暂态稳定评估结果。因此，本文提出了一种失稳模式判别模型，用于模型在输入实际数据时输出各类失稳模式对应子评估模型的权重。选择深度神经网络(deep neural network, DNN)挖掘样本数据到失稳模式对应权值的非线性拟合关系，实现多输入多输出的回归预测。

失稳模式判别模型采用的 DNN 结构包括输入层、隐藏层和输出层，每层都包含一组神经元，这些神经元通过加权连接进行信息传递。网络中可包含多个隐藏层，以学习从输入到输出的复杂映射关系。输入层的神经元个数通常与输入数据的维度相同，DNN 隐藏层的输出 \mathbf{x}_H 和输出层的输出 \mathbf{y}' 如式(5)和式(6)所示。DNN 通过前向传播将输入数据从输入层传递到输出层，并计算输出结果。通过反向传播算法，根据预期输出和实际输出之间的误差来更新网络的权重和偏差，优化网络参数。本文采用具有 3 个隐藏层的 DNN 模型，隐藏层采用 ReLU 激活函数，输出层采用 softmax 激活函数，激活函数用于引入非线性因素，使得神经网络能够拟合复杂的非线性关系。

$$\mathbf{x}_H = \max(0, \mathbf{W}_H \mathbf{x} + \mathbf{b}_H) \quad (5)$$

$$\mathbf{y}' = [y'_1, y'_2, \dots, y'_i, \dots, y'_o] \quad (6)$$

其中

$$\mathbf{x} = [x_1, x_2, \dots, x_T]^T \quad (7)$$

$$y'_i = \frac{\exp(z_i)}{\sum_{j=1}^o \exp(z_j)}, \quad i, j \in [1, o] \quad (8)$$

$$\mathbf{z} = \mathbf{W}_o \mathbf{x}_H + \mathbf{b}_o = [z_1, z_2, \dots, z_o] \quad (9)$$

$$\sum_{i=1}^o y'_i = 1 \quad (10)$$

式中: \mathbf{x} 为输入序列; x_T 为第 T 个时间步的特征量; \mathbf{W}_H 和 \mathbf{b}_H 分别为隐藏层的权重矩阵和偏置向量; \mathbf{z} 为对隐藏层输出的线性加权向量; z_o 为输出层第 o 个神经元的输入; \mathbf{W}_O 和 \mathbf{b}_O 分别为输出层的权重矩阵和偏置向量; y'_i 为输出层第 i 个神经元的输出。

DNN 通过在大量标记数据上进行迭代训练, 采用梯度下降算法调整网络参数以最小化损失函数。为了使组合模型对各失稳模式样本的拟合程度达到预期效果, 在训练失稳模式判别模型之前, 需要合理设置不同类失稳模式训练数据对应的权值。因灰狼优化(gray wolf optimization, GWO) 算法具有控制参数少、适用于处理高维和非线性的优化问题、收敛速度快、寻优能力强等特点^[22-23], 本文采用 GWO 算法搜索各类样本数据对应的最优权重, 以获得失稳模式判别模型所需的样本集标签。如图 3 所示, 原始数据集 D 根据失稳模式的不同可划分为 n 个数据子集 $D_1 \sim D_n$, 对于 n 类失稳模式数据可得到 n 组权重分布标签 $w_1^{(v)} \sim w_n^{(v)}$, 其中 $v=1, 2, \dots, n$ 。第 v 类数据同时输入 n 个子评估模型 GRU-1—GRU- n , 可得到对应的 0~1 范围内的预测概率结果 $R_1^{(v)} \sim R_n^{(v)}$, 参与 GWO 目标函数的构成。如式(11)所示, 由 $w_1^{(v)} \sim w_n^{(v)}$ 对 n 个结果 $R_1^{(v)} \sim R_n^{(v)}$ 进行加权求和得到自适应判稳组合模型的最终预测概率 $\hat{y}^{(v)}$, 实际失稳模式与子评估模型针对失稳模式之间的相似程度则体现在权重系数 $w_i^{(v)}$ 中, 其中 $i=1, 2, \dots, n$ 。GWO 的决策变量是 $w_1^{(v)} \sim w_n^{(v)}$, 优化目标是 minimized 最终预测概率和真实标签之间的均方误差(mean-square error, MSE), 如式(12)所示。GWO 算法优化后的权重可使组合模型对输入数据失稳模

