

考虑代价敏感的 AC-LSTM 暂态稳定评估

李楠^{1,2}, 朱媛², 崔莹³

(1. 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(东北电力大学), 吉林 吉林 132012; 2. 东北电力大学电气工程学院, 吉林 吉林 132012; 3. 广东电网有限责任公司珠海供电局, 广东 珠海 519000)

摘要: 电力系统稳定样本与失稳样本的失衡会导致数据驱动型暂稳评估模型对失稳样本的漏分率增加, 由于失稳样本漏判的代价远高于稳定样本误判的代价, 因此提出一种引入代价敏感机制的 AC-LSTM 电力系统暂态稳定评估模型。通过改进 Adaboost 算法, 引入代价敏感函数对样本权重进行更新, 更好地考虑了少数类样本对整体分类准确率的影响, 降低不稳定样本的漏分率。并进一步将改进的 Adaboost 算法和长短期记忆网络(long short-term memory, LSTM)相结合以提高分类器的综合性能。在 IEEE39 和 IEEE140 节点系统上的仿真结果表明, 所提模型较其他模型具有良好的适应性和泛化能力, 提升了评估模型的综合性能, 其抗噪能力也优于其他模型。

关键词: 暂态稳定评估; 样本不平衡; 代价敏感; Adaboost; LSTM

AC-LSTM transient stability assessment considering cost-sensitivity

LI Nan^{1,2}, ZHU Yuan², CUI Ying³

(1. Key Laboratory of Modern Power System Simulation and Control & Renewable Energy Technology, Ministry of Education (Northeast Electric Power University), Jilin 132012, China; 2. School of Electrical Engineering, Northeast Electric Power University, Jilin 132012, China; 3. Zhuhai Power Supply Bureau of Guangdong Power Grid Corporation, Zhuhai 519000, China)

Abstract: When the data-driven transient stability assessment model is used to judge the stability of power system, there can be an increase in the false positive rate of unstable samples. This is due to the imbalance between stable samples and unstable samples. Also the cost of misjudgment of unstable samples is much higher. An AC-LSTM transient stability assessment model with a cost-sensitive mechanism is proposed. By improving the Adaboost algorithm and introducing a cost-sensitive function to update the sample weights, the influence of minority samples on the overall classification accuracy is eliminated to minimize the false positive rate of unstable samples. In addition, the improved AdaBoost algorithm is integrated with long short-term memory (LSTM) to improve the comprehensive performance of the classifier. The simulation results on the IEEE39-bus and IEEE140-bus systems show that the model proposed has better adaptability and generalization ability than others, and the comprehensive evaluation performance is improved. In addition, the anti-noise ability is also better than other models.

This work is supported by the National Natural Science Foundation of China (No. 61973072).

Key words: transient stability assessment; sample imbalance; cost-sensitive; Adaboost; LSTM

0 引言

随着特高压直流输电系统和可再生能源的快速发展^[1-3], 电网的风险水平和运行难度逐渐增加。暂态稳定评估(transient stability assessment, TSA)是对电力系统在元器件故障、短路故障等扰动后的暂态

稳定性进行预先评估的一种方法^[4-5]。如果系统判断暂态不稳定, 就会触发相应的紧急控制措施, 并导致大规模停电、电力设备损坏等情况。因此, 暂态稳定评估对电网的安全稳定运行至关重要^[6]。

传统的时域仿真法^[7-8]和直接法^[9]由于计算量大、耗时长、抗扰能力差等, 不能很好地应用于电力系统的在线稳定评估。随着 PMU^[10]的广泛应用, 机器学习^[11-12]可获取大量样本进行离线训练及更新

学习,基于数据驱动的 TSA 模型具有速度快、精度高等优点。但机器学习大多属于浅层学习,对于复杂电力大数据的处理能力有限,难以适应真实电力系统的复杂评估。近年来,利用深度学习^[13-14]来评估电力系统暂态稳定取得了较大的进展,常用的模型有卷积神经网络(convolutional neural networks, CNN)、堆叠自动编码器(stacked auto encoder, SAE)、循环神经网络(recurrent neural network, RNN)和长短期记忆网络(long short-term memory, LSTM)等。文献[15]基于 SAE 并利用深层模型自动提取特征数据完成分类评估。文献[16]训练 CNN 模型并与时域仿真相结合,提高了 CNN 的分类性能。上述算法应用于 TSA 时多以处理静态数据为主,而 RNN 及其变形(如 LSTM)等模型的出现,为处理时间序列数据提供了新的研究思路。文献[17]将注意力机制的 LSTM 模型应用于 TSA 中,有效地处理了时间序列变量,提高了预测精度。

电力系统的运行特点决定了电力大数据中稳定样本与失稳样本的数量分布是不均衡的。分类评估时,即使存在一定的失稳样本被误分类的情况,由于稳定样本数量上的优势,评估模型仍可得到较高的准确率。但是,如果将不稳定样本误分为稳定样本,会给电力系统带来巨大的安全风险。在已有的研究中,数据不平衡^[18]问题可在样本层面和算法层面进行改进。样本层面的处理方法大多借助于数据采样法使整体样本趋于平衡。文献[19]提出了 EasyEnsemble 算法对数据集进行欠采样,仿真结果表明其综合指标和训练时间皆优于不进行样本处理的原算法。但由于欠采样后的样本数要少于原来的样本数,因此会造成一些信息缺失。文献[20]通过 SMOTE 算法随机生成少数类样本来均衡样本类别,但该方法会导致对多数类的错误分类,从而影响模型的整体平衡。文献[21]利用改进的 SMOTE 算法在部分少数类样本中合成新样本,间接改变和更新权重,产生了更好的分类模型。上述方法虽平衡了不同类别样本的数量,但未考虑数据间的整体关系,同时过多地捕捉了训练数据中的噪声,影响了分类边界的确定,使模型的泛化能力变弱。算法层面的处理包括模型融合、增量模型和代价敏感方法。文献[22]将多种算法通过 bagging 方法集成,充分发挥各自模型优势,提高了 TSA 的分类性能。文献[23]基于随机森林进行暂态稳定裕度评估,相比单个决策树提高了模型的泛化能力。文献[24]使用改进的 XGBoost 算法,在进行 TSA 的同时减小不稳定样本错误分类的可能性。上述从算法层面进行改进的方法在某些噪音较大的分类或回归问题上会产生过拟合。文献

