

基于堆叠变分自动编码器的电力系统暂态稳定评估方法

王怀远, 陈启凡

(福州大学 电气工程与自动化学院, 福州 福建 350116)

摘要:通过模型的构建和特征量的提取2个方面,提出了一种具有较好抗噪能力的暂态稳定性判别模型。模型的构建采用堆叠变分自动编码器,并在训练过程中引入L2正则化,加强了稳定性判别模型的泛化能力。同时,特征量的提取时刻与传统方法不同,通过设定所有发电机最大功角差值的阈值,当系统发展至该阈值时,进行特征量的提取。在IEEE 39节点系统中进行仿真验证,仿真结果表明,采用上述特征量提取方法,大幅降低了稳定性判别模型的误判率,同时设定合理的阈值并不会影响实时控制措施的启动,加强了模型的抗噪能力。

关键词:深度学习;堆叠变分自动编码器;暂态分析;稳定性;抗噪能力;特征量;电力系统

中图分类号:TM 731

文献标志码:A

DOI:10.16081/j.epae.201911032

0 引言

随着新能源接入比例的增加,新能源的间歇性和随机性对电力系统造成的冲击越来越大;同时由于能源与电力消费的分布不均,我国构建了大容量远距离的输电网络。电网结构的过渡和演变、省级电网与大区电网的关联约束、交直流和多直流的相互影响等因素,使电网大扰动行为特性发生巨大变化,电力系统的安全稳定运行将面临新的挑战^[1-4]。由于电力系统地域宽广、设备众多,其运行变量的变化十分迅速,仅靠局部信息的控制措施已越来越难以确保其良好的动态性能。因此,基于广域测量系统(WAMS)的电力系统的暂态稳定性判别与控制具有重大的研究价值^[5-6]。

随着同步相量测量装置(PMU)在电网的逐步安装,控制中心已经能够从WAMS实时获取系统各个动态的响应信息。随着大数据技术的兴起,基于数据驱动的方法扩展了传统的模式识别类方法,这为工作人员从大数据的角度分析电力系统的安全稳定性奠定了基础。数据驱动型的暂态稳定判别模型,只需要构建输入量与输出量之间的映射模型,将系统的实时响应量输入模型中,即可快速获得系统稳定与否的状态信息。目前已经展开了大量的研究工作,主要集中于应用人工神经网络技术(ANN)^[7]、决策树(DT)^[8]、K-最邻近(K-NN)^[9]、支持向量机(SVM)^[10]、深度学习^[11]等机器学习算法进行电力系统的稳定性评估。

由于实时信息在采集、传输等各个过程都有可

能受到噪声的干扰^[12-13],这会对后续的系统状态评估造成很大的影响。针对噪声可能会对基于机器学习模型的评估结果造成影响,本文从2个方面去考虑降低噪声带来的影响:①从模型本身出发,增强模型在分类时的泛化能力;②从提取的特征量出发,增强输入量对临界情况的辨识度。

变分自动编码器(VAE)^[14-15]是自编码器的一种,VAE能够对高维原始特征量进行提取,抽象成低维的高阶特征量而尽可能多地保留原本的信息。与一般的自编码器不同,VAE基于变分贝叶斯推断,通过寻找高阶隐藏变量所满足的高斯分布,使得映射得到的高阶特征具有更强的鲁棒性,有利于增强分类器的泛化能力。

噪声会对数据造成影响,导致判别结果出现错误,根据实验结果发现,噪声带来的误判大多数集中在临界情况下,因此如果所提取的特征量在临界稳定与临界不稳定情况下的差异更加明显,就能够减少噪声带来的干扰。对于基于数据驱动的判别模型而言,输入的特征量需要故障发生的各个阶段信息,而故障后的特征量最能反映临界情况差异。因此,考虑通过延迟故障后特征量的提取时刻以降低噪声影响。

本文通过构建基于堆叠变分自动编码器(SVAE)的判别模型,利用VAE的强泛化能力,降低噪声对评估结果的影响。同时,设置一个故障后的功角阈值,当系统内的所有发电机之间的最大功角差达到设置阈值时,进行特征量提取,通过延迟故障后特征量的提取时刻,加强提取数据在临界情况下的差异,由此降低噪声对评估结果的影响。

