

DOI: 10.19783/j.cnki.pspc.210654

基于改进深度置信网络的智能电网暂态安全状态感知

李海英¹, 沈益涛¹, 罗雨航²

(1. 上海理工大学电气工程系, 上海 200093; 2. 四川水利职业技术学院, 四川 成都 611231)

摘要: 深度学习是感知智能电网暂态安全状态的有效方法, 针对多层重构学习过程低维特征及结构参数难以全局寻优的问题, 提出了一种改进深度置信网络(Deep Belief Network, DBN)方法。首先, 该方法利用 SMOTE 过采样算法, 增加样本多样性, 促使 DBN 深层架构的挖掘。其次, 直接面向噪声样本, DBN 通过网络中各神经元吉布斯抽样的二值状态, 增强重构特征的抗噪能力。最后, 建立了基于遗传算法(Genetic Algorithm, GA)的 GA-DBN 模型, 有效解决 DBN 结构参数调试繁琐的问题, 确保 DBN 高精度地从底层量测数据提取低维特征, 提高安全分类精度。新英格兰 10 机 39 节点系统的仿真实验表明, 在样本不平衡、含噪声情况下, 所提算法比其他算法的失稳漏判率降低, 辨识准确率和 F_1 分数提升。

关键词: 暂态安全感知; 深度置信网络; SMOTE; 遗传算法; 样本不平衡

Transient security situational awareness of smart grids based on an improved deep belief network

LI Haiying¹, SHEN Yitao¹, LUO Yuhang²

(1. Department of Electrical Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2. Sichuan Water Conservancy Vocational College, Chengdu 611231, China)

Abstract: Deep learning shows superiority in transient security situational awareness of smart grids. However, it is hard to find optimal parameters for low-dimensional features and network structures in multi-layer network reconstruction. Thus an improved deep belief network (DBN) is proposed. In this method, the SMOTE algorithm is first adopted for oversampling to balance the proportion of data samples. This ensures mining of the deep structure of DBN. Then the binary neuron from Gibbs sampling is used in DBN to improve the noise immunity in the reconstruction process. Given the repeated manual debugging of network structure, a genetic algorithm (GA)-based GA-DBN model is finally employed to achieve global optimization. The low-dimensional features are abstracted accurately from the high-dimensional measurement data at the bottom layer and the classification precision is guaranteed. A test on the New England 39-bus system with imbalance and noise samples shows that the proposed method outperforms the existing methods in accuracy, F_1 score and missing alarm.

This work is supported by the National Natural Science Foundation of China (No. 51777126).

Key words: transient security situational awareness; deep belief network; SMOTE; genetic algorithm; sample imbalance

0 引言

随着电力需求激增以及可再生能源的接入, 电网运行环境复杂多样, 发生故障的概率远超预期。智能电网暂态安全状态感知(Transient Security Situational Awareness, TSSA)是指系统发生大扰动后是否可以过渡到稳态, 用于故障后采取相应紧急措施, 规避大规模停电事件发生。

暂态安全感知中的时域仿真法^[1]、Lyapunov 能量函数法^[2]和扩展面积法^[3]具有计算精度高的优点, 但在复杂系统高精度建模、实时性方面仍存在巨大挑战。随着基于同步相量测量装置(Phasor Measurement Unit, PMU)的广域测量系统(Wide Area Measurement System, WAMS)逐步完善, 电网动态响应信息可以实时获取, 使得基于数据驱动的机器学习法在智能电网暂态安全感知上得到应用^[4]。

决策树(Decision Tree, DT)、支持向量机(Support Vector Machine, SVM)、相关向量机(Relevance Vector

Machine, RVM)等浅层机器学习方法^[5-9]在电网安全感知中首先被提出。浅层机器学习特征提取降维时,不同的提取方法影响模型分类性能。随着深度学习的发展,这一问题得以改善。深度学习模型通过足够多的转换将底层特征抽象为高层次表示,实现降维。深度学习在暂态安全状态感知方面^[10-12]的研究仍处于探索阶段,主要有卷积神经网络(Convolutional Neural Networks, CNN)、堆叠自动编码器(Stacked Auto-Encoder, SAE)、长短期记忆网络(Long Short-Term Memory, LSTM)等。