[25]提出一种采用焦点损失函数(focal loss, FL)的方法来解决样本的不平衡问题。该方法在平衡交叉熵的基础上引入调制因子增大对少数样本的关注度,其本质属于一种代价敏感方法。文献[26]通过引入焦点损失函数,调整权重系数来修正模型训练的倾向性,将其与深度残差收缩网络相结合实现 TSA 模型的改进。但焦点损失函数中超参数的数量相对较多且具有一定的耦合关联性,模型训练时参数的微小变化会导致评估结果产生较大的差异性,调参难度较大。

为减小样本不平衡对评估模型的影响,提升评估模型的综合性能,本文将增量模型与代价敏感相结合,提出一种改进的 AC-LSTM (adaboost-lstm based on cost-sensitive learning)暂态稳定评估模型。该模型在弱分类器迭代构建强分器的过程中引入代价敏感机制,改进样本权重更新策略,提高误分代价高的样本权重,减小分类正确的样本权重,从而更多地考虑了少数类样本对分类准确率的影响。评估模型在线应用时,因获取的电力数据为动态时间序列,故借助 LSTM 在处理长时间序列时能较好地解决梯度问题的优势,将其与 Adaboost 算法^[27]相结合,进一步提升了评估模型的综合性能。并在 IEEE39 节点和 IEEE140 节点系统上进行测试,验证了所提评估模型的有效性。

1 算法介绍

1.1 LSTM 算法

RNN 是用于处理序列数据的神经网络,当时间间隔增大时,RNN 会出现“梯度消失”问题,严重影响模型处理时间数据的能力。LSTM 是 RNN 网络的改进模型,该模型通过引入门限机制来控制信息的累计速度,并可以选择地遗忘之前的信息,从而有效地解决了 RNN 网络中的长期依赖问题。LSTM 网络的时序结构如图 1 所示,其中 S 是隐藏单元,C 是新增的状态单元, x 是输入时间序列数据。

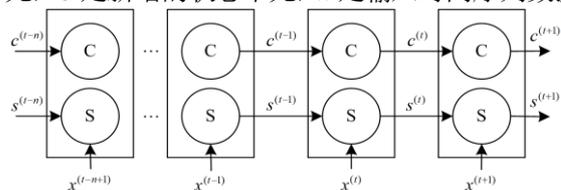


图 1 LSTM 网络的时序结构

Fig. 1 Temporal structure of LSTM network

图 2 为在任意时刻 t 下 LSTM 的隐含层结构,相比 RNN 来说,在 LSTM 的隐含层中引入了门结构,分别为遗忘门、输入门和输出门。每个门通过

激活函数的神经层和逐点乘法操作允许信息有选择地通过。遗忘门的作用是丢弃上一时刻的状态单元 $c^{(t-1)}$ 中不重要的信息, 该门经过激活函数在时刻 t 的输出 $f^{(t)}$ 的表达式为

$$f^{(t)} = \sigma(\mathbf{W}_f \cdot [s^{(t-1)}, x^{(t)}] + \mathbf{b}_f) \quad (1)$$

式中: σ 为 sigmoid 函数; $[s^{(t-1)}, x^{(t)}]$ 表示将上一个隐层单元的输出 $s^{(t-1)}$ 和当前输入 $x^{(t)}$ 连接起来; \mathbf{W}_f 和 \mathbf{b}_f 分别为遗忘门的权重和偏置向量。

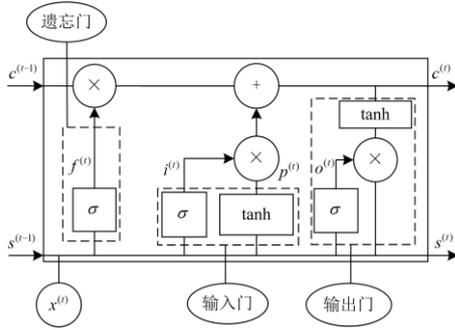


图 2 LSTM 隐层结构

Fig. 2 LSTM hidden layer structure

输入门的作用是决定当前网络的输入中有多少可以被保存到细胞状态单元 C 中。输入 $x^{(t)}$ 分别经由左右两条支路进行处理并送入乘法器后输出, 支路的参量关系分别为

$$i^{(t)} = \sigma(\mathbf{W}_i \cdot [s^{(t-1)}, x^{(t)}] + \mathbf{b}_i) \quad (2)$$

$$p^{(t)} = \tanh(\mathbf{W}_p \cdot [s^{(t-1)}, x^{(t)}] + \mathbf{b}_p) \quad (3)$$

式中: $i^{(t)}$ 、 $p^{(t)}$ 分别为两条支路的输出; 激活函数分别为 sigmoid 函数和 tanh 函数; \mathbf{W}_i 、 \mathbf{W}_p 为权重向量; \mathbf{b}_i 、 \mathbf{b}_p 为偏置向量。

根据更新后的单元状态, 输出门将输出一个新的细胞状态, 计算和更新方程分别为

$$o^{(t)} = \sigma(\mathbf{W}_o \cdot [s^{(t-1)}, x^{(t)}] + \mathbf{b}_o) \quad (4)$$

$$c^{(t)} = i^{(t)} \cdot p^{(t)} + f^{(t)} \cdot c^{(t-1)} \quad (5)$$

$$s^{(t)} = o^{(t)} \cdot \tanh(c^{(t)}) \quad (6)$$

式中: $o^{(t)}$ 为输出门的输出; $c^{(t)}$ 当前时刻状态单元的输出; $s^{(t)}$ 为当前时刻隐层单元的输出; \mathbf{W}_o 和 \mathbf{b}_o 分别为输出门的权重和偏置向量。

本文应用 LSTM 基于以下几点考虑:

1) 具有快速适应变化的能力, 能深入挖掘电力数据特征间的关联性;

2) 可有效解决梯度消失和梯度爆炸的问题, 克服时间序列长期依赖问题, 能快速捕捉电力数据的实变动态信息;

3) 对噪声有较强的鲁棒性。

1.2 Adaboost 算法

Adaboost 算法是一种具有自适应性质的 Boosting 集成学习算法, 其自适应主要表现在每次迭代之后, 错误分类实例的权值自动增加, 而正确分类实例的权值自动降低。其具体的算法流程如下:

令训练样本集 $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, 其中 x_k 为第 k 个样本的输入特征, y_k 为第 k 个样本的标签, $y_k \in \{-1, 1\}$, $k = 1, 2, 3, \dots, n$, n 为训练集的样本数;

