

DOI:10.12158/j.2096-3203.2022.01.028

基于堆叠稀疏降噪自编码器的暂态稳定评估模型

温涛¹, 张敏², 王怀远³

(1. 广东电网有限责任公司电力调度控制中心, 广东 广州 510600;

2. 广东电网有限责任公司广州供电局, 广东 广州 510620;

3. 福州大学电气工程与自动化学院, 福建 福州 350116)

摘要:深度学习模型凭借其良好的性能被引入到电力系统的暂态稳定性评估中,但进行在线应用时,须关注模型的抗噪能力和泛化能力。文中提出一种基于堆叠稀疏降噪自编码器(SSDAE)的暂态稳定性评估模型,首先对原始输入数据加入噪声得到受损数据样本,然后对受损数据样本进行高阶特征提取,最后将提取的高阶特征重构成未受损的数据,这一训练过程大大提高了模型的抗噪能力。同时,在对输入特征进行重构的过程中,对隐藏层神经元权重和激活程度进行抑制,实现模型的稀疏化,以此提高模型的泛化能力。仿真结果表明,相对于其他机器学习算法,SSDAE模型具有良好的抗噪能力和泛化能力。

关键词:深度学习;堆叠稀疏降噪自编码器(SSDAE);暂态稳定;抗噪声能力;泛化能力;机器学习

中图分类号:TM744

文献标志码:A

文章编号:2096-3203(2022)01-0207-06

0 引言

若电力系统稳定性受到破坏,不仅会给人民生活带来不便,而且会造成巨大的经济损失,因此有必要进一步加强电力系统监控^[1-3]。目前,传统的暂态稳定性评估方法主要有时域仿真法^[4]和直接法^[5]。随着大规模电网复杂性的增加,这些传统方法的耗时逐步增加,难以满足在线评估应用的要求。

随着电网同步相量测量装置(phasor measurement unit, PMU)的逐步安装以及通信技术的快速发展,控制中心已经能够实时获取系统各个动态过程的响应信息,这为电力系统的在线监测与分析奠定了基础^[6-7]。机器学习算法凭借其计算速度快、准确性高等优点,被广泛应用于电力系统暂态稳定的在线评估。浅层学习算法在暂态稳定评估应用方面已经有了大量研究^[8-13]。浅层学习算法需要先进行特征量的提取,特征量提取的合理性影响着判别结果的准确性。而深度学习模型具有多隐藏层的网络结构,将高维度的原始特征量输入到模型中,深度学习算法便能够实现相关特征量的快速分离和提取^[14]。常用的深度学习模型有深度置信网络^[15-16]、卷积神经网络^[17-19]和堆叠自动编码器^[20-21]等。

已有的研究成果在无噪声的情况下,均有着不错的表现,但若要将机器学习算法应用到在线监测

上,采样或传输过程中产生的噪声就不能被忽略^[22-23]。同时,训练模型无法涵盖系统所有的突发状况,在应用过程中,遇到新的工况或故障时,其准确性不能太低,因此模型的泛化能力也很重要。

文中提出了一种基于堆叠稀疏降噪自编码器(stacked sparse denoising auto-encoder, SSDAE)的暂态稳定评估模型。首先对SSDAE评估模型的算法和原理进行了介绍,通过改进自编码器,减少了输入数据中的噪声对特征提取的干扰,增强模型的鲁棒性。同时,SSDAE对原始数据进行了稀疏表达,有利于模型在训练过程中抓住主导特征,从而提高模型的泛化能力。然后介绍了基于SSDAE的评估模型的具体实现过程,包括离线训练和在线应用,并给出评估训练结果的指标。最后通过仿真验证了文中方法的有效性。

1 基于SSDAE的模型原理

1.1 稀疏降噪自编码器模型

稀疏降噪自编码器(sparse denoising auto-encoder, SDAE)由编码器和解码器两部分构成。SDAE首先将噪声加入原始输入数据得到受损数据样本,编码器对受损数据样本进行特征提取,解码器将提取的高阶特征重构成未受损的数据,这一训练过程大大提高了模型的抗噪能力。SDAE提取的高阶特征具有极强的鲁棒性,能够对高维原始特征进行抽象表达而不受噪声的干扰,因此SDAE模型具有很好的抗噪能力。SDAE结构如图1所示。