1 VAE模型

自编码器是深度学习中的一种无监督学习模型,先通过编码器将高维特征映射到低维度的隐藏

收稿日期:2019-01-14;修回日期:2019-09-30

基金项目:福建省中青年骨干教师教育科研项目(JT180018)

Project supported by the Scientific Research Projects of Fujian Province Young and Middle-aged Teacher Education (JT180018)

表示,再通过解码器将输入特征量复现,结构见图1。




图1 自编码器结构

Fig.1 Structure of self-encoder

编码器将高维原始输入特征量 $\mathbf{x} = [x_1, x_2, \dots, x_m]$ 映射到一个低维隐藏空间向量 $\mathbf{z}$ (n 维), 解码器再将 $\mathbf{z}$ 映射到一个 m 维输出层, 从而实现了原始输入特征量的复现。不同于传统的自编码器直接将原始输入映射成隐藏层向量, VAE 将原始输入映射成一组特殊的概率分布, 再从得到的概率分布中进行随机采样得到隐藏空间向量, VAE 的结构见图2。图中, σ_i 为 n 维标准差向量 $\boldsymbol{\sigma} = [\sigma_1, \sigma_2, \dots, \sigma_n]$ 中的第 i 个元素; μ_i 为 n 维数学期望向量 $\boldsymbol{\mu} = [\mu_1, \mu_2, \dots, \mu_n]$ 的第 i 个元素; 若随机变量 X 服从一个数学期望为 $\boldsymbol{\mu}$ 、方差为 $\boldsymbol{\sigma}^2$ 的正态分布, 记为 $N(\boldsymbol{\mu}, \boldsymbol{\sigma}^2)$; I 为单位矩阵。




图2 VAE原理结构

Fig.2 Principal structure of VAE

VAE 假设隐藏变量 $\mathbf{z}$ 的后验分布 $p(\mathbf{z}|\mathbf{x})$ 满足多元高斯分布, 即:

$$\ln p(\mathbf{z}|\mathbf{x}) = \ln N(\mathbf{z}|\boldsymbol{\mu}, (\text{diag}(\boldsymbol{\sigma}))^2) \quad (1)$$

VAE 将原始输入特征映射到 2 组 n 维隐藏层, 其输出分别为后验分布 $p(\mathbf{z}|\mathbf{x})$ 所对应的高斯分布的 2 个参数——数学期望向量 $\boldsymbol{\mu}$ 和标准差向量 $\boldsymbol{\sigma}$ 。隐藏空间向量 $\mathbf{z}$ 可以通过对 $N(\boldsymbol{\mu}, (\text{diag}(\boldsymbol{\sigma}))^2)$ 分布采样得到, 但如果直接对 $N(\boldsymbol{\mu}, (\text{diag}(\boldsymbol{\sigma}))^2)$ 分布进行随机采样, 将会导致无法使用反向传播算法对 VAE 进行优化。为了避免这个问题, 本文使用重参数技巧对数据进行采样。采样值 $\mathbf{z}$ 的计算为:

$$\mathbf{z} = \boldsymbol{\mu} + \boldsymbol{\sigma} \otimes \boldsymbol{\varepsilon} \quad (2)$$

其中, $\boldsymbol{\varepsilon}$ 为对 n 维独立标准高斯分布的一次随机采样

值; $\otimes$ 表示元素积。得到采样值 $\mathbf{z}$ 之后便可以通过解码器复现输入特征量。

VAE 模型训练的目标是最小化重构误差和使 $p(\mathbf{z}|\mathbf{x})$ 尽可能地接近标准多元高斯分布。VAE 的损失函数为:

$$L_{\text{VAE}} = 0.5(L_{\text{xent}} + L_{\text{KL}}) \quad (3)$$

$$L_{\text{xent}} = -\frac{1}{m} \sum_{i=1}^m [x_i \ln x'_i + (1 - x_i) \ln (1 - x'_i)] \quad (4)$$

$$L_{\text{KL}} = -0.5 \sum_{i=1}^n (1 + \ln \sigma_i^2 - \mu_i^2 - \sigma_i^2) \quad (5)$$