1) 初始化训练样本权重。样本的初始权重为

$$\mathbf{w}^1 = (w_{11}, w_{12}, \dots, w_{1n})^T, w_{1k} = \frac{1}{n} \quad (7)$$

式中, w_{1k} 表示第 1 次迭代中第 k 个样本的权重。

2) 更新训练样本权重。

(1) 对于 $i = 1, 2, 3, \dots, m$, m 为基学习器的数目, 使用权重分布为 \mathbf{w}^i 的样本集进行训练, 得到基学习器 L_i 。

(2) 计算 L_i 在训练集上的分类错误率 e_i , 计算公式为

$$e_i = \sum_{k=1}^n w_{ik} I(L_i(x_k) \neq y_k) \quad (8)$$

式中, $I(\cdot)$ 为二值化函数, 当 $L_i(x_k) \neq y_k$ 时, $I(\cdot)$ 取值为 1, 否则为 0。

(3) 确定 L_i 的组合权重 α_i 。 L_i 的权重值与其分类性能有关, e_i 越小, α_i 越大, 故 α_i 为

$$\alpha_i = \frac{1}{2} \ln \frac{1 - e_i}{e_i} \quad (9)$$

(4) 更新训练集上的样本权重, 用于下一次迭代, 更新公式为

$$\mathbf{w}^{i+1} = \begin{cases} \frac{w_{ik} \exp(-\alpha_i), L_i(x_k) = y_k}{Z_i} \\ \frac{w_{ik} \exp(\alpha_i), L_i(x_k) \neq y_k}{Z_i} \end{cases} \quad (10)$$

化简后, 得

$$\mathbf{w}^{i+1} = \frac{w_{ik} \exp(-\alpha_i y_k L_i(x_k))}{Z_i} \quad (11)$$

式中, Z_i 为归一化因子, 确保更新后的权重符合概率分布, 计算公式为

$$Z_i = \sum_{k=1}^n w_{ik} \exp(-\alpha_i y_k L_i(x_k)) \quad (12)$$

(5) 当 $i < m$ 时, 令 $i = i + 1$ 并返回步骤 2); $i \geq m$ 时, 继续执行步骤 3)。

3) 将训练得到的 m 个基学习器 L_1, L_2, \dots, L_m 按权重 α_i 进行组合, 生成强分类器 L 。

$$L = \text{sign} \left(\sum_{i=1}^m \alpha_i L_i(x) \right) \quad (13)$$

式中, $\text{sign}(\cdot)$ 为符号函数。

Adaboost 算法通过迭代更新权重训练不同的基分类器, 加权构成性能更好的强分类器, 提高了分类器的精度。同时通过权重的更新, 使得 Adaboost 可以专注于困难样本的分类, 以减少训练误差。

2 代价敏感的 AC-LSTM 暂态稳定评估

2.1 Ada-LSTM 算法

传统的 Adaboost 是以决策树作为基分类器进行训练, 但决策树存在以下缺点: (1) 针对不平衡样本集, 决策树很可能在某些类占主导地位时, 创建出有偏异的树而导致精度下降; (2) 决策树极易出现过拟合问题, 其抗噪能力较差。LSTM 具有快速适应场景急剧变化的能力, 可对样本集中隐含的特征进行充分挖掘, 进而提升分类性能, 且 LSTM 能充分逼近复杂的非线性关系, 对噪声有较强的鲁棒性和容错能力。本文将 LSTM 作为基分类器进行训练, 算法整体框架如图 3 所示。

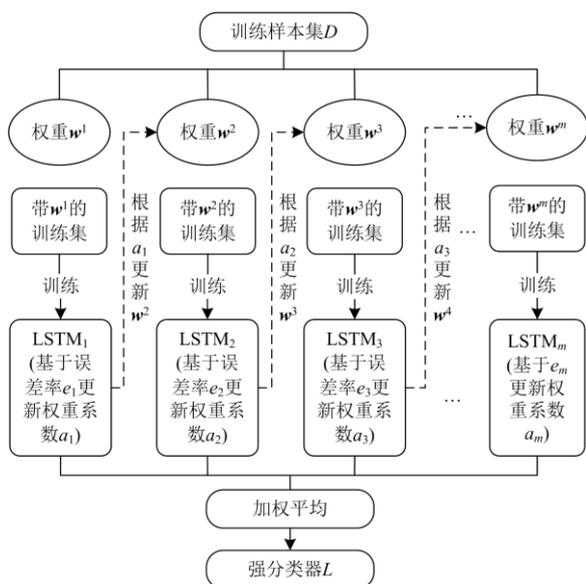


图 3 Ada-LSTM 算法框架

Fig. 3 Ada-LSTM algorithm framework

本文将多个 LSTM 网络通过 Adaboost 算法的思想经过训练构建成为强分类器。初始时每个样本的权重是相同的, 在训练过程中通过前一个网络的分类结果对下一个网络的样本权重进行调整, 调整后的样本集继续训练, 直到达到预先指定的迭代次数。最后的分类结果为将 m 个学习得到的分类器进行加权求和后经过符号函数的映射值。

2.2 代价敏感机制的设计

由于稳定样本和不稳定样本数量不平衡, 需要设计代价敏感机制来提高分类器的性能。代价敏感机制是为不同类型的错误分类设置不同的代价参数。由于参数的调整, 两类样本在训练过程中对模型的调整程度是不同的, 代价参数越大的类, 其判别性能越好。

本文在 Ada-LSTM 算法中引入代价敏感机制, 提出了 AC-LSTM 评估模型, 其权值更新规则是使错误分类样本的权值更积极地增大, 而使正确分类样本的权值更保守地减小。本文将稳定样本与不稳定样本数量上的比值定义为样本不平衡度。关注到样本的不平衡度对模型的影响, 及在电力应用背景下两类样本被误分后的代价不同, 在权重更新式(11)中引入代价调整因子 β , 改善由于样本不平衡导致少数样本被漏分的情况, 改进后第 $i+1$ 次迭代的权重更新公式为

$$w^{i+1} = \frac{w_{ik} \exp(-\alpha_i y_k L_i(x_k) \beta_i)}{Z_i} \quad (14)$$

$$\beta_+ = -0.5C_k + 0.5, \beta_- = 0.5C_k + 0.5 \quad (15)$$

式中: C_k 为第 k 个样本的分类代价; β_+ 、 β_- 分别表示样本被正确和错误分类情况下 β_i 的取值。

2.3 性能评价指标

评价指标在分类器的构建和性能的评估中起着重要作用, 是指导分类模型参数调整的关键, 传统上采用准确率 P_{ACC} 来衡量模型的性能。然而, 当样本类别的数量不平衡时, 多数样本的判别结果主导了模型的性能, 因此需要定义更详细、具体的指标来评价模型的性能。本文通过构造混淆矩阵来评估算法的分类效果, 混淆矩阵的具体表示如表 1 所示。