式的捕捉效果达到最优。

$$\hat{y}^{(v)} = \sum_{i=1}^n w_i^{(v)} R_i^{(v)}, \sum_{i=1}^n w_i^{(v)} = 1 \quad (11)$$

$$M_{SE} = \frac{1}{n} \sum_{v=1}^n (\hat{y}^{(v)} - y^{(v)})^2 \quad (12)$$

式中: $R_i^{(v)}$ 为第 v 类失稳模式数据输入第 i 个子评估模型后得到的预测概率结果; $w_i^{(v)}$ 为第 v 类失稳模式关于第 i 个子评估模型的权重系数; $\hat{y}^{(v)}$ 为第 v 类失稳模式训练数据的加权预测概率, 当其大于阈值 0.5 时, 自适应判稳组合模型将对应故障样本判断为稳定样本, 否则判断为不稳定样本; $y^{(v)}$ 为第 v 类失稳模式训练数据的真实标签。

失稳模式判别模型在训练过程中, 以数据集的归一化特征量为输入, 以 GWO 算法寻优得到的权重值为真实标签。当输入实际数据时, 可以应用失稳模式识别模型捕捉实际数据的失稳模式, 判别模型将输出权重系数 $w_1 \sim w_n$, 输入数据的失稳模式与训练集中第 i 类失稳模式越相似, 第 i 个子评估模型的预测结果越重要, w_i 越大, 这为子评估模型的加权集成方式提供了可靠依据, 使自适应判稳组合模型能够根据输入数据的失稳模式合理分配子评估模型的权重。

4 基于判稳组合模型的暂态稳定评估

4.1 离线训练和在线应用

通过仿真软件得到 TSA 模型的样本数据, 模型输入特征为故障清除后各发电机的功角和角速度, 各个样本的标签由暂态稳定指数(transient stability index, TSI)计算得到。

$$T_{SI} = \frac{360^\circ - |\Delta\delta_{\max}|}{360^\circ + |\Delta\delta_{\max}|} \quad (13)$$

式中, $\Delta\delta_{\max}$ 为时域仿真结束时任意两台发电机的最大功角差。当 $T_{SI} > 0$ 时, 该样本为稳定样本, 标签为 1; 否则为不稳定样本, 标签为 0。

本文提出的暂态稳定性评估过程如图 4 所示, 将 n 类不同失稳模式的样本数据 $D_1 \sim D_n$ 用于组合模型的离线训练, 子评估模型 GRU-1—GRU- n 与失稳模式判别模型的训练过程是相互独立的。组合模型在线应用时, 对得到的电力系统实时响应数据进行特征量采集, 输入离线训练好的组合模型, 各子评估模型和失稳模式判别模型将同时输出预测概率和权重值, 通过对各子评估模型的预测概率进行加权求和, 实时获取电力系统的最终暂态评估结果。

4.2 模型性能评价指标

本文通过以下指标对模型性能进行评估。

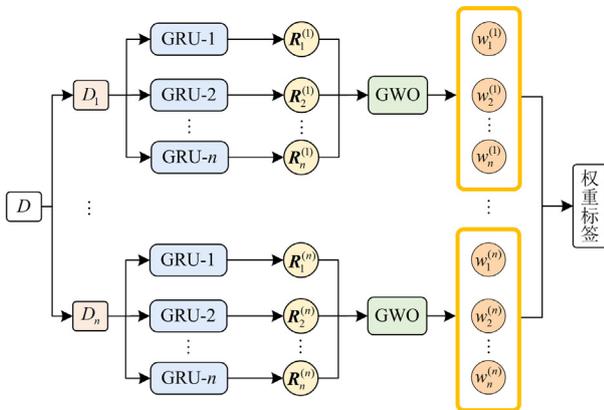


图 3 失稳模式判别模型样本集的权重标签制作

Fig. 3 Establishment of weight labels for the sample set of the instability pattern discrimination model