SDAE首先对原始输入数据样本 $\mathbf{x} \in \mathbf{R}^m$ 进行

收稿日期:2021-07-26;修回日期:2021-10-13

基金项目:福建省自然科学基金资助项目(2018J01482);福建省科技厅引导性项目(2019H01010204)

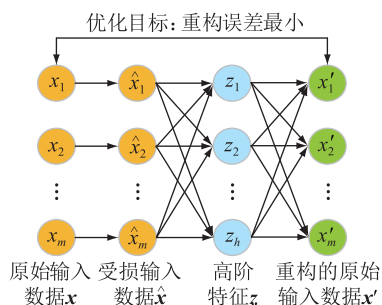


图1 SDAE 结构

Fig.1 Structure of SDAE

“破坏和污染”得到受损数据样本 $\hat{x} \in \mathbf{R}^m$, 然后编码器通过式(1)将 \hat{x} 映射到隐藏层向量 $z \in \mathbf{R}^h$ 。

$$z = f_{\varphi}(\hat{x}) = \frac{1}{1 + e^{-W\hat{x} + B}} \quad (1)$$

式中: $W \in \mathbf{R}^{h \times m}$ 为连接输入层和隐藏层的权重矩阵; $B \in \mathbf{R}^{h \times 1}$ 为连接输入层和隐藏层的偏置向量矩阵。

解码器通过式(2)将隐藏层向量 z 映射到一个与输入层相同维度的输出层, 得到重构的原始输入特征 x' 。

$$x' = q_{\alpha}(z) = \frac{1}{1 + e^{-W'z + B'}} \quad (2)$$

式中: $W' \in \mathbf{R}^{m \times h}$ 为连接隐藏层和输出层的权重矩阵; $B' \in \mathbf{R}^{m \times 1}$ 为连接隐藏层和输出层的偏置向量矩阵。

SDAE 训练的目标是将受损样本 \hat{x} 重构成未受损样本 x' , 通过最小化式(3)实现。式(3)用来衡量受损样本与未受损样本之间的误差。

$$L_{\text{reconstruction}} = \frac{1}{m} \sum_{i=1}^m (x'_i - x_i)^2 \quad (3)$$

式中: x'_i 为重构的输入特征的第 i 维特征量; x_i 为未受损原始输入特征的第 i 维特征量。

电力系统运行时的电压、电流和不平衡功率等信息之间具有相关性, 导致高维原始输入信息中包含了大量的冗余特征。对 SDAE 模型加入稀疏化限制, 能迫使 SDAE 模型在训练的过程中自动去除冗余特征, 提取出对暂态稳定性评估具有高区分度的特征, 从而提高暂态稳定评估的性能。同时, 稀疏化使得网络的部分参数为 0, 提高了使用反向传播 (back propagation, BP) 算法对网络进行训练的速度。

1.2 SSDAE 分类模型

SSDAE 是由多个 SDAE 的编码器有机组合, 并在最后加入一层 Logistic 分类器组成的深度神经网络。通过这样的堆叠结构, 充分发挥了 SDAE 的特征提取能力, 使得 SSDAE 具有很强的拟合高维非线

性函数的能力。

为了对 SSDAE 进行有效训练, 首先, 将多个 SDAE 串联起来, 前一级 SDAE 编码器的输出特征作为下一级 SDAE 的输入特征, 逐个对 SDAE 进行无监督的预训练。经过无监督预训练的 SDAE 能够将受损数据恢复成原始数据。此时, SDAE 的编码器部分便能够从受损的数据中提取出能反映未受损数据信息的高阶特征。将每个经过预训练的 SDAE 的编码器串联起来, 并在最后加入一层 Logistic 分类器, 使用 BP 算法, 对 SSDAE 分类模型进行有监督的训练。模型的最优参数 θ^* 可通过式(4)得到。

$$\theta^* = \arg \min_{\theta} (-y \ln y' - (1 - y) \ln(1 - y')) \quad (4)$$

式中: y 为训练样本的真实标签值; y' 为预测标签值; θ 为 SSDAE 分类模型的网络参数。

逐层贪婪无监督预训练与有监督微调的训练相结合, 能对 SSDAE 模型进行有效训练, 充分发挥深度神经网络对于高维非线性函数强大的拟合能力^[24]。由于 SDAE 提取的特征具有强鲁棒性, 以及 SDAE 激活程度的稀疏化限制, 使得 SSDAE 分类模型具有较强的抗噪声能力和泛化能力, 且训练样本不容易过拟合。