表 1 混淆矩阵

Table 1 Confusion matrix

混淆矩阵		预测值	
		稳定(1)	失稳(-1)
真实值	稳定(1)	f_{++}	f_{+-}
	失稳(-1)	f_{-+}	f_{--}

在评估类分布不均衡数据的分类性能时, 一般使用 P_{Gmean} 。与 P_{ACC} 相比, P_{Gmean} 值能反映模型对失稳样本的预测效果, 重视不平衡数据下的少数类, 对于衡量和评价数据更有利。故本文选用 P_{ACC} 、 P_{FN} (误分率)、 P_{FP} (漏分率)和 P_{Gmean} 作为评价分类性能的指标, 对模型进行评价, 计算公式分别为

$$P_{ACC} = \frac{f_{++} + f_{--}}{f_{++} + f_{+-} + f_{-+} + f_{--}} \times 100\% \quad (16)$$

$$P_{FN} = \frac{f_{+-}}{f_{++} + f_{+-}} \times 100\% \quad (17)$$

$$P_{FP} = \frac{f_{-+}}{f_{+-} + f_{-+}} \times 100\% \quad (18)$$

$$P_{Gmean} = \sqrt{(1 - P_{FN})(1 - P_{FP})} \times 100\% \quad (19)$$

式中： f_{++} 和 f_{--} 分别为稳定和失稳样本预测正确的个数； f_{+-} 和 f_{-+} 分别为稳定和失稳样本误判的数量。

2.4 迭代次数的设置

超参数值的选取是模型获得最佳性能的关键，本文通过迭代次数和代价敏感参数的联合优化来训练模型。通过保持其中一个参数不变，训练另一个参数来实现两个参数的联合优化。

迭代次数即训练基分类器的个数，每迭代一次即完成一个基分类器的训练。本节通过设置不同的迭代次数以及样本不平衡度，观测迭代次数对评估模型性能的影响。为消除随机因素对试验结果的影响，本实验重复进行 200 次，取其均值作为最终结果。以迭代次数 2 为步长，仿真结果如图 4 所示。

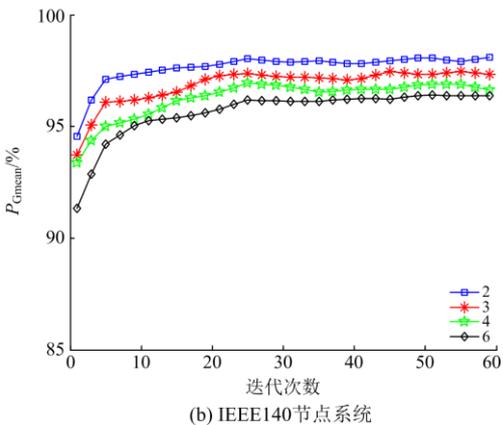
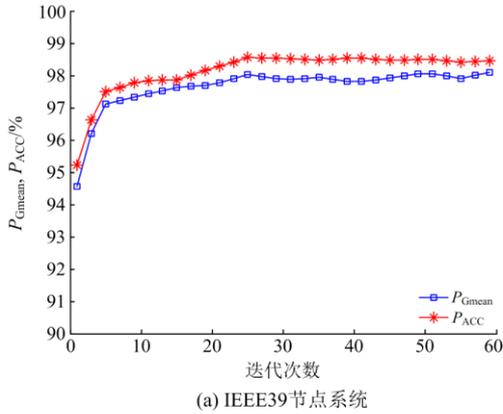


图 4 迭代次数及不平衡度对模型性能影响分析

Fig. 4 Analysis of the effect of iteration number and imbalance degree on model performance

从图 4 结果可以看出，模型的 P_{ACC} 和 P_{Gmean} 值随着迭代次数的增加呈现波动上升，并趋于平缓稳定的态势，该现象的原因如下：(1) 根据集成学习思想，基分类器的叠加效果决定了最终强分类器的分类能力，随着基分类器个数的增加，分类效果会显著提升。(2) 理论上随着迭代次数的增加，训练的错误率上界会逐渐下降，有效地解决了过拟合问题。从仿真结果看，随着基分类器数量的增加， P_{ACC} 和 P_{Gmean} 呈现小幅值上升并趋向于稳定的态势，但算法的执行效率会下降，复杂度急剧上升，算法消耗的时间成本也相应增加。因此，迭代次数应在时间成本与模型性能间权衡选择。(3) 由于模型引入了代价敏感机制，数据集中不同的样本平衡度并不影响迭代次数与模型评估性能关系的总体规律。从图 4(a) 中可以看出，当迭代次数大于 25 时， P_{ACC} 和 P_{Gmean} 值波动较小；从图 4(b) 可以看出，在不同的样本不平衡度下，模型的性能随着迭代次数的增加呈上升趋势，同样在迭代 25 次之后逐渐趋于稳定。考虑到时间成本和评估性能之间的平衡，本文在下面的仿真中将基分类器的数量设置为 25。

2.5 代价敏感参数的设置

代价调整因子 β_i 中 C_k 的取值也会对模型的性能产生影响。错误分类代价可通过代价敏感方法进行修正，错误分类代价越高，拟合程度越好。当样本分类错误时，将稳定样本错分为不稳定样本的代价权重参数记为 C_{01} ，相反的代价权重参数记为 C_{10} 。下面通过仿真来分析设置不同代价敏感参数对模型性能的影响，固定稳定样本误分代价 C_{01} 的值为 1， C_{10} 的参数设置分别考虑以下 3 种方案。