其中, x_i 为原始第 i 维输入特征量; x'_i 为复现的第 i 维原始输入特征量。

损失函数由 2 个部分组成: 其一为交叉熵损失函数, 用来度量复现特征与原始输入特征之间的差异程度; 其二为相对熵损失函数, 即 KL (Kullback-Leibler) 散度, 用来度量 $p(\mathbf{z}|\mathbf{x})$ 与标准多元高斯分布之间的差异程度。

2 建模过程

2.1 特征量的提取

选择合适的初始输入特征对于暂态稳定性的判别有着至关重要的影响。而对于系统暂态稳定性的判别, 提取的特征量需要包含故障前、故障中和故障后的响应信息。由于系统的暂态稳定性与发电机的运行状态息息相关, 因此本文选择故障发生前时刻、故障发生时刻、故障清除后时刻所有发电机的功角、角速度、机械功率、电磁功率等作为评估模型的输入特征量。

对于故障后特征量的提取, 目前的文献基本是在故障清除后采用固定的时间延迟进行特征量的提取, 且设定的时间延迟往往很短。采用这样的设定, 其故障后的稳定性判别速度很快, 但是所提取的特征量中包含的故障后系统调速器、调压器等控制器的信息不足, 且临界稳定与临界不稳定之间的特征量差异也不够明显, 会对部分临界情况造成误判。

为改善对临界情况的误判率, 本文通过设定一个功角阈值, 当故障后发电机之间的最大功角差值 $\Delta\delta_T$ 达到阈值时, 进行特征量的提取, 如式(6)所示。

$$\Delta\delta_T = \delta_{\max, T} - \delta_{\min, T} \quad (6)$$

其中, $\delta_{\max, T}$ 和 $\delta_{\min, T}$ 分别为系统内发电机组在 T 时刻所对应的最大功角和最小功角。故障后的特征量提取时刻取群内最大功角差值达到 $\Delta\delta_T$ 时, 所对应的时刻, 此时即为稳定性的判别时刻。

对于多机系统, 假定失稳系统为两群模式, 可将系统中的发电机分为两群: 超前机群 (S) 和滞后机群 (A)。对 S 群和 A 群分别进行等值^[16], 2 个机群的等值功角分别为:

$$\begin{cases} \delta_S = \sum_{g \in S} M_g \delta_g / \sum_{g \in S} M_g \\ \delta_A = \sum_{g \in A} M_g \delta_g / \sum_{g \in A} M_g \end{cases} \quad (7)$$

其中, M_g 和 δ_g 分别为发电机 g 的惯量和功角。

两机系统可以进一步等值为单机无穷大系统, 其等值功角如式(8)所示。

$$\delta_{eq} = \delta_S - \delta_A \quad (8)$$

$$\sum_{g \in S} M_g \delta_g / \sum_{g \in S} M_g = \delta_S \leq \delta_{\max} \quad (9)$$

$$\sum_{g \in A} M_g \delta_g / \sum_{g \in A} M_g = \delta_A \geq \delta_{\min} \quad (10)$$

因此可得:

$$\Delta \delta_T \geq \delta_{eq, T} \quad (11)$$

当系统的最大功角差值达到 $\Delta \delta_T$ 时, 等值单机无穷大系统的等值功角一定是小于等于 $\Delta \delta_T$ 。因此, 以单机无穷大系统为例, 只要设置的阈值 $\Delta \delta_T$ 不超过一定幅值(如 60°), 即可保证判别时刻是在不稳定平衡点之前。

采用这样的故障后特征量提取方法, 有以下几点好处: ①由于设定了功角阈值, 导致稳定性的判别时刻与故障的严重程度相关, 只要设定合适的功角阈值并不会造成控制措施无法实施; ②功角阈值设定得越大, 提取的特征量中所包含的调速器、调压器等控制器的控制信息越多, 越有利于稳定性的判别; ③临界情况之间的差异随着功角阈值设定的增加而愈发明显, 有利于提高对临界情况的评估。

2.2 评估模型的结构设计

SVAE 是将多个 VAE 堆叠构成的深层网络结构, SVAE 逐层降低输入特征的维度, 提取出高阶特征。整个模型的训练过程分为无监督的预训练和有监督的微调 2 个阶段。评估模型的结构如图 3 所示。图中, 输入层中的圆点表示神经元; $z^{(k)}$ 为第 k 个 VAE 提取的高阶特征值。