2 基于 SSDAE 的暂态稳定性评估

2.1 离线训练

通过仿真数据和历史运行数据构建训练样本集。提取故障发生前时刻、故障发生时刻、故障清除时刻、故障清除后 0.1 s 这 4 个时刻所有发电机的功角、角速度、机械功率、电磁功率, 作为评估模型的输入特征, 并对所有特征进行归一化预处理。

根据式(5)判断每一例样本为稳定样本或不稳定样本。若 $\varphi \geq 0$, 则为稳定样本, 标签为 1; 否则为不稳定样本, 标签为 0。

$$\varphi = 360^\circ - |\Delta\delta_{\max}| \quad (5)$$

式中: $\Delta\delta_{\max}$ 为任意时刻所有发电机间的最大功角差值。

文中使用 BPA 仿真软件在 IEEE 39 节点系统和华东某省电网上进行仿真。在 IEEE 39 节点系统中, 故障情况为永久性三相短路故障, 系统负荷水平分别为 90%, 100%, 110%, 故障位置分别位于线路 10%, 30%, 50%, 70%, 90% 处, 故障持续时间为 100~300 ms。通过仿真共生成样本 4 950 个, 其中稳定样本 2 933 个, 不稳定样本 2 017 个。将所有样本按照 4:1 的比例分成训练集和测试集, 训练集用

于离线训练,测试集用于评价模型的性能。在华东某省电网中,只考虑了系统 100% 的负载水平。故障设置为 220 kV 及以上的输电线路的 10%, 50%, 90% 处发生永久性三相短路故障。故障持续时间为 8 个周波。随机模拟了 18 204 种故障情况。将所有样本分为训练集和测试集。其中训练集中有 6 000 个样本,测试集中有 12 204 个样本。

使用训练集样本对 SSDAE 评估模型进行训练,网络的超参数由 5 折交叉验证结合随机搜索确定。最终确定 SSDAE 的隐藏层神经元个数依次为 500, 500, 250, 50, 25; 批样本大小为 128; 使用 Adam 方法进行网络优化,学习率为 0.001; 无监督预训练次数为 200; 有监督训练次数为 300。

2.2 在线应用

借助电网中广泛分布的电力系统同步 PMU, 可以实时收集发电机和母线的动态信息。然后,实时监测数据可以通过高速通信网络发送到控制中心。在控制中心,当故障被清除 5 周波后,从接收动态信息中提取出评估模型的输入特征,并进行预处理。将预处理后的特征量输入离线训练好的基于 SSDAE 的暂态稳定评估模型中。SSDAE 评估模型本质上是输入特征与输出结果之间的高维非线性映射。当这种映射关系被确定后,只需要将当前的特征量输入 SSDAE 评估模型,就能够快速完成电力系统暂态稳定性的预测。

当电力系统发生新的故障情况时,评估当前的基于 SSDAE 的暂态稳定评估模型对新故障的评估效果。若当前评估模型对新故障的评估正确率能够满足要求,则不更新当前评估模型。否则,将基于这批新的故障,仿真生成相近或相同运行情况的故障样本,并标记稳定情况,构建成补充训练样本集。利用补充训练样本集对当前暂态稳定评估模型进行微调,得到更新后的暂态稳定评估模型,并用于在线评估。