方案 1: 将 C_{10} 的值设为不稳定样本和稳定样本的比值，即 $C_{10} < 1$ ，使稳定样本的代价权重高于不稳定样本的代价权重。

方案 2: 令 $C_{10} = C_{01} = 1$ ，即不引入代价参数。

方案 3: 将 C_{10} 的值设为稳定样本和不稳定样本的比值，即 $C_{10} > 1$ ，使不稳定样本的代价权重高于稳定样本的代价权重。

3 种方案的模型性能如表 2 所示(仿真中样本的不平衡度为 4)。

表 2 不同方案下的模型性能

Table 2 Model performance with different cases				
方案	$P_{ACC} / \%$	$P_{FP} / \%$	$P_{FN} / \%$	$P_{Gmean} / \%$
方案 1	96.99	2.86	3.92	96.61
方案 2	96.64	3.22	4.68	96.05
方案 3	97.79	0.69	5.37	96.94

由表 2 可知，代价敏感参数的取值影响了分类器的性能。在电力系统 TSA 的实际应用中，不稳定

样本漏分所造成的损失更为严重, 方案 1 无法有效提高不平衡样本在训练过程中的权重; 而方案 3 稳定样本的误分率虽比方案 1 高, 但其不稳定样本的漏分率明显优于其他方案, 减小了由于对失稳样本误判引发电力安全事件的机率, 有效地发挥了代价敏感学习算法的优越性。因此, 下文中将代价调整函数中的权重参数 C_{10} 设置为稳定样本与失稳样本的数量比值。

2.6 代价敏感模型的性能分析

本节将引入代价敏感的方法与其他处理不平衡样本问题的方法进行对比, 测试结果如表 3 所示。SMOTE 算法和欠采样为数据层面的改进, RF、XGBoost 和 FL-LSTM 为算法层面的模型。其中本文所提 AC-LSTM 中 LSTM 模型的超参数设置如下: 采用 Adam 优化算法, 网络层数为 2, Batchsize 为 64, 学习率为 0.001, Epoch 为 100, 隐层单元设为 50, 激活函数为 sigmoid 函数, 整体 AC-LSTM 的迭代次数为 25, 代价调整函数中权重参数 C_{10} 设置为稳定样本与失稳样本的数量比值, 在本节中设置为 4。RF 基分类器数量为 70, 最大深度为 10; XGBoost 基分类器数量为 100, 最大深度为 10; FL-LSTM 模型的超参数权重和调节因子分别设置为 0.25 和 2, 其 LSTM 的参数设置同 AC-LSTM 模型中一致。

表 3 处理不平衡样本问题的不同方法对比

Table 3 Comparison of different methods for dealing with imbalanced sample problems

方法	$P_{ACC} / \%$	$P_{FP} / \%$	$P_{FN} / \%$	$P_{Gmean} / \%$
欠采样 ^[19]	96.37	2.79	5.12	96.04
SMOTE ^[20]	96.91	2.54	3.90	96.78
RF ^[23]	96.52	2.83	4.25	96.46
XGBoost ^[24]	97.19	4.60	2.27	96.55
FL-LSTM	97.16	3.28	4.19	96.26
AC-LSTM	97.79	0.69	5.37	96.94

由表 3 可以看出, 基于代价敏感模型 AC-LSTM 的失稳样本 P_{FP} 是最低的, 从而大大减少了在实际问题中不稳定样本被误分为稳定样本的情况, 在一定程度上避免了严重的后果。代价敏感模型稳定样本的误分率 P_{FN} 相对其他算法略高, P_{FN} 是将稳定样本误分为不稳定样本, 其对电力系统的安全风险影响不大, 且本文所提模型的 P_{Gmean} 和 P_{ACC} 最优, 综合评估性能最好。

3 算例分析

3.1 样本生成

在 IEEE39 节点和 IEEE140 节点系统上对本文所提模型进行了测试。电力系统仿真软件为中国电

科院的 PSD-BPA, 编程语言为 python, 计算机配置为 R7-5800 CPU/RTX 3060Ti/16GB RAM。

电力系统运行工况参数设置如下:

- 1) 算例考虑 80%, 85%, 115%, 120% 共 9 种负荷水平, 并相应改变发电机出力, 维持系统功率平衡;
- 2) 故障类型设置为电力系统中最严重的三相短路故障, 故障位置设置在每条线路的 0, 10%, 20%, 90% 处;
- 3) 故障发生时刻为 0 s, 在故障发生后 0.1 s、0.15 s、0.18 s、0.2 s 故障切除;
- 4) 总仿真时长为 10 s, 仿真步长为 0.01 s, 取故障清除后 12 个周波的数据;

5) 在故障后一段时间内, 系统任意 2 台发电机之间功角差大于 360° , 则判定系统失稳, 反之稳定。

母线电压作为系统的潮流数据, 对故障的响应比转子角快^[28], 能准确反映系统的运行情况, 且可通过 PMU 量测得到。因此本文取故障清除后的母线电压幅值构建模型的输入特征集。

IEEE39 节点系统通过仿真获取样本 12 240 个, 其中稳定样本 8123 个, 不稳定样本 4117 个。对于 IEEE140 节点系统通过仿真获取样本 22 026 个, 其中稳定样本 16 744 个, 不稳定样本 5281 个。并按照 8:1:1 的比例划分训练集、验证集和测试集。

3.2 仿真结果分析

为验证本文所提 AC-LSTM 评估模型的有效性, 将其与 DT、KNN、SVM、Adaboost、LSTM 及 Ada-LSTM 评估模型进行对比。上述模型在两套不同电力系统上的对比结果如表 4 所示。其中 AC-LSTM 的超参数设置同 2.6 节; DT 采用 CART 算法, 评估指标为基尼系数, 最大深度设置为 7; KNN 中的超参数 k 值为 6, 距离参数 p 为 2, 即使用欧氏距离度量; SVM 使用径向基函数作为核函数, 其中超参数惩罚因子 C 的取值为 $[10^{-4}, 10^4]$ 、核函数参数 γ 的取值为 $[2^{-8}, 2^8]$; Adaboost 基分类器使用 CART 分类树, 最大深度为 10; LSTM 和 Ada-LSTM 模型中的 LSTM 参数与 AC-LSTM 中的参数一致。

由表 4 可以看出, 相较于其他评估模型, 本文所提 AC-LSTM 模型的 P_{ACC} 和 P_{Gmean} 最高。与 Ada-LSTM 模型相比, AC-LSTM 在两套电力系统上对不稳定样本的漏分率分别降低了 2.83% 和 0.67%, 这是因为训练集中样本的不平衡度分别为 2 和 3, 代价敏感模型更倾向于区分不稳定样本, 使稳定样本与不稳定样本之间的数量不平衡对模型的影响得到有效的修正, 从而提高了评价模型的整体准确性和 P_{Gmean} , 证明了改进的有效性。