目前,深度学习仍存在如下问题:1)深度学习依赖大数据挖掘信息。获取的样本集中,通常稳定样本与失稳样本比例失衡^[13]。不平衡问题的存在会造成模型更偏向稳定样本的学习,导致漏判风险。2)过采样算法、量测单元、多层特征重构均易引入噪声,影响感知精度^[14]。3)模型性能受结构影响,没有完整的理论证明如何挑选较优结构。通常根据专家经验人工反复调试,甚至优化的结构并不唯一。

基于上述问题,文中提出一种遗传算法优化深度置信网络结构的暂态安全状态感知方法。该方法通过 DBN 各层神经元二值特征,提升抗噪能力。同时利用遗传算法全局寻优,根据输入的数据特征集寻找 DBN 的优化结构参数。此外,采用 SMOTE 算法^[15]均衡数据集样本比例,该算法可以增加失稳样本数目,提高失稳样本特征学习概率,降低漏判风险。该方法在新英格兰 10 机 39 节点系统上验证,其与传统 DBN 及 SVM 相比有更高的准确率及 F_1 分数,对失稳样本有更低的漏判率,且具有很好的鲁棒性。

1 GA 优化 DBN 算法

1.1 DBN 结构

DBN 由多个受限玻尔兹曼机 (Restricted Boltzmann Machine, RBM)堆叠和一层 BP 网络构成,如图 1 所示。

RBM 是一种两层的神经网络,包括可视层和隐藏层。前一个 RBM 的隐藏层作为下一个 RBM 的可视层,依次堆叠。

$$\mathbf{h} = \boldsymbol{\omega}\mathbf{v} + \mathbf{b} \quad (1)$$

$$\mathbf{v} = \boldsymbol{\omega}^T\mathbf{h} + \mathbf{a} \quad (2)$$

式中: \mathbf{v} 、 \mathbf{h} 为可视层、隐藏层状态向量; \mathbf{a} 、 \mathbf{b} 为可视层、隐藏层偏置向量; $\boldsymbol{\omega}$ 为可视层与隐藏层之间的权重向量。

RBM 堆叠网络通过无监督训练将输入的高维特征重构融合成低维特征,并初步确定 DBN 的层数、神经元、权重等参数。BP 网络根据标签信息有

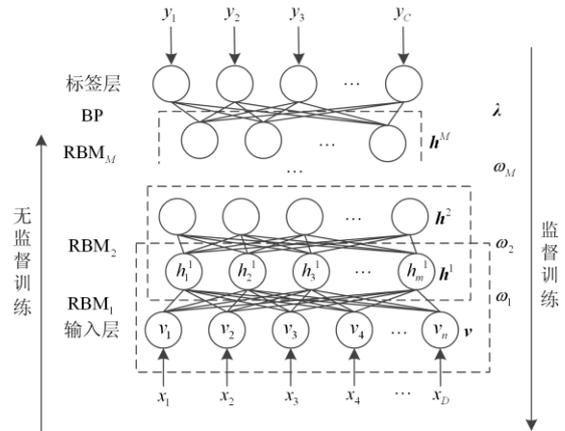


图 1 DBN 结构

Fig. 1 Structure of DBN

监督地反向微调 DBN 的权重、偏置参数,使模型性能更优。因此, DBN 学习分为特征重构和参数微调两个过程。

1.2 DBN 特征重构

DBN 特征重构的原则是调整隐藏层各神经元激活与否,使之与可视层的概率分布在最大程度上保持一致,且隐藏层神经元个数不多于可视层神经元个数,确保重构过程降噪、降维。

RBM 结构中,每一层都具有独立性,隐藏层与可视层的神经元激活条件概率分别为

$$P(h_j = 1|\mathbf{v}, \boldsymbol{\theta}) = \sigma(b_j + \sum_i \omega_{ij}v_i) \quad (3)$$

$$P(v_i = 1|\mathbf{h}, \boldsymbol{\theta}) = \sigma(a_i + \sum_j \omega_{ij}h_j) \quad (4)$$

式中: $\boldsymbol{\theta} = (\mathbf{a}, \mathbf{b}, \boldsymbol{\omega})$ 为 RBM 模型参数; i 表示可视层中第 i 个神经元; j 表示隐藏层中第 j 个神经元; σ 为激活函数,文中使用的是 sigmoid 函数。

n 个可视神经元和 m 个隐藏神经元之间的联合能量函数 $E(\mathbf{v}, \mathbf{h}|\boldsymbol{\theta})$ 为

$$E(\mathbf{v}, \mathbf{h}|\boldsymbol{\theta}) = -\sum_{i=1}^n a_i v_i - \sum_{j=1}^m b_j h_j - \sum_{i=1}^n \sum_{j=1}^m v_i \omega_{ij} h_j \quad (5)$$