2.3 模型性能评价指标

对于暂态稳定评估模型,文中使用以下指标对模型性能进行评估。

(1) 全局正确率 η_{AC} 。

$$\eta_{AC} = \frac{N_R}{N_{all}} \quad (6)$$

式中: N_R 为预测正确的样本数量; N_{all} 为样本总数。

(2) 漏警率 η_{FD} 。

$$\eta_{FD} = \frac{N_{UF}}{N_U} \quad (7)$$

式中: N_{UF} 为预测错误的稳定样本数量; N_U 为不

稳定样本总数。

(3) 误警率 η_{FA} 。

$$\eta_{FA} = \frac{N_{SF}}{N_S} \quad (8)$$

式中: N_{SF} 为预测错误的稳定样本数量; N_S 为稳定样本总数。

全局正确率 η_{AC} 体现了模型的综合性能,漏警率 η_{FD} 体现了模型对于不稳定样本的评估性能,误警率 η_{FA} 体现了模型对于稳定样本的评估性能,综合考察这 3 个指标能够全面评价模型性能。

3 仿真算例

3.1 无噪声数据实验结果

3.1.1 IEEE 39 节点系统

将 SSDAE 与堆叠稀疏自编码器 (stacked sparse auto-encoder, SSAE)^[17]、支持向量机 (support vector machine, SVM)、决策树算法 (decision tree, DT)、人工神经网络 (artificial neural network, ANN)、朴素贝叶斯 (naive bayes, NB) 的实验结果作比较。其中, DT 使用分类回归树算法; SVM 使用径向基核函数,通过 5 折交叉验证和网格搜索法确定参数 C 为 500, γ 为 0.1; ANN 为单隐藏层结构,训练次数为 300,批样本大小为 128,通过 5 折交叉验证和网格搜索法确定学习率为 0.5,隐藏层神经元个数为 200; SSAE 使用和 SSDAE 相同的超参数。

由于抽样具有随机性,为了更加可靠地评估模型性能,所有算法均进行 5 次随机抽样,以 5 次测试集评估结果的平均值作为最终评估结果。评估结果如表 1 所示。

表 1 不同分类模型在无噪声情况下的评估结果

评估模型	η_{AC}	η_{FD}	η_{FA}
SSDAE	98.60	1.86	1.11
SSAE	98.57	1.82	1.17
SVM	97.81	3.23	1.48
DT	97.00	3.68	2.53
ANN	95.55	6.00	3.38
NB	79.71	34.28	10.67

可以看出,SSDAE 和 SSAE 的评估性能明显高于其他浅层学习算法。而 SSDAE 和 SSAE 采用相同的结构和参数,在无噪声情况下,两者的性能指标基本相同。

模型计算时间如表 2 所示,SSDAE 模型训练 500 次的时间为 147.65 s,其在应用过程中每个测试

样本的计算速度非常快,仅为 2.99 ms,可以满足在线计算的需求。

表 2 不同模型的训练和测试时间

Table 2 Training and testing time of different models

模型	训练时间/s	测试时间/ms
SSDAE	147.65	2.99
SSAE	143.32	3.59
ANN	553.86	5.25

3.1.2 华东某省电网

在华东某省电网中,将 SSDAE,SSAE,ANN 的实验结果相比较。进行 5 次随机抽样,以 5 次测试集评估结果的平均值作为最终评估结果,结果如表 3 所示。

表 3 实际电网仿真结果

Table 3 Simulation results of different models in actual grid

模型	$\eta_{AC} / \%$	$\eta_{FD} / \%$	$\eta_{FA} / \%$	测试时间/ms
SSDAE	96.62	5.92	0.84	3.98
SSAE	96.55	5.78	1.12	4.88
ANN	94.12	10.27	3.94	7.72

在华东某省电网中,输入特征量仍然为各发电机组的功角、角速度、机械功率、电磁功率,但该电网系统包含 183 台发电机组,因此输入特征量维数变大,各样本平均测试时间多了 0.99 ms,但总体来说,SSDAE 的计算速度仍满足在线计算的需求。

3.2 噪声干扰对评估模型的影响

由于在实际应用中,数据的采集、传输等过程均有可能受到不同程度的干扰^[19],因此需要检验评估模型对含噪声数据评估的准确性。在训练评估模型时,训练集的数据采用无噪声的实验数据,而在测试过程中,对 IEEE 39 节点系统测试样本分别加入信噪比为 20 dB,15 dB,10 dB,8 dB 的高斯白噪声,来模拟数据在实际应用时伴随的噪声干扰。不同分类模型对含噪声数据的评估结果见表 4。