表 4 两套电力系统上不同评估模型的性能对比

Table 4 Performance comparison of different evaluation models on two power systems

	IEEE39 节点系统				IEEE140 节点系统			
	$P_{ACC}/\%$	$P_{FP}/\%$	$P_{FN}/\%$	$P_{Gmean}/\%$	$P_{ACC}/\%$	$P_{FP}/\%$	$P_{FN}/\%$	$P_{Gmean}/\%$
DT	96.40	4.26	3.25	96.24	98.50	2.91	1.04	98.02
KNN	96.16	8.31	1.49	95.04	97.33	8.87	0.40	95.27
SVM	95.55	8.07	2.55	94.65	97.59	7.55	0.80	95.77
Adaboost	95.92	7.11	2.57	95.13	98.26	4.01	0.99	97.49
LSTM	97.05	5.77	1.39	96.40	98.43	4.37	1.22	97.19
Ada-LSTM	97.86	3.21	1.36	97.71	98.98	2.41	0.78	98.40
AC-LSTM	98.67	0.38	3.54	98.03	99.07	1.74	0.53	98.86

3.3 不平衡度对模型性能的影响分析

为进一步说明本文所提算法对不平衡类样本分类性能的影响，设置多组不同的样本不平衡度进行实验，其中IEEE39 节点系统的样本不平衡度设置为 2、3、4、5、6，IEEE140 节点系统的样本不平衡度设置为 3、4、5、6，得到两套系统在不同样本不平衡度下的模型性能对比，如图 5 所示。

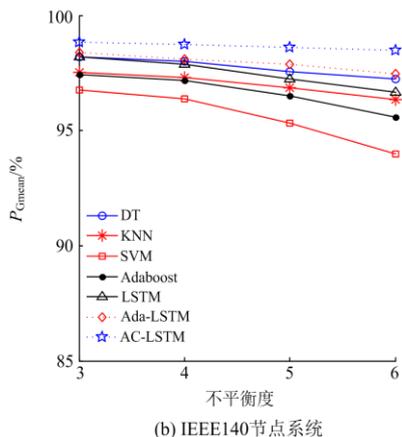
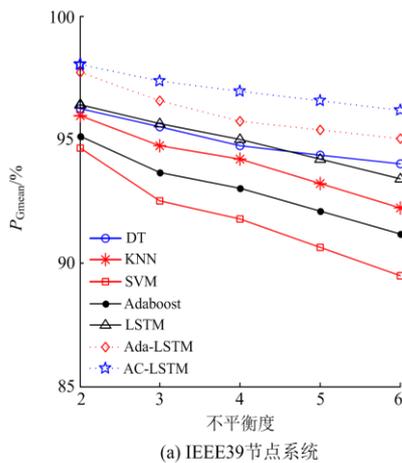


图 5 两套系统在不同样本不平衡度下的模型性能对比

Fig. 5 Model performance comparison of two systems under different sample unbalances

传统的学习算法在不平衡数据中具有较大的局限性。从图 5 可以看出，随着数据集不平衡度的增加，其他模型在 P_{Gmean} 上的性能表现得越来越差，而本文所提的 AC-LSTM 模型具有较好的稳健性。

3.4 抗噪性能分析

在实际应用中，PMU 在测量并采集电力数据时必定存在噪声污染问题。为了验证所提评估模型对 PMU 测量噪声的鲁棒性，本节在两套电力系统上，对 PMU 测量时受到两类噪声干扰进行仿真实验。当信噪比分别为 40 dB、30 dB、20 dB 时，在两类噪声影响下各模型的 TSA 结果如表 5 和表 6 所示。

第 1 组是对原始样本集均匀加入不同程度的高斯白噪声来模拟测量误差；第 2 组为突发噪声，这种噪声反映了测量值的随机突变性，在任意给定时刻，考虑每个发电机的测量值有 0.1 的概率发生噪声污染，因此该类噪声要比均匀噪声更真实。

从表 5 和表 6 可以看出，在两类噪声的干扰下，对比模型的 P_{ACC} 及 P_{Gmean} 都受到一定程度的影响。但本文提出的 AC-LSTM 评估模型， P_{ACC} 仍能保持在 98% 以上，且精度下降程度也比其他模型轻微，对 PMU 噪声具有良好的鲁棒性。另外，通过对比表 5 和表 6 可以看出，整体上加入突发噪声所造成的影响要比第 1 组的小，第 2 组的 P_{ACC} 和 P_{Gmean} 普遍比第 1 组的高，且随着噪声水平的变化下降缓慢，由于突发噪声具有随机性且小概率加入，其评估性能比较稳定。

3.5 拓扑结构的变化

为验证所提模型在拓扑变化上的影响，本文随机切除一条线路，并提取母线电压幅值构造数据集。先对完整拓扑的数据集进行训练，再将 $N-1$ 下得到的数据集作为测试集进行测试，并与其他模型所得结果进行对比， P_{ACC} 和 P_{Gmean} 测试结果如图 6 所示。

表 5 两套电力系统上不同程度高斯白噪声下各模型性能对比

Table 5 Performance comparison of different models under different degrees of white Gaussian noise on two power systems

测试系统	评估模型	$P_{ACC}/\%$				$P_{Gmean}/\%$			
		无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB
IEEE39 节点系统	DT	96.40	96.01	94.28	92.81	96.24	95.37	93.63	92.16
	KNN	96.16	95.75	95.26	94.71	95.04	94.36	94.18	92.94
	SVM	95.55	95.47	95.41	94.98	94.65	94.55	94.53	93.98
	Adaboost	95.92	95.02	94.61	92.97	95.13	94.15	93.71	91.93
	LSTM	97.05	95.83	95.18	95.09	96.40	94.82	95.31	94.87
	Ada-LSTM	97.86	97.30	96.52	96.22	97.71	97.48	96.57	95.15
	AC-LSTM	98.67	98.31	98.04	97.47	98.03	97.89	97.52	96.73
IEEE140 节点系统	DT	98.50	98.48	97.25	96.70	98.02	97.93	96.12	95.27
	KNN	97.33	97.24	96.97	96.95	95.27	94.00	93.94	93.95
	SVM	97.59	97.61	97.58	97.50	95.77	95.69	95.77	95.63
	Adaboost	98.26	97.87	97.56	97.13	97.49	96.38	96.53	95.52
	LSTM	98.43	98.10	97.73	97.19	97.19	96.94	96.40	96.09
	Ada-LSTM	98.98	98.76	98.42	98.06	98.40	98.43	97.93	96.60
	AC-LSTM	99.07	98.95	98.67	98.17	98.86	98.75	98.57	97.54