图3 SVAE+Logistic评估模型结构

Fig.3 Structure of SVAE+Logistic evaluation model

预训练阶段, 模型从最底层的 VAE 开始训练, 当充分完成对本层特征的学习之后, 本层 VAE 输出的高阶特征将作为上一层 VAE 的输入, 继续对上一层 VAE 进行训练, 直至所有 VAE 都得到了充分的训练。如此, 便完成了对判别模型的预训练, 实现了对原始高维特征的提取。整个预训练过程不需要标签数据的参与, 是一个无监督的学习过程, 预训练使得 VAE 的参数能收敛到较好的局部最优解, 同时减少了使用反向传播算法进行微调时梯度弥散的影响。SVAE 通过学习特征的分布情况, 在训练时加入高斯噪声, 拥有泛化能力强, 提取的高阶特征具有抗噪声能力的特点。而且, 相较于使用单个 VAE 直接提取特征, SVAE 由于其深层的网络结构, 能提取出更抽象的高阶特征, 对于高维的非线性系统拥有更好的拟合能力, 更适合复杂的分类任务。

经过 SVAE 提取后的高阶特征输入 Logistic 分类器, 使用反向传播算法对整个网络的参数进行有监督的微调, 根据式(12)得到模型的最优参数 θ^* 。

$$\theta^* = \underset{\theta}{\operatorname{argmin}} \left[-y \ln y' - (1-y) \ln (1-y') \right] \quad (12)$$

其中, 函数 $\underset{\theta}{\operatorname{argmin}}(\cdot)$ 为使函数 $(\cdot)$ 取最小值时 θ 的取值; θ 为模型参数矩阵; y 为训练样本的真实标签值; y' 为训练样本的预测标签值。

2.3 L2正则化

为了提高判别模型的泛化能力, 本模型引入 L2 正则化。加入 L2 正则化后的损失函数 L_{Sparse} 为:

$$L_{\text{Sparse}} = L_{\text{VAE}} + \alpha \sum_{q \in W} w_q^2 \quad (13)$$

其中, L_{VAE} 为原始的目标函数; w_q 为神经元的权重值参数; W 为所有神经元的权重值集合; α 为惩罚系数。L2 正则化通过在损失函数中加入 L2 正则化项, 使得判别模型在训练时倾向于使用较小的权重值参数, 一定程度上减小了模型的过拟合, 增强了泛化能力。

3 仿真实验

仿真软件使用 PSD-BPA, 测试系统采用 IEEE 39 节点系统, 带有调速器和调压器。系统负荷水平考虑 90%、100%、110% 负荷情况, 故障均为三相短路, 故障位置分别位于线路的 10%、30%、50%、70%、90% 处, 故障持续时间分别为 100、120、130、140、150、160、180、200、250、300 ms, 共有 10 个故障清除时间。通过仿真总共生成样本 4950 个, 其中保持稳定的样本 2933 个, 不稳定的样本 2017 个。按比例从保持稳定的样本和不稳定的样本中随机抽取样本数据组成训练集和测试集。

训练集与测试集的样本数比值为 2:1。考虑到各评估方法的随机性, 每种评估方法均进行 5 次实

验。每次实验按照 2:1 比例随机划分训练集和测试集,使用训练集样本对模型进行训练,使用测试集样本评估模型性能。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,在测试集数据中加入信噪比分别为 50、40、30、20、10 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。最终,取 5 次实验中测试集样本的平均评估正确率作为模型的最终正确率。

3.1 噪声干扰对评估模型的影响

本文基于 SVAE 构建了一个拥有 5 层深度网络结构的判别模型,各层神经元个数分别为 120、100、50、25、1,预训练阶段的无监督学习率为 0.001,微调阶段的学习率为 0.001,使用 Adam 优化器进行训练。为了验证基于 SVAE 的暂态稳定性评估模型具有良好的抗噪能力,对比了几种常见的机器学习算法:SVM、DT、K-NN、ANN。在本文中,SVM-1 使用线性核函数;SVM-2 采用径向基核函数;DT 采用 CART 算法;ANN 学习率为 0.5,使用 sigmoid 作为激活函数。