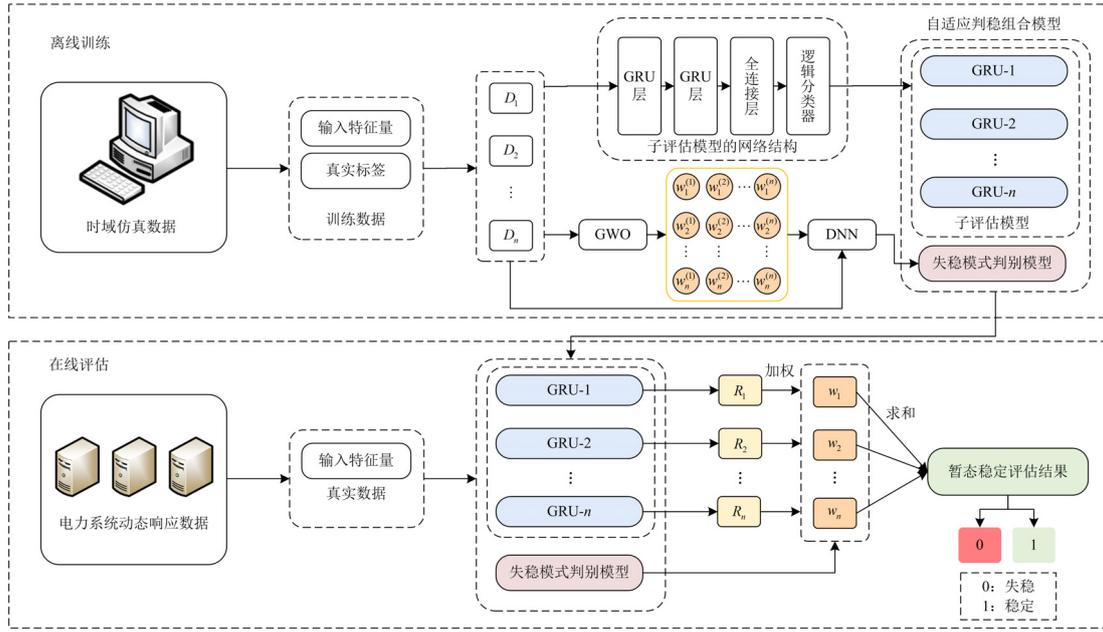


图 4 基于自适应判稳组合模型的暂态稳定评估过程

Fig. 4 Transient stability assessment process based on adaptive stability judgment combined model

(1) 全局准确率 P_{ACC}

$$P_{ACC} = \frac{T_p + T_N}{T_p + F_p + T_N + F_N} \times 100\% \quad (14)$$

(2) 误警率 P_{FA}

$$P_{FA} = \frac{F_N}{F_N + T_p} \times 100\% \quad (15)$$

(3) 漏报率 P_{FD}

$$P_{FD} = \frac{F_p}{F_p + T_N} \times 100\% \quad (16)$$

(4) 几何平均值 G_{mean}

$$G_{mean} = \sqrt{\frac{T_N}{T_N + F_p} \times \frac{T_p}{T_p + F_N}} \times 100\% \quad (17)$$

式中： T_p 、 F_N 分别为稳定样本被正确、错误评估的数量； T_N 、 F_p 分别为不稳定样本被正确、错误评估的数量。

5 算例分析

本文采用 PSD-BPA 仿真软件生成原始数据集，测试系统为 IEEE39 节点系统^[14]和华东电网系统。

5.1 IEEE39 节点系统

选取 IEEE39 节点系统的 33 条线路作为测试线路，负荷水平分别为 90%、95%、100%、105%、110%。故障类型均为三相短路故障，故障位置分别位于输电线路长度的 10%、50%和 90%处。故障持

续时间有 26 种不同的类型，范围从 6 个周波到 18.5 个周波，增量为 0.5 个周波。通过仿真共生成 15 012 个样本。稳定样本 7191 个，不稳定样本 7821 个。选取故障清除时刻和故障清除后 5 个周波各发电机的功角和角速度数据作为原始特征。

5.1.1 组合模型的评估性能

根据样本失稳模式的不同，将所有样本划分为 5 类，划分情况如图 5 所示。每类失稳模式的样本按照 4:1 的比例随机抽样，划分为训练集和测试集，利用测试集评估 TSA 模型性能，为了验证自适应判稳组合模型的有效性，对比组合模型与子评估模型输入各类失稳模式数据时的评估结果。子评估模型结构由 2 个 GRU 层、1 个全连接层和 1 个逻辑分类器组成，各层神经元数量分别为 128、64、32、1。失稳模式判别模型采用具有 3 个隐藏层的 DNN 结构，各隐藏层神经元数量为 64、32 和 8，隐藏层的激活函数均为 ReLU 函数，输出层的激活函数为 softmax 函数。

为了验证组合模型的有效性，分别输入 5 类失稳模式样本 D_1 — D_5 ，对比其在组合模型和各子评估模型 GRU-1—GRU-5 上的准确率指标，如表 1 所示，表中最后一行的平均准确率为各评估模型在不同失稳模式数据下泛化性能的量化指标，平均准确率越大，意味着模型的泛化能力越强。