表 6 两套电力系统上不同程度突变噪声下各模型性能对比

Table 6 Performance comparison of different models under different degrees of mutation noise on two power systems

测试系统	评估模型	$P_{ACC}/\%$				$P_{Gmean}/\%$			
		无噪声	40 dB	30 dB	20 dB	无噪声	40 dB	30 dB	20 dB
IEEE39 节点系统	DT	96.40	96.32	95.85	95.25	96.24	95.93	95.53	95.34
	KNN	96.16	95.95	95.39	95.18	95.04	94.89	94.03	94.25
	SVM	95.55	96.07	95.86	95.56	94.65	95.23	94.88	94.26
	Adaboost	95.92	95.34	95.10	94.93	95.13	94.62	94.11	94.11
	LSTM	97.05	96.89	96.57	96.72	96.40	96.75	96.02	95.38
	Ada-LSTM	97.86	97.58	96.94	96.71	97.71	97.66	96.73	96.24
	AC-LSTM	98.67	98.48	98.16	97.93	98.03	97.96	97.81	97.54
IEEE140 节点系统	DT	98.50	98.87	98.50	98.29	98.02	98.42	97.95	97.56
	KNN	97.33	97.31	97.31	97.27	95.27	94.00	94.00	93.97
	SVM	97.59	97.59	97.58	97.57	95.77	95.77	95.74	95.74
	Adaboost	98.26	98.03	97.88	97.42	97.49	97.19	96.29	96.72
	LSTM	98.43	98.22	97.87	97.48	97.19	97.21	97.08	96.83
	Ada-LSTM	98.98	98.99	98.56	98.53	98.40	98.52	98.42	97.92
	AC-LSTM	99.07	99.05	98.98	98.97	98.86	98.70	98.57	98.47

由图 6 可以看出, 由于拓扑结构发生变化, 各算法的性能与完整拓扑下的性能相比大大降低, 但本文所提 AC-LSTM 模型的 P_{ACC} 和 P_{Gmean} 均高于其他模型, 因此具有较强的适应性和泛化能力。

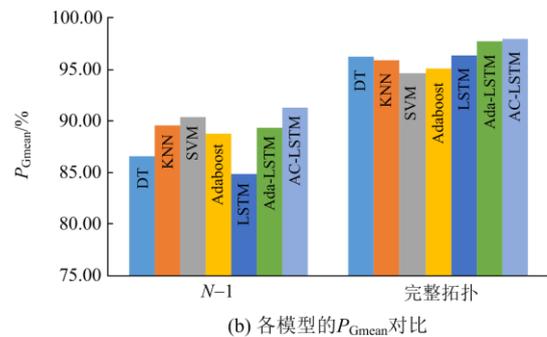
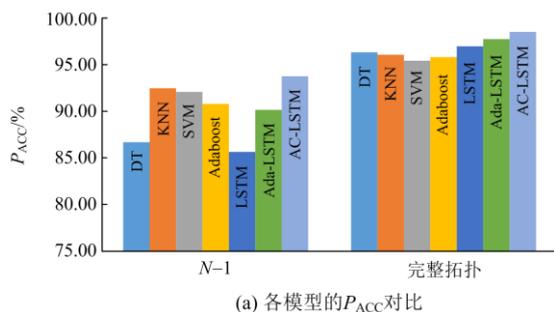


图 6 不同拓扑结构下模型的性能对比

Fig. 6 Performance comparison of models under different topologies

4 结论

本文提出了以 LSTM 为基分类器, 并通过改进 Adaboost 算法训练构造的 AC-LSTM 评估模型。该模型引入了代价敏感机制, 对样本分类不平衡问题进行处理, 旨在减少由于失稳样本漏分造成的电力重大安全事故。在 IEEE39 节点和 IEEE140 节点系统上进行了仿真分析, 得到以下结论:

1) 与其他机器学习构造的评估模型相比, 本文所提模型具有优良的综合性能及可靠性。此外, 引入的代价敏感机制提高了失稳样本的识别准确率, 从而降低失稳样本的漏分率, 并优于其他处理样本不平衡的方法, 具有更好的分类性能。

2) 对于数据采集存在噪声的问题, 通过添加两类不同的噪声进行仿真分析, 本文所提模型仍具有较高的 P_{ACC} 和 P_{Gmean} , 对噪声具有较好鲁棒性。

3) 当面对拓扑变化的情况时, 本文所提模型虽比其他对比模型具有更强的适应性和泛化能力, 但仍未达到理想效果。因此, 如何提取出未训练的拓扑变化与已知拓扑之间的特征相似性, 提升拓扑结构改变时分类器的性能, 以及如何选择合理的更新方案, 是未来研究的重点。