故障后的特征量取至故障清除时刻,先不考虑功角阈值对评估模型的影响。表 1 给出了各种机器学习算法在有噪声干扰时的准确率。

表 1 不同的噪声强度对判别结果的影响

Table 1 Influence of different noise intensities on discrimination results

模型	准确率 / %					
	无噪声	50 dB	40 dB	30 dB	20 dB	10 dB
SVAE	97.82	97.87	97.87	97.75	97.51	95.15
SVM-1	96.81	96.89	96.55	94.14	84.35	66.24
SVM-2	97.27	97.26	97.29	97.23	97.18	87.18
DT	96.26	94.09	93.85	92.44	88.03	73.60
K-NN	94.74	94.77	94.74	94.80	94.71	93.64
ANN	94.98	94.86	94.88	94.85	94.85	92.72

由表 1 中可知,在没有噪声的情况下,本文提出的基于 SVAE 的暂态稳定性评估模型准确率可以达到 97.82%,高于其他的机器学习算法。加入噪声之后,加入信噪比为 50、40、30 dB 的高斯白噪声对大多数的基于机器学习算法模型的结果影响并不大,信噪比 20 dB 的噪声对 SVM-1 和 DT 算法的影响比较大,而信噪比 10 dB 的噪声会对除 SVAE 以外的所有算法评估结果造成较严重的影响。当噪声的信噪比达到 20 dB 时,基于 SVAE 的评估模型准确率仍然能够达到 97.51%;当噪声的信噪比达到 10 dB 时,其准确率能够保持在 95% 以上。

3.2 功角阈值的设定对评估模型的影响

功角阈值的设定可以使得提取的临界情况的特征量之间的差异更加明显,这不仅仅有利于稳定性的判别,同时也大幅提高了评估模型的抗噪能力。本文对比了功角阈值设置为 10°、20°、40°、60° 时,不

同噪声干扰对基于 SVAE 模型的影响,结果如表 2 所示。不同的功角阈值在不同噪声下的准确率曲线图如图 4 所示。

表 2 不同的功角阈值对判别结果的影响

Table 2 Influence of different power angle thresholds on discrimination results

功角阈值 / (°)	准确率 / %					
	无噪声	50 dB	40 dB	30 dB	20 dB	10 dB
0	97.82	97.87	97.87	97.75	97.51	95.15
10	98.10	97.92	97.87	98.02	97.77	96.32
20	98.12	97.95	98.08	98.08	97.87	96.60
40	98.32	98.30	98.28	98.22	98.18	97.26
60	98.64	98.65	98.59	98.51	98.49	97.77




图 4 不同的功角阈值对判别结果的影响

Fig.4 Influence of different power angle thresholds on discriminant results

由表 2 可知,故障后的特征量通过设定功角阈值之后进行提取,评估模型的准确率在没有噪声干扰的情况下,随着功角阈值设定值的增大而不断增大,当功角阈值设定为 60° 时,评估模型的准确率可以达到 98.64%。当增加了噪声干扰时,由于功角阈值的设定,评估模型的抗噪能力不断加强,在功角阈值为 60° 时,加入信噪比为 10 dB 的噪声,其准确率仍然高达 97.77%。

3.3 功角阈值的设定对判别时间的影响

由于设置功角阈值,会延迟故障后特征量的提取时刻,因此以 100% 的负荷水平,母线 26 和母线 27 之间发生故障,故障时间为 0.2 s,当故障地点在距离 26 号母线 50% 的位置发生三相短路接地故障时,系统临界失稳;当故障地点在距离 26 号母线 70% 的位置发生三相短路接地故障时,系统处于临界稳定状态。取故障地点为距离 26 号母线 10% 和 50% 的位置发生三相短路接地故障,校验功角阈值的设置对这 2 种情况判别时刻的影响。2 种不同故障地点下,设置的功角阈值与其判别时刻与判别时刻所对应的等值单机无穷大系统的功角如表 3 所示。表 4 给出了采用动态鞍点法^[16]和固定门槛值方法(最大功角差值设置为 180°)得到的判别时刻与其所对应的等值功角。

由表 3 和表 4 可知,即使设置功角阈值为 60° 时,得到的判别时刻也远早于动态鞍点法和固定门槛值(180°)得到的判别时间,因此设置一定的功角

表3 不同功角阈值对应的判别时刻与等值功角

Table 3 Discriminant time and equivalent power angle corresponding to different power angle thresholds