表 4 不同分类模型在有噪声情况下的评估结果

Table 4 Evaluation results of different models with noise %

评估模型	信噪比/dB				
	无噪声	20	15	10	8
SSDAE	98.60	98.40	97.96	97.12	96.38
SSAE	98.57	98.21	97.79	96.66	95.77
SVM	97.81	97.66	97.47	92.60	79.14
DT	97.00	89.64	87.18	83.96	81.99
ANN	95.55	95.33	94.67	93.50	92.89
NB	79.71	70.22	64.91	62.37	61.90

可以看出,当信噪比为 20 dB 时,DT,NB 这 2 种模型的评估性能受影响很大,准确率下降很多。而 SSDAE,SSAE,SVM,ANN 这 4 种模型受影响并不大,说明这 4 种模型均有一定的抗噪能力。当信噪比为 10 dB 时,SVM 和 ANN 的评估结果受到了较大影响。而 SSDAE 和 SSAE 的评估准确性仍然很高,SSAE 的准确性在 96.5% 以上,SSDAE 的准确性保持在 97% 以上。当信噪比为 8 dB 时,SSDAE 的评估准确性仍然可以达到 96.38%,而 SSAE 的准确性为 95.77%。由此可见,SSDAE 在训练时对数据加入噪声重构成无噪声数据的过程大大提高了模型的抗噪能力。

3.3 SSDAE 评估模型的泛化能力

在 IEEE 39 节点系统中,随机抽取 200~1 200 个样本作为训练集;在剩余的样本集中,抽取 800 个样本作为测试集,测试样本不被训练。以未训练测试样本的准确性评估 SSDAE 模型的泛化能力。不同数量的训练样本,其对未知样本的评估准确性如表 5 所示。

表 5 不同数量训练样本的评估结果

Table 5 Evaluation results of different training samples %

评估模型	训练样本数量				
	200	400	600	800	1 200
SSDAE	92.32	94.78	96.03	96.65	97.05
SVM	83.34	91.91	94.10	95.09	95.88
DT	88.88	91.52	93.23	93.83	94.75

样本数量对于模型的训练具有重要影响,当样本数量较小时,使用高维输入特征对模型进行训练容易导致模型过拟合,从而影响评估模型的泛化性能。当训练样本数量仅为 200 个时,SSDAE 模型准确率超过 92%,相较于 SVM 和 DT 拥有明显的优势;而 SVM 由于过拟合最为严重,泛化能力最差,相较于使用 400 个训练样本时,其测试集准确率低了 8.57%。随着训练样本数量的增加,3 种模型在测试集上的评估准确率也逐渐上升,其中,SSDAE 一直拥有最高的准确率。当训练集样本数量达到 1 200 个时,SSDAE 的评估准确率超过 97%。这是由于大量的训练样本可以更加有效地训练评估模型,使评估模型泛化能力越来越强,模型对系统暂态稳定性的评估性能越来越好。

4 结语

在实际应用过程中,不仅仅要考虑机器学习算法在无噪声情况下的准确率,同时也要考虑噪声干

扰的影响,以及算法的泛化能力。文中基于 SSDAE 分类模型,提出一种具有较好抗噪性能和泛化能力的暂态稳定性评估模型。在无噪声的情况下,该模型的准确率略高于其他机器学习算法;含噪声干扰时,其准确率要大大高于其他机器学习算法。仿真结果表明,SSDAE 分类模型在有噪声和无噪声的情况下,均有着较高的准确率。不同训练样本数量的评估结果验证了 SSDAE 分类模型具有很好的泛化能力。

文中利用 SSDAE 算法独特的训练方式降低了数据噪声对结果的影响,未来可以考虑通过机器学习算法对噪声数据进行去噪处理,进一步提高机器学习模型在应用过程中的实用能力。

本文得到福建省中青年教育科研项目(JT180018)资助,谨此致谢!