对于各个子评估模型 GRU-1—GRU-5，当输入数据的失稳模式与针对的失稳模式相同时，准确率

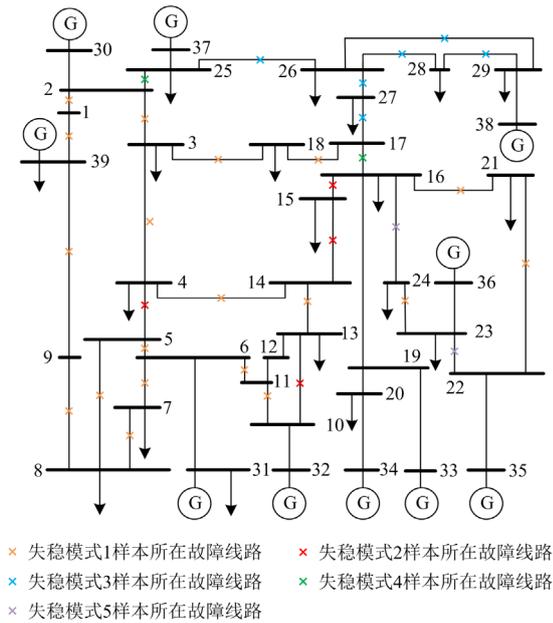


图5 IEEE39节点系统样本失稳模式分类情况

Fig. 5 Classification of instability patterns on the IEEE39-bus system samples

较高。例如, 输入 D_2 时, GRU-2 输出预测结果的准确率最高。然而, 由于 GRU-1—GRU-5 是针对各类失稳模式数据训练得到的, 当输入数据失稳模式与其针对的失稳模式差别较大时, 输出结果准确率较差, 因此 GRU-1—GRU-5 的平均准确率不够高, 泛化能力较差。

而自适应判稳组合模型是集成了 5 类失稳模式的 TSA 模型, 能够通过失稳模式判别模型输出的权重值有效捕捉输入数据的失稳模式, 因此组合模型在各类失稳模式数据上的准确度较高, 是这些模型中平均准确率最高的, 验证了本文提出的组合模型的有效性。

表1 子评估模型与组合模型的评估结果

Table 1 Evaluation results of sub-evaluation models and the combined model

| 样本 | GRU-1 | GRU-2 | GRU-3 | GRU-4 | GRU-5 | 组合模型 |
|-------|---------------|---------------|---------------|---------------|---------------|---------------|
| D_1 | 0.9897 | 0.9755 | 0.9819 | 0.9793 | 0.9826 | 0.9897 |
| D_2 | 0.9834 | 0.9862 | 0.9807 | 0.9834 | 0.9779 | 0.9862 |
| D_3 | 0.9833 | 0.9556 | 0.9945 | 0.9667 | 0.9889 | 0.9889 |
| D_4 | 0.9945 | 0.9890 | 0.9890 | 0.9945 | 0.9835 | 0.9945 |
| D_5 | 0.9817 | 0.9799 | 0.9762 | 0.9707 | 0.9890 | 0.9872 |
| 平均准确率 | 0.9865 | 0.9772 | 0.9845 | 0.9789 | 0.9844 | 0.9893 |

5.1.2 所提方法与其他 TSA 方法的比较

将自适应判稳组合模型与几种浅层机器学习算

法(DT、KNN、SVM)和深度学习方法(DBN、CNN、SSAE、LSTM、GRU)在同一数据集上的实验结果作比较。其中, DT 采用分类回归树(classification and regression tree, CART)算法; KNN 的参数 k 设置为 5; SVM 的核函数是径向基函数, 超参数 $c=10$ 、 $\gamma=0.1$ ^[24]; DBN 采用 5 层隐含层结构, 神经元的数量分别为 500、500、250、50、25; CNN 模型有 2 层卷积层, 每层卷积层后连接 2×2 的最大池化层, 最后连接 2 个全连接层, 激活函数为 ReLU 函数^[20]; SSAE 采用与 DBN 相同的网络结构; LSTM 结构为 2 个 LSTM 层、1 个全连接层和逻辑分类器。GRU 采用与 LSTM 相似结构, 为 2 个 GRU 层加上 1 个全连接层和逻辑分类器。

考虑到各评估方法的随机性, 所有试验结果均为 5 次测试后的平均性能, 试验结果如表 2 所示。

表2 不同分类模型在 IEEE39 节点系统上的评估结果

Table 2 Evaluation results of different classification models on the IEEE39-bus system

| 模型 | $P_{Acc}/\%$ | $P_{FA}/\%$ | $P_{FD}/\%$ | $G_{mean}/\%$ |
|----------|--------------|-------------|-------------|---------------|
| DT | 96.30 | 4.35 | 3.08 | 96.28 |
| KNN | 97.27 | 2.35 | 3.08 | 97.28 |
| SVM | 97.97 | 1.59 | 2.44 | 97.98 |
| DBN | 97.27 | 0.69 | 4.63 | 97.32 |
| CNN | 98.10 | 1.04 | 2.70 | 98.13 |
| SSAE | 98.47 | 1.45 | 1.61 | 98.47 |
| LSTM | 98.27 | 1.03 | 2.49 | 98.24 |
| GRU | 98.53 | 0.97 | 1.93 | 98.55 |
| GRU+本文方法 | 98.97 | 1.35 | 0.77 | 98.94 |