功角阈值/(°)	判别时刻/s		等值功角/(°)	
	故障地点 10%	故障地点 50%	故障地点 10%	故障地点 50%
0	0.21	0.21	28.18	24.93
10	0.25	0.25	39.10	34.51
20	0.28	0.29	46.88	43.53
40	0.36	0.38	65.76	61.37
60	0.44	0.49	82.02	78.51

表4 传统方法得到的判别时刻

Table 4 Discriminant time obtained by traditional method

判别方法	判别时刻/s		等值功角/(°)	
	故障地点 10%	故障地点 50%	故障地点 10%	故障地点 50%
动态鞍点	0.61	0.89	120.97	121.53
固定门槛值	0.82	1.27	180.36	181.74

阈值可以提高基于SVAE的判别模型的准确率和抗噪能力,同时得到的判别时刻是可以用于启动实时控制措施的^[17]。

4 结论

响应数据的采集和传输过程会有一定概率受到噪声的干扰,如果构建的暂态稳定性判别模型不具备抗噪能力,会导致结果的准确性受到很大影响。本文从模型的构建与数据的采集2个方面出发,得到具有良好抗噪能力的暂态稳定性判别模型。本文提出了一种基于SVAE的暂态稳定性判别模型,并且在训练过程中加入了L2正则化,提高了模型的泛化能力;同时,在采集数据时,通过引入最大功角差值的阈值,大幅降低了模型的误判率,增强了判别模型的抗噪能力,并且合理的阈值设定并不会影响模型的判别结果对后续控制措施的启动。不同的机器学习判别模型的对比结果表明了基于SVAE的暂态稳定性判别模型相较于其他判别模型具有更好的准确度和抗噪能力;不同功角阈值的设定的结果验证了设定合理的功角阈值可以提高判别模型的准确度和抗噪能力,同时不会导致控制措施来不及实施的情况发生。

参考文献:

- [1] 田芳,周孝信,于之虹. 基于灵敏度分析和时域仿真的暂态稳定预防控制优化方法[J]. 电力自动化设备, 2018, 38(7): 155-161.
TIAN Fang, ZHOU Xiaoxin, YU Zhihong. Optimization method of transient stability preventive control based on sensitivity analysis and time domain simulation[J]. Electric Power Automation Equipment, 2018, 38(7): 155-161.
- [2] 杨松浩,王怀远,苏福,等. 基于相轨迹凹凸性的暂态不稳定性判别方法的分析比较[J]. 电力自动化设备, 2017, 37(9): 193-198.
YANG Songhao, WANG Huaiyuan, SU Fu, et al. Analysis and

comparison of transient instability detection methods based on convexity and concavity of phase trajectory [J]. Electric Power Automation Equipment, 2017, 37(9): 193-198.