参考文献:

- [1] CARRERAS B A, NEWMAN D E, DOBSON I. North American blackout time series statistics and implications for blackout risk [J]. *IEEE Transactions on Power Systems*, 2016, 31(6): 4406-4414.
- [2] 王怀远,张保会,杨松浩,等. 电力系统暂态稳定切机控制策略表的快速整定方法[J]. *电力系统自动化*, 2016, 40(11): 68-72, 79.
WANG Huaiyuan, ZHANG Baohui, YANG Songhao, et al. Fast setting method of generator tripping strategy tables in transient stability control of power systems [J]. *Automation of Electric Power Systems*, 2016, 40(11): 68-72, 79.
- [3] 王怀远,张保会,杨松浩,等. 基于相平面特性的切机切负荷紧急控制方法[J]. *中国电机工程学报*, 2016, 36(15): 4144-4152.
WANG Huaiyuan, ZHANG Baohui, YANG Songhao, et al. Combined emergency control strategy of generator tripping and load-shedding based on the characteristics of state plane [J]. *Proceedings of the CSEE*, 2016, 36(15): 4144-4152.
- [4] 黄天罡,薛禹胜,林振智,等. 动态 EEAC 的自适应分段映射[J]. *电力系统自动化*, 2018, 42(21): 21-27.
HUANG Tiangang, XUE Yusheng, LIN Zhenzhi, et al. Dynamic EEAC with adaptive subsection mapping [J]. *Automation of Electric Power Systems*, 2018, 42(21): 21-27.
- [5] 夏小琴,徐伟. 考虑调整变化量和变步长的暂态稳定约束最优潮流模型[J]. *电力工程技术*, 2018, 37(6): 115-119.
XIA Xiaoqin, XU Wei. Transient stability constrained optimal power flow model considering power adjustments and variable step size [J]. *Electric Power Engineering Technology*, 2018, 37(6): 115-119.
- [6] AGHAMOHAMMADI M R, ABEDI M. DT based intelligent predictor for out of step condition of generator by using PMU data [J]. *International Journal of Electrical Power & Energy Systems*, 2018, 99: 95-106.
- [7] PAL A, SANCHEZ-AYALA G A, CENTENO V A, et al. A PMU placement scheme ensuring real-time monitoring of critical buses of the network [J]. *IEEE Transactions on Power Delivery*, 2014, 29(2): 510-517.
- [8] HASHIESH F, MOSTAFA H E, KHATIB A R, et al. An intelligent wide area synchrophasor based system for predicting and mitigating transient instabilities [J]. *IEEE Transactions on Smart Grid*, 2012, 3(2): 645-652.
- [9] SIDDIQUI S A, VERMA K, NIAZI K R, et al. Real-time monitoring of post-fault scenario for determining generator coherency and transient stability through ANN [J]. *IEEE Transactions on Industry Applications*, 2018, 54(1): 685-692.
- [10] 朱利鹏,陆超,黄河,等. 基于广域时序数据挖掘策略的暂态电压稳定评估[J]. *电网技术*, 2016, 40(1): 180-185.
ZHU Lipeng, LU Chao, HUANG He, et al. Wide-area time series data mining based transient voltage stability assessment [J]. *Power System Technology*, 2016, 40(1): 180-185.
- [11] LI Y, YANG Z. Application of EOS-ELM with binary jaya-based feature selection to real-time transient stability assessment using PMU data [J]. *IEEE Access*, 2017, 5: 23092-23101.
- [12] ZHOU Y Z, WU J Y, JI L Y, 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.
- [13] 陈厚合,王长江,姜涛,等. 基于投影能量函数和 Pin-SVM 的电力系统暂态稳定评估[J]. *电工技术学报*, 2017, 32(11): 67-76.
CHEN Houhe, WANG Changjiang, JIANG Tao, et al. Transient stability assessment in bulk power grid using projection energy function and support vector machine with pinball loss [J]. *Transactions of China Electrotechnical Society*, 2017, 32(11): 67-76.
- [14] 赵晶晶,贾然,陈凌汉,等. 基于深度学习和改进 K-means 聚类算法的电网无功电压快速分区研究[J]. *电力系统保护与控制*, 2021, 49(14): 89-95.
ZHAO Jingjing, JIA Ran, CHEN Linghan, et al. Research on fast partition of reactive power and voltage based on deep learning and an improved K-means clustering algorithm [J]. *Power System Protection and Control*, 2021, 49(14): 89-95.
- [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] 胡婧,周洋,何志强,等. 基于深度置信网络和随机森林的电力扰动检测方法[J]. *供用电*, 2020, 37(9): 17-22, 28.
HU Jing, ZHOU Yang, HE Zhiqiang, et al. Power quality disturbance detection method using deep belief network [J]. *Distribution & Utilization*, 2020, 37(9): 17-22, 28.