可以看到, 常规机器学习算法的漏报率较高, 造成全局准确率下降, 而自适应判稳组合模型的全局准确率和几何平均值最高, 并且漏报率降至 1% 以下, 降低了不稳定样本误分类给系统带来的风险。

5.1.3 自适应判稳组合模型的适应性分析

本文提出的自适应判稳组合模型由多个子评估模型和一个失稳模式判别模型构成, 其中融合了基于失稳模式自适应捕捉的 TSA 方法。考虑通过改变子评估模型的网络结构, 对本文方法的适应性进行说明。当自适应判稳组合模型的子评估模型分别采用 SVM、LSTM 和 GRU 时, 在 IEEE39 节点系统样本数据上的评估结果如表 3 所示。可以看到, 相较于单一模型, 采用基于失稳模式自适应捕捉的动态加权集成方法, 能有效提升同一数据集上的暂态稳定评估精度, 同时也证明了基于失稳模式自适应捕捉的 TSA 方法在不同子模型结构下具有良好的适应性和稳定性, 具有较为广泛的适用前景。

表 3 采用不同结构子评估模型的评估结果
Table 3 Evaluation results of sub-evaluation models using different structures

| 模型 | $P_{ACC}/\%$ | $P_{FA}/\%$ | $P_{FD}/\%$ | $G_{mean}/\%$ |
|-----------|--------------|-------------|-------------|---------------|
| SVM | 97.97 | 1.59 | 2.44 | 97.98 |
| SVM+本文方法 | 98.62 | 1.19 | 1.54 | 98.63 |
| LSTM | 98.27 | 1.03 | 2.49 | 98.24 |
| LSTM+本文方法 | 98.90 | 1.51 | 0.77 | 98.86 |
| GRU | 98.53 | 0.97 | 1.93 | 98.55 |
| GRU+本文方法 | 98.97 | 1.35 | 0.77 | 98.94 |

5.1.4 考虑噪声干扰的模型性能评估

由于在实际应用中，数据在采集和传输等过程可能会受到不同程度的噪声干扰，因此需要 TSA 模型具有较强的抗噪能力。为了验证自适应判稳组合模型具有较强的抗噪能力，和 DT、KNN、SVM、CNN、LSTM、GRU 几种常见的机器学习算法进行了噪声实验比较。在构建评估模型时的训练集数据采用无噪声的实验数据，而在测试模型准确率时，向测试集数据中分别加入信噪比为 50、40、30、25、20 dB 的高斯白噪声来模拟实际数据在测量或传输过程中由于噪声产生的误差。不同 TSA 模型对含噪声数据的评估结果见表 4。

表 4 不同噪声强度对暂态稳定评估结果的影响

Table 4 Influence of different noise intensities on transient stability evaluation results

| 模型 | 准确率/% | | | | | |
|----------|-------|-------|-------|-------|-------|-------|
| | 无噪声 | 50 dB | 40 dB | 30 dB | 25 dB | 20 dB |
| DT | 96.30 | 96.14 | 96.10 | 93.87 | 91.08 | 87.68 |
| KNN | 97.27 | 97.27 | 97.30 | 97.20 | 97.24 | 96.94 |
| SVM | 97.97 | 97.97 | 98.00 | 97.77 | 97.67 | 97.50 |
| CNN | 98.10 | 98.10 | 98.07 | 98.17 | 97.97 | 97.37 |
| LSTM | 98.27 | 98.27 | 98.37 | 98.14 | 97.80 | 96.67 |
| GRU | 98.53 | 98.40 | 98.33 | 98.37 | 97.77 | 96.74 |
| GRU+本文方法 | 98.97 | 98.97 | 98.94 | 98.62 | 98.30 | 97.70 |

可以看出，随着噪声强度增加，各评估模型的准确率有所下降。当噪声信噪比为 30 dB 时，DT 模型的准确率下降幅度较大，抗噪能力较弱，当噪声信噪比为 20 dB 时，LSTM 和 GRU 的评估性能受到较大影响，而 SVM、CNN 和组合模型的准确率仍然较高，其中组合模型的准确率保持在 97.50% 以上，说明其具有较好的抗噪能力，满足 TSA 实际应用要求。