参考文献

- [1] 李欣悦, 李凤婷, 尹纯亚, 等. 直流双极闭锁故障下送端系统暂态过电压计算方法[J]. 电力系统保护与控制, 2021, 49(1): 1-8.
LI Xinyue, LI Fengting, YIN Chunya, et al. Transient overvoltage calculation method of HVDC sending-end system under DC bipolar blocking[J]. Power System Protection and Control, 2021, 49(1): 1-8.
- [2] 王璐, 李凤婷, 尹纯亚, 等. 考虑直流电流变化的 HVDC 系统不对称故障换相失败分析[J]. 电力系统保护与控制, 2021, 49(1): 17-23.
WANG Lu, LI Fengting, YIN Chunya, et al. Analysis of asymmetric fault commutation failure in an HVDC system with DC current variation[J]. Power System Protection and Control, 2021, 49(1): 17-23.
- [3] 文劲宇, 周博, 魏利岫. 中国未来电力系统储电网初探[J]. 电力系统保护与控制, 2022, 50(7): 1-10.
WEN Jinyu, ZHOU Bo, WEI Lishen. Preliminary study on an energy storage grid for future power system in China[J]. Power System Protection and Control, 2022, 50(7): 1-10.
- [4] KUNDUR P, PASERBA J, AJJARAPU V, et al. Definition and classification of power system stability[J]. IEEE Transactions on Power Systems, 2004, 19(3): 1387-1401.
- [5] REN Chao, XU Yan, ZHANG Yuchen. Post-disturbance transient stability assessment of power systems towards optimal accuracy-speed tradeoff[J]. Protection and Control of Modern Power Systems, 2018, 3(2): 194-203.
- [6] YUAN Minyu. Research on risk assessment and planning of distribution networks integrating large-scale distributed photovoltaics[D]. Hefei: Hefei University of Technology, 2020.
- [7] 汪芳宗. 大规模电力系统暂态稳定性数值计算方法[M]. 北京: 科学出版社, 2013.
- [8] 曹树立, 汪芳宗, 刘涛, 等. 基于二次向量场的暂态稳定性快速数值计算方法[J]. 电力系统保护与控制, 2021, 49(10): 37-42.
CAO Shuli, WANG Fangzong, LIU Tao, et al. Fast transient stability simulation using the quadratic vector field method[J]. Power System Protection and Control, 2021, 49(10): 37-42.
- [9] CHANG H D, CHU C C, CAULEY G. Direct stability analysis of electric power systems using energy functions: theory, applications, and perspective[J]. Proceedings of the IEEE, 1995, 83(11): 1497-1529.
- [10] APPASANI B, JHA A V, MISHRA S K, et al. Communication infrastructure for situational awareness enhancement in WAMS with optimal PMU placement[J]. Protection and Control of Modern Power Systems, 2021, 6(1): 124-135.
- [11] 刘雷涛. 基于机器学习的电力系统暂态稳定评估[D]. 北京: 华北电力大学, 2017.
LIU Leitao. Transient stability assessment of power system based on machine learning[D]. Beijing: North China Electric Power University, 2017.
- [12] 叶圣永, 王晓茹, 刘志刚, 等. 基于受扰严重机组特征及机器学习方法的电力系统暂态稳定评估[J]. 中国电机工程学报, 2011, 31(1): 46-51.
YE Shengyong, WANG Xiaoru, LIU Zhigang, et al. Power system transient stability assessment based on severely disturbed generator attributes and machine learning method[J]. Proceedings of the CSEE, 2011, 31(1): 46-51.
- [13] 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.
- [14] 刘谋海, 胡军华, 丁国栋, 等. 基于深度学习的电力监控视频超分辨率重建[J]. 电力系统保护与控制, 2021, 49(11): 181-187.

- LIU Mouhai, HU Junhua, DING Guodong, et al. Super-resolution reconstruction of a power monitoring video based on deep learning[J]. Power System Protection and Control, 2021, 49(11): 181-187.
- [15] 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.
- ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[J]. Proceedings of the CSEE, 2018, 38(10): 2937-2946.
- [16] 田芳, 周孝信, 史东宇, 等. 基于卷积神经网络综合模型和稳态特征量的电力系统暂态稳定评估[J]. 中国电机工程学报, 2019, 39(14): 4025-4032.
- TIAN Fang, ZHOU Xiaoxin, SHI Dongyu, et al. Transient stability assessment of power system based on convolutional neural network comprehensive model and steady-state characteristic quantities[J]. Proceedings of the CSEE, 2019, 39(14): 4025-4032.
- [17] WANG X, ZHOU Q, HUANG C, et al. A transient stability assessment method using LSTM network with attention mechanism[C] // 2019 IEEE 8th International Conference on Advanced Power System Automation and Protection (APAP), October 21-24, 2019, Xi'an, China: 120-124.
- [18] TAN B, YANG J, TANG Y, et al. A deep imbalanced learning framework for transient stability assessment of power system[J]. IEEE Access, 2019, 7: 81759-81769.
- [19] LIU X Y. Exploratory under-sampling for class-imbalance learning[C] // Sixth International Conference on Data Mining (ICDM'06), December 18-22, 2006, Hongkong, China: 965-969.
- [20] RODRIGUEZ-TORRES F, CARRASCO-OCHOA J A, MARTINEZ-TRINIDAD J F. Deterministic oversampling methods based on SMOTE[J]. Journal of Intelligent and Fuzzy Systems, 2019, 36(5): 4945-4955.
- [21] BEJ S, DAVTYAN N, WOLFIEN M, et al. LoRAS: an oversampling approach for imbalanced datasets[J]. Machine Learning, 2021, 110(2): 279-301.
- [22] 赵冬梅, 谢家康, 王闯, 等. 基于 Bagging 集成学习的电力系统暂态稳定在线评估[J]. 电力系统保护与控制, 2022, 50(8): 1-10.
- ZHAO Dongmei, XIE Jiakang, WANG Chuang, et al. On-line transient stability assessment of a power system based on Bagging ensemble learning[J]. Power System Protection and Control, 2022, 50(8): 1-10.
- [23] 王彤, 刘九良, 朱劲璇, 等. 基于随机森林的电力系统暂态稳定评估与紧急控制策略[J]. 电网技术, 2020, 44(12): 4694-4701.
- WANG Tong, LIU Jiuliang, ZHU Shaoxuan, et al. Transient stability assessment and emergency control strategy based on random forest in power system[J]. Power System Technology, 2020, 44(12): 4694-4701.
- [24] 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.
- [25] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2020, 42(2): 318-327.
- [26] 卢锦玲, 郭鲁豫. 基于改进深度残差收缩网络的电力系统暂态稳定评估[J]. 电工技术学报, 2021, 36(11): 2233-2244.
- LU Jinling, GUO Luyu. Power system transient stability assessment based on improved deep residual shrinkage network[J]. Transactions of China Electrotechnical Society, 2021, 36(11): 2233-2244.
- [27] 曹莹, 苗启广, 刘家辰, 等. AdaBoost 算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
- CAO Ying, MIAO Qiguang, LIU Jiachen, et al. Advance and prospects of adaboost algorithm[J]. Acta Automatica Sinica, 2013, 39(6): 745-758.
- [28] ZHANG R, WONG K P, XU Y, et al. Post-disturbance transient stability assessment of power systems by a self-adaptive intelligent system[J]. IET Generation Transmission & Distribution, 2015, 9(3): 296-305.

收稿日期: 2022-02-23; 修回日期: 2022-08-25

作者简介:

李楠(1973—), 女, 通信作者, 博士, 副教授, 研究方向为数据挖掘在电力系统中的应用; E-mail: jllinan@163.com

朱媛(1999—), 女, 硕士研究生, 研究方向为深度学习在电力系统中的应用; E-mail: zhuy1346@163.com

崔莹(1987—), 男, 博士, 研究方向为低压电力线载波通信。E-mail: cuiying794758706@126.com

(编辑 许威)