RBM 模型需确定 $\boldsymbol{\theta}$ 值,可通过输入训练集上的最大似然概率获得:

$$\max_{\boldsymbol{\theta}} P(\mathbf{v}|\mathbf{h}, \boldsymbol{\theta}) = \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h}|\boldsymbol{\theta})} \quad (6)$$

通过吉布斯抽样, RBM 采用对比散度算法^[16]更新参数,以权重 ω_{ij} 为例。

$$\omega_{ij} = \mathcal{G}\omega_{ij} + \varepsilon \frac{\partial \log P(\mathbf{v})}{\partial \omega_{ij}} \quad (7)$$

式中: \mathcal{G} 为动量; ε 为学习率; a_i 、 b_j 的更新与 ω_{ij} 相似。

1.3 DBN 参数微调

每个样本 $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_D\}$ 都对应一个标签 $\mathbf{Y} = \{y_1, y_2, y_3, \dots, y_C\}$ 。 D 为特征数, C 为样本类别数。标签输出层采用 Softmax 回归层, 以二分类问题 $\mathbf{Y} = \{y_1, y_2\}$ 为例, 函数关系如式(8)。

$$y_\lambda(\mathbf{h}) = \frac{1}{e^{\lambda_1^T \mathbf{h}^M} + e^{\lambda_2^T \mathbf{h}^M}} \begin{bmatrix} e^{\lambda_1^T \mathbf{h}^M} \\ e^{\lambda_2^T \mathbf{h}^M} \end{bmatrix} \quad (8)$$

式中: λ_1 、 λ_2 为次顶层与顶层之间的权重向量; \mathbf{h}^M 为第 M 层隐藏层向量。

利用标签信息有监督地反向微调整个模型参数时, 样本输入数据经过前向传播得到模型输出值。根据模型输出与真实标签的差距设置代价函数计算误差。

$$\mu = \frac{1}{N} \sum_{i=1}^N (y_i^* - y_i)^2 \quad (9)$$

式中: μ 为平均平方误差; y_i^* 和 y_i 分别为真实标签和模型输出; N 为数据集样本容量。

以 μ 最小为目标, 采用梯度下降法微调 DBN 各层权重及偏置参数。

1.4 GA 全局寻优

文献[17]指出深度神经网络模型的性能会随着隐藏层层数的改变而改变^[17]。深度神经网络模型的性能随着隐藏层层数增加而上升, 但增至4层以上时正确率及泛化性能反而会下降^[18]。

遗传算法(Genetic Algorithm, GA)^[19]可对结构对象直接操作, 具有高效的全局寻优能力, 适用复杂多样的深度神经网络结构参数寻优。因此, 在优化DBN网络结构时采用GA全局寻优。

GA优化DBN时, 首先设置隐藏层范围为1~4。为保证高精度提取低维特征, 每层神经元数搜索范围为5~30。

在设定范围内随机抽样得到DBN的隐藏层层数及每层神经元数, 并将其编码为染色体, 设置种群大小, 训练DBN。DBN参数参考文献[16]取学习率为0.01, 动量为0.9, 迭代次数为100次, dropout为0.2。

GA全局寻优以分类正确率为适应度值^[20]。根据前代种群染色体的适应度值, 经过选择、交叉、变异衍生后代更优种群, 直至最优, 用于智能电网暂态安全状态感知。

2 暂态安全状态感知模型构造

2.1 数据库建立

文中暂态稳定指功角稳定, 本质为在大扰动下系统内的同步发电机组是否发生失步, 判断依据为

同步机群里存在的最大相对功角差 $\Delta\delta_{\max}$ 是否超过 360° 。若 $\Delta\delta_{\max} > 360^\circ$, 样本判为失稳, 反之为稳定。

由于故障前发电机出力等静态特征能够反映稳态运行时的安全裕度; 故障发生瞬间转子角速度、转子角加速度等动态特征能够表征系统内部功率失衡对暂态安全的冲击; 故障受扰阶段, 发电机转子角的运动轨迹能够直接反映系统暂态安全的信息。结合文献[21-22], 选择故障前系统总有功负荷、总有功出力、所有发电机机械功率之和, 以及故障后发电机转子角等在电网暂态安全状态感知表现优异的25维特征作为模型输入。特征数据归一化处理采用z-score标准化^[16]。