5.2 华东电网系统

为了进一步验证本文方法的实用性，在华东电网系统中对本文所提出的自适应判稳组合模型进行

测试。测试系统包括 6040 条母线、5599 条输电线路和 705 台发电机，系统频率为 50 Hz；选取 597 条电压等级为 500 kV 或 1000 kV 的输电线路作为测试线路；相量测量单元(PMU)被配置在 426 台容量大于 200 MW 的发电机上，采样频率为 100 次/s；负荷水平为系统容量的 100%；故障发生在 500 kV 及以上电压等级的输电线路全长的 10%、50%和 90%处；故障类型为 $N-1$ 三相短路、 $N-2$ 三相短路和两相接地短路；故障持续时间为 5~20 个周波。仿真生成样本 41 999 个，其中稳定样本 32 980 个，不稳定样本 9019 个，根据失稳模式的不同将所有故障样本划分为 9 类，各类样本按 3:2 的比例划分为训练集和测试集。因华东电网系统发电机数量较多，考虑到样本特征维度显著增多的问题，适量减少时序数据样本输入模型的周波数，选择故障清除时刻和故障清除后 3 个周波所有发电机功角与角速度数据作为模型的原始特征量。

自适应判稳组合模型对实际数据失稳模式的捕捉效果，体现在各子评估模型的权重分配结果中。不同失稳模式的输入数据 $D_1 - D_9$ ，赋予各子模型 GRU-1—GRU-9 的权重如图 6 所示。图中不同行的色块表示不同失稳模式数据的权重集，色块的颜色越深，表示对应的权值越大。可以看到，失稳模式判别模型在进行权重分配时，会根据输入数据的失稳模式，将最高权重分配给与之最匹配的子评估模型，以此实现对输入数据失稳模式的捕捉。

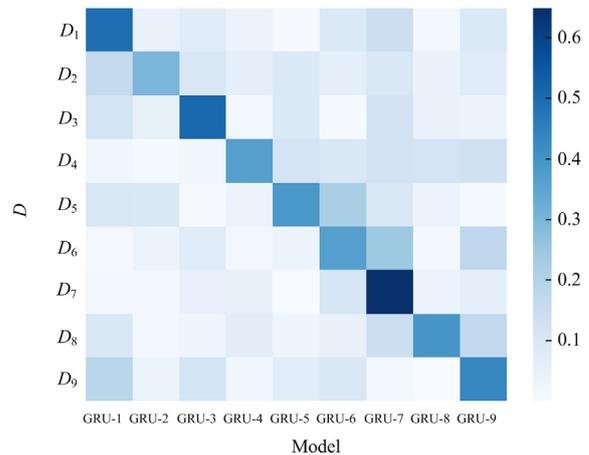


图 6 不同失稳模式在各子评估模型上的权重分布

Fig. 6 Weight distribution of different instability patterns on each sub-evaluation model

不同分类模型的评估结果如表 5 所示，组合模型在实际系统上的漏报率和误警率均低于 2%，两者之比接近 1，无明显的评估倾向性，准确率和几

何平均值最高, 说明组合模型适用于实际系统, 且评估性能优于其他机器学习方法。

表 5 不同分类模型在华东电网系统上的评估结果

Table 5 Evaluation results of different classification models on East China power grid system

| 模型 | $P_{Acc}/\%$ | $P_{FA}/\%$ | $P_{FD}/\%$ | $G_{mean}/\%$ |
|-----------|--------------|-------------|-------------|---------------|
| DT | 95.48 | 3.68 | 7.31 | 94.49 |
| KNN | 97.01 | 2.19 | 5.64 | 96.07 |
| SVM | 98.11 | 0.70 | 6.25 | 96.48 |
| DBN | 97.39 | 1.63 | 6.23 | 96.05 |
| CNN | 98.32 | 0.89 | 3.62 | 97.73 |
| SSAE | 98.10 | 0.32 | 7.82 | 95.86 |
| LSTM | 98.21 | 0.81 | 5.42 | 96.86 |
| LSTM+本文方法 | 98.43 | 1.51 | 1.76 | 98.36 |
| GRU | 98.35 | 0.71 | 5.11 | 97.06 |
| GRU+本文方法 | 98.61 | 1.34 | 1.49 | 98.58 |

5.3 模型训练时间和在线应用时间

考虑到 TSA 模型的实际在线应用要求, 在提高模型预测准确率的同时, 需要保持一定的快速性。基于 GTX1650 GPU 和 i7 10750 CPU, 对本文方法在 IEEE39 节点系统和华东电网系统中的训练时间和评估速度进行测试, 测试结果如表 6 所示。

表 6 在不同系统下组合模型的训练时间和单样本评估时间

Table 6 Training time and single-sample evaluation time of the combined model in different systems

| 测试系统 | 训练时间/s | 单样本评估时间/ms |
|-------------|--------|------------|
| IEEE39 节点系统 | 403.59 | 1.16 |
| 华东电网系统 | 847.42 | 2.93 |