- [3] 冯雷,蔡泽祥,王奕,等. 双馈风电机组低压穿越特性对电力系统暂态稳定的影响[J]. 电力自动化设备, 2018, 38(3): 16-23.
FENG Lei, CAI Zexiang, WANG Yi, et al. Impact of DFIC LVRT characteristics on transient stability of power system [J]. Electric Power Automation Equipment, 2018, 38(3): 16-23.
- [4] 苏福,杨松浩,王怀远,等. 电力系统暂态稳定时域仿真快速终止算法研究[J]. 中国电机工程学报, 2017, 37(15): 4372-4378.
SU Fu, YANG Songhao, WANG Huaiyuan, et al. Study on fast termination algorithm of time-domain simulation for power system transient stability [J]. Proceedings of the CSEE, 2017, 37(15): 4372-4378.
- [5] 汤涌. 基于响应的电力系统广域安全稳定控制[J]. 中国电机工程学报, 2014, 34(29): 5041-5050.
TANG Yong. Response-based wide area control for power system security and stability [J]. Proceedings of the CSEE, 2014, 34(29): 5041-5050.
- [6] BHUI P, SENROY N. Real-time prediction and control of transient stability using transient energy function [J]. IEEE Transactions on Power Systems, 2017, 32(2): 923-934.
- [7] MUYEEN S M, HASANIEN H M, AL-DURRA A. Transient stability enhancement of wind farms connected to a multi-machine power system by using an adaptive ANN-controlled SMES [J]. Energy Conversion & Management, 2014, 78(1): 412-420.
- [8] 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: 320-328.
- [9] HOUBEN I, WEHENKEL L, PAVELLA M. Coupling of K-NN with decision trees for power system transient stability assessment [C] // International Conference on Control Applications. New York, USA: IEEE, 1995: 825-832.
- [10] ZHOU Y, WU J, JI L, et al. Transient stability preventive control of power systems using chaotic particle swarm optimization combined with two-stage support vector machine [J]. Electric Power Systems Research, 2018, 155: 111-120.
- [11] 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.
YI 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.
- [12] 张业茂, 万保权, 周兵, 等. 特高压输电线路可听噪声长期测试数据的统计分析[J]. 中国电机工程学报, 2017, 37(20): 6136-6144.
ZHANG Yemao, WAN Baoquan, ZHOU Bing, et al. Statistic analysis of long-term measured data of audible noise on UHV AC transmission lines [J]. Proceedings of the CSEE, 2017, 37(20): 6136-6144.
- [13] 朱亮, 温和, 戴慧芳, 等. 计及噪声的动态谐波准同步采样分析方法[J]. 电力自动化设备, 2018, 38(2): 217-223.
ZHU Liang, WEN He, DAI Huifang, et al. Dynamic harmonic analysis method based on quasi-synchronous sampling algorithm considering noise [J]. Electric Power Automation Equipment, 2018, 38(2): 217-223.
- [14] 王守相, 陈海文, 李小平, 等. 风电和光伏随机场景生成的条件变分自动编码器方法[J]. 电网技术, 2018, 42(6): 1860-1869.
WANG Shouxiang, CHEN Haiwen, LI Xiaoping, et al. Conditional variational automatic encoder method for stochastic scenario generation of wind power and photovoltaic system [J].

- Power System Technology, 2018, 42(6):1860-1869.
- [15] NASH C, WILLIAMS C K I. The shape variational autoencoder: a deep generative model of part-segmented 3D objects [J]. Computer Graphics Forum, 2017, 36(5):1-12.
- [16] 项丽, 彭慧敏, 丁茂生, 等. 基于动态鞍点暂态动能灵敏度分析的紧急控制[J]. 电力系统自动化, 2013, 37(21):129-133.
XIANG Li, PENG Huimin, DING Maosheng, et al. Emergency control based on the sensitivity analysis of transient kinetic energy of dynamic saddle point[J]. Automation of Electric Power Systems, 2013, 37(21):129-133.
- [17] 张保会, 王怀远, 杨松浩. 电力系统暂态稳定性闭环控制(四)——切机控制效果的要素分析[J]. 电力自动化设备, 2014, 34(11):1-6.
ZHANG Baohui, WANG Huaiyuan, YANG Songhao. Closed-loop

control of power system transient stability(4): analysis of elements influencing control effect of generator shedding[J]. Electric Power Automation Equipment, 2014, 34(11):1-6.

作者简介:



王怀远

王怀远(1987—),男,福建泉州人,讲师,博士,通信作者,主要研究方向为电力系统稳定性分析及其控制(E-mail: 79749544@qq.com);

陈启凡(1995—),男,福建宁德人,硕士,主要研究方向为人工智能在电力系统中的应用(E-mail: 785211625@qq.com)。

(编辑 王欣竹)

Transient stability assessment method of electric power systems based on stacked variational auto-encoder

WANG Huaiyuan, CHEN Qifan

(College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350116, China)

Abstract: From the two aspects of model construction and characteristic quantities extraction, a transient stability discriminant model with better noise immunity is proposed. A stacked variational auto-encoder is adopted to construct the assessment model. Besides, a L2 regularization method is introduced in the training process, which enhances the generalization ability of the stability discriminant model. Meanwhile, the characteristic quantities extraction time of the proposed method is different from the traditional method. By setting the threshold of the maximum power angle difference of all generators, when the system develops to the threshold, the characteristic quantities extraction is carried out. The simulative results based on IEEE 39-bus system show that the miscalculation of the stability assessment model is greatly reduced with the proposed characteristic quantities extraction method. Meanwhile the reasonable threshold will not affect the start of real-time control methods, and the noise immunity ability of the model can be also strengthened.

Key words: deep learning; stacked variational auto-encoder; transient analysis; stability; noise immunity; characteristic quantities; electric power systems