- [17] 周悦,谭本东,李森,等. 基于深度学习的电力系统暂态稳定评估方法[J]. 电力建设,2018,39(2):103-108.
ZHOU Yue, TAN Bendong, LI Miao, et al. Transient stability assessment of power system based on deep learning technology [J]. Electric Power Construction, 2018, 39(2): 103-108.
- [18] 许若冰,王璇,赵倩宇,等. 基于卷积神经网络和深度置信网络的多类型能源需求预测方法[J]. 供用电,2020,37(10):65-70.
XU Ruobing, WANG Xuan, ZHAO Qianyu, et al. A multi-energy demand prediction method based on convolutional neural network and deep belief network [J]. Distribution & Utilization, 2020, 37(10): 65-70.
- [19] 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.
- [20] 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):2937-2946,3144.
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, 3144.
- [21] MAHDI M, GENC V M I. Post-fault prediction of transient instabilities using stacked sparse autoencoder [J]. Electric Power Systems Research, 2018, 164: 243-252.
- [22] 张俊峰,杨婷,陈珉,等. 基于 Prony 滑动平均窗算法的电力系统低频振荡特征分析[J]. 电力自动化设备,2018,38(10):178-183.
ZHANG Junfeng, YANG Ting, CHEN Min, et al. Power system low-frequency oscillation characteristic analysis based on Prony moving average window algorithm [J]. Electric Power Automation Equipment, 2018, 38(10): 178-183.
- [23] 熊思宇,符玲,张佳怡,等. 基于测量值波动特性的 PMU 测量性能在线评价方法[J]. 电网技术,2017,41(7):2332-2339.
XIONG Siyu, FU Ling, ZHANG Jiayi, et al. Online assessment for PMU measurement performance based on phasor measurement volatility characteristics [J]. Power System Technology, 2017, 41(7): 2332-2339.
- [24] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.

作者简介:



温涛

温涛(1988),男,硕士,工程师,从事电力系统运行与控制、继电保护相关工作(E-mail: tw_went@126.com);

张敏(1988),女,硕士,工程师,从事电力系统运行与控制、继电保护相关工作;

王怀远(1987),男,博士,副教授,研究方向为电力系统稳定性。

Transient stability assessment model based on stacked sparse denoising auto-encodern

WEN Tao¹, ZHANG Min², WANG Huaiyuan³

(1. Electric Power Dispatching Control Center of Guangdong Power Grid Co., Ltd., Guangzhou 510600, China;

2. Guangdong Power Grid Co., Ltd. Guangzhou Power Supply Bureau, Guangzhou 510620, China;

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

Abstract: With its good performance, the deep learning model is introduced into the transient stability assessment of power system. However, when applying online, the anti-noise ability and generalization ability of the models must be paid attention to. A deep learning model based on stacked sparse denoising auto-encoder (SSDAE) is proposed for real-time transient stability assessment. The corrupted data is generated by adding white Gaussian noise to the original input data. Then, the high-order features are extracted from the corrupted data. Finally, the original data is reconstructed by using the high-order features. The anti-noise ability is greatly improved after training. Besides, the weights and the degree of activation of the hidden layer neurons are suppressed to achieve the sparseness of the model, which can improve the generalization ability of the model. The simulation results show that the SSDAE based model has good anti-noise ability and generalization ability compared to other machine learning algorithms.

Keywords: deep learning; stacked sparse denoising auto-encoder (SSDAE); transient stability; anti-noise ability; generalization ability; machine learning

(编辑 方晶)