可以看到, 模型测试数据中单个样本的平均评估时间在 3 ms 以内, 能够满足暂态稳定评估在线应用的快速性要求, 而模型的训练过程是离线进行的, 故模型训练时间增加是可以接受的, 并且随着数据集特征量和数量的增加, 模型的训练时间也会增加。

6 结论

以电力系统数据的不同失稳模式为切入点, 本文提出了基于自适应判稳组合模型的暂态稳定评估方法, 通过失稳模式判别模型输出的权重集成子评估模型, 在 IEEE39 节点系统和华东电网系统的仿真测试结果表明: 1) 本文训练的 GRU 子评估模型能够明显提高在针对失稳模式数据上的准确率, 同时对其他类失稳模式数据也具有一定的泛化能力; 2) 通过集成学习算法弥补了子评估模型的缺陷, 建立了分类效果更好的组合模型, 与其他机器学习算法相比具有更优的评估性能; 3) 通过失稳模式判别

模型的输出权重, 可对未知输入数据的失稳模式进行捕捉, 在降低不稳定样本的漏报率的同时提高了模型的评估精度。

参考文献

- [1] 陈征, 胡鹏飞, 戴立宇, 等. 基于锁相环的并网 VSC 暂态失稳机理与控制方法[J]. 中国电力, 2022, 55(10): 77-86.
CHEN Zheng, HU Pengfei, DAI Liyu, et al. Transient Instability mechanism and control method of pll-based grid-connected VSC[J]. Electric Power, 2022, 55(10): 77-86.
- [2] 高书宇, 刘友波, 刘挺坚, 等. 嵌入轻量梯度提升机评估模型的暂态稳定预防-紧急协调控制[J]. 电力工程技术, 2023, 42(5): 167-176.
GAO Shuyu, LIU Youbo, LIU Tingjian, et al. Transient stability prevention-emergency coordinated control embedded with assessment model of light gradient boosting machine[J]. Electric Power Engineering Technology, 2023, 42(5): 167-176.
- [3] 刘建锋, 姚晨曦, 陈乐乐. 基于门控时空图神经网络的电力系统暂态稳定评估[J]. 电力科学与技术学报, 2023, 38(2): 214-223.
LIU Jianfeng, YAO Chenxi, CHEN Lele. Power system transient stability assessment based on gating spatial temporal graph neural network[J]. Journal of Electric Power Science and Technology, 2023, 38(2): 214-223.
- [4] 朱蜀, 刘开培, 秦亮, 等. 电力电子化电力系统暂态稳定性分析综述[J]. 中国电机工程学报, 2017, 37(14): 3948-3962.
ZHU Shu, LIU Kaipei, QIN Liang, et al. Analysis of transient stability of power electronics dominated power system: an overview[J]. Proceedings of the CSEE, 2017, 37(14): 3948-3962.
- [5] 余高旺, 方陈, 樊占峰, 等. 基于汉宁窗的配电网同步相量测量装置算法及应用[J]. 中国电力, 2022, 55(6): 18-24.
YU Gaowang, FANG Chen, FAN Zhanfeng, et al. Research and application of algorithm for distribution network synchronous phasor measurement unit based on hanning window[J]. Electric Power, 2022, 55(6): 18-24.
- [6] 刘海泳, 代佰华, 朱洪防, 等. 考虑敏感区域的电压暂降监测装置优化配置[J]. 电力工程技术, 2022, 41(2): 90-96.
LIU Haiyong, DAI Baihua, ZHU Hongfang, et al. Optimal configuration of voltage sag monitors considering sensitive areas[J]. Electric Power Engineering Technology, 2022, 41(2): 90-96.
- [7] SARAJCEV P, KUNAC A, PETROVIC G, et al. Artificial intelligence techniques for power system transient stability assessment[J]. Energies, 2022, 15(2).
- [8] ZHANG S T, ZHU Z X, LI Y. A critical review of data-driven transient stability assessment of power systems: principles, prospects and challenges[J]. Energies, 2021, 14(21).

- [9] 田芳, 周孝信, 于之虹. 基于支持向量机综合分类模型和关键样本集的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2017, 45(22): 1-8.
TIAN Fang, ZHOU Xiaoxin, YU Zhihong. Power system transient stability assessment based on comprehensive SVM classification model and key sample set[J]. Power System Protection and Control, 2017, 45(22): 1-8.
- [10] WANG H Y, HU L T, ZHANG Y. SVM based imbalanced correction method for power systems transient stability evaluation[J]. ISA Transactions, 2023, 136: 245-253.
- [11] 叶圣永, 王晓茹, 刘志刚, 等. 基于 Stacking 元学习策略的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2011, 39(6): 12-16, 23.
YE Shengyong, WANG Xiaoru, LIU Zhigang, et al. Power system transient stability assessment based on Stacking meta-learning strategy[J]. Power System Protection and Control, 2011, 39(6): 12-16, 23.
- [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] LASHGARI M, SHAHRTASH S M. Fast online decision tree-based scheme for predicting transient and short-term voltage stability status and determining driving force of instability[J]. International Journal of Electrical Power and Energy Systems, 2022, 137.
- [14] 田芳, 周孝信, 史东宇, 等. 基于卷积神经网络的电力系统暂态稳定预防控制方法[J]. 电力系统保护与控制, 2020, 48(18): 1-8.
TIAN Fang, ZHOU Xiaoxin, SHI Dongyu, et al. A preventive control method of power system transient stability based on a convolutional neural network[J]. Power System Protection and Control, 2020, 48(18): 1-8.
- [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] 李楠, 朱嫻, 崔莹. 考虑代价敏感的 AC-LSTM 暂态稳定评估[J]. 电力系统保护与控制, 2022, 50(22): 160-169.
LI Nan, ZHU Yuan, CUI Ying. AC-LSTM transient stability assessment considering cost-sensitivity[J]. Power System Protection and Control, 2022, 50(22): 160-169.
- [17] 吴思婕, 王怀远. 基于集成学习的时间自适应电力系统暂态稳定评估方法[J]. 电力系统保护与控制, 2022, 50(24): 112-119.
WU Sijie, WANG Huaiyuan. Transient stability assessment of power system with time-adaptive method based on ensemble learning[J]. Power System Protection and Control, 2022, 50(24): 112-119.
- [18] CHENG S, YU Z H, LIU Y, et al. Power system transient stability assessment based on the multiple paralleled convolutional neural network and gated recurrent unit[J]. Protection and Control of Modern Power Systems, 2022, 7(3): 586-601.
- [19] 温涛, 张敏, 王怀远. 基于堆叠稀疏降噪自编码器的暂态稳定评估模型[J]. 电力工程技术, 2022, 41(1): 207-212.
WEN Tao, ZHANG Min, WANG Huaiyuan. Transient stability assessment model based on stacked sparse denoising autoencoder[J]. Electric Power Engineering Technology, 2022, 41(1): 207-212.
- [20] 吴俊勇, 张若愚, 季佳伸, 等. 计及漏判/误判代价的两阶段电力系统暂态稳定预测方法[J]. 电力系统自动化, 2020, 44(24): 44-52.
WU Junyong, ZHANG Ruoyu, JI Jiashen, et al. Two-stage transient stability prediction method of power system considering cost of misdetection and false alarm[J]. Automation of Electric Power Systems, 2020, 44(24): 44-52.
- [21] 高发骏, 王怀远, 党然. 基于 Transformer 的暂态稳定评估模型的可解释性分析与模型更新研究[J]. 电力系统保护与控制, 2023, 51(17): 15-25.
GAO Fajun, WANG Huaiyuan, DANG Ran. Interpretability analysis and model update research of a transient stability assessment model based on Transformer[J]. Power System Protection and Control, 2023, 51(17): 15-25.
- [22] 欧阳鑫, 李志斌. 基于样本扩充和特征优选的 IGWO 优化 SVM 的变压器故障诊断技术[J]. 电力系统保护与控制, 2023, 51(18): 11-20.
OUYANG Xin, LI Zhibin. Transformer fault diagnosis technology based on sample expansion and feature selection and SVM optimized by IGWO[J]. Power System Protection and Control, 2023, 51(18): 11-20.
- [23] 郭成, 谢浩, 孟贤, 等. 基于灰狼优化算法的负荷模型参数辨识[J]. 电力科学与技术学报, 2022, 37(2): 30-37.
GUO Cheng, XIE Hao, MENG Xian, et al. Journal of electric power science and technology[J]. Journal of Electric Power Science and Technology, 2022, 37(2): 30-37.
- [24] CHEN Q F, LIN N, BU S Q, et al. Interpretable time-adaptive transient stability assessment based on dual-stage attention mechanism[J]. IEEE Transactions on Power Systems, 2023, 38(3): 2776-2790.

收稿日期: 2024-01-28; 修回日期: 2024-06-04

作者简介:

张诗熠(2000—), 女, 硕士研究生, 研究方向为机器学习在电力系统中的应用; E-mail: 1367389140@qq.com

王怀远(1987—), 男, 通信作者, 博士, 副教授, 研究方向为电力系统运行与控制; E-mail: 79749544@qq.com

李剑(1986—), 男, 本科, 高级工程师, 研究方向为电力系统运行与控制。E-mail: 1229608439@qq.com

(编辑 张颖)