2.2 不平衡问题的处理

暂态安全状态感知是一个典型的非平衡二分类问题, 体现为样本数量比例失衡。稳定样本往往远大于失稳样本, 造成漏判, 导致无法及时采取紧急控制措施^[23]。

SMOTE 算法利用 k 最近邻(k -nearest neighbor, KNN)技术^[24]计算失稳样本的 k 个邻近, 从中挑选 k 个样本模拟分析后线性插值, 构造新的失稳样本, 使样本比例趋于平衡。

SMOTE 算法在提升样本比例的同时, 也在一定程度上引入抽样误差。而 DBN 模型的神经元都是二值变量, 取 0 或 1, 抗噪能力强。DBN 与 SMOTE 算法结合进一步提升了模型的泛化能力和感知精度。

2.3 模型评价指标的建立

构建暂态安全状态感知的混淆矩阵, 用准确率 A_{cc} 、 F_1 分数和漏判率 P_{ma} 全面评价模型性能。混淆矩阵如表 1 所示, 各评估指标的具体公式如式(10)~式(14)所示。

表 1 暂态安全状态感知的混淆矩阵

评估结果	真实结果	
	稳定	失稳
稳定	TP	FP
失稳	FN	TN

$$A_{cc} = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

$$P_{pr} = \frac{TN}{TN + FN} \quad (11)$$

$$P_{re} = \frac{TN}{TN + FP} \quad (12)$$

$$F_1 = \frac{2P_{pr}P_{re}}{P_{pr} + P_{re}} \quad (13)$$

$$P_{ma} = \frac{FP}{FP + TN} \quad (14)$$

准确率 A_{cc} 着重于整体的性能评估, F_1 分数和漏判率 P_{ma} 侧重体现失稳样本的评估。

3 算例与结果分析

3.1 数据样本集获取

文中采用新英格兰 10 机 39 节点系统验证所建模型。样本特征集的获取如图 2 所示。

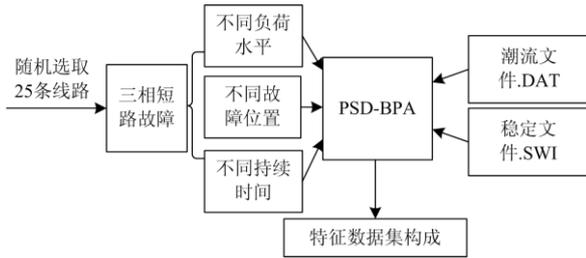


图 2 数据获取过程

Fig. 2 Data acquisition process

随机选取 25 条线路, 扰动为三相短路故障, 改变不同负荷水平、不同故障位置、不同故障持续时间, 采用 PSD-BPA 软件仿真。具体以 5% 为一个增长步长, 考虑 90%~120% 负荷情况, 相应调整发电机出力确保潮流收敛。故障位置位于每条被选取线路的 20%、50%、80% 处, 扰动发生后分别在 100 ms、160 ms、180 ms、200 ms 启动可靠保护动作同时切断两端线路。最终获取 2 100 条有效样本, 包含稳定样本 1 629 条及失稳样本 471 条, 比例为 3.5:1。

3.2 特征分析

选取 3 个时刻特征检验暂态稳定相关性, 如图 3 所示, 可知故障发生瞬间及故障切除时刻的特征对系统稳定性具有更显著的区分度。

3.3 GA 优化 DBN 的结构

将特征数据集按 8:2 随机划分为训练集和测试集, GA 全局寻优 DBN 结构。

将未过采样的训练集及测试集用于 GA 优化 DBN 的结构寻优, 得到的适应度曲线如图 4 所示。可知在寻优过程中, 随着迭代次数的增加, A_{cc} 有所提升, 第 5 次迭代时由 97.1% 升至 98.6%。可见, GA 在迭代过程中以提升 A_{cc} 为目标, 搜寻优化结构, 为后续暂态安全状态感知准备。

训练集过采样处理后, 测试集保持不变, 通过 GA 对 DBN 结构寻优。如图 5 所示, 样本比例平衡后, 模型的 A_{cc} 整体有所提升, 优化的结构下 A_{cc} 可达 99.4%。随着样本数量增加, 优化的结构层数随之增加, A_{cc} 提升。模型深层架构增加, 能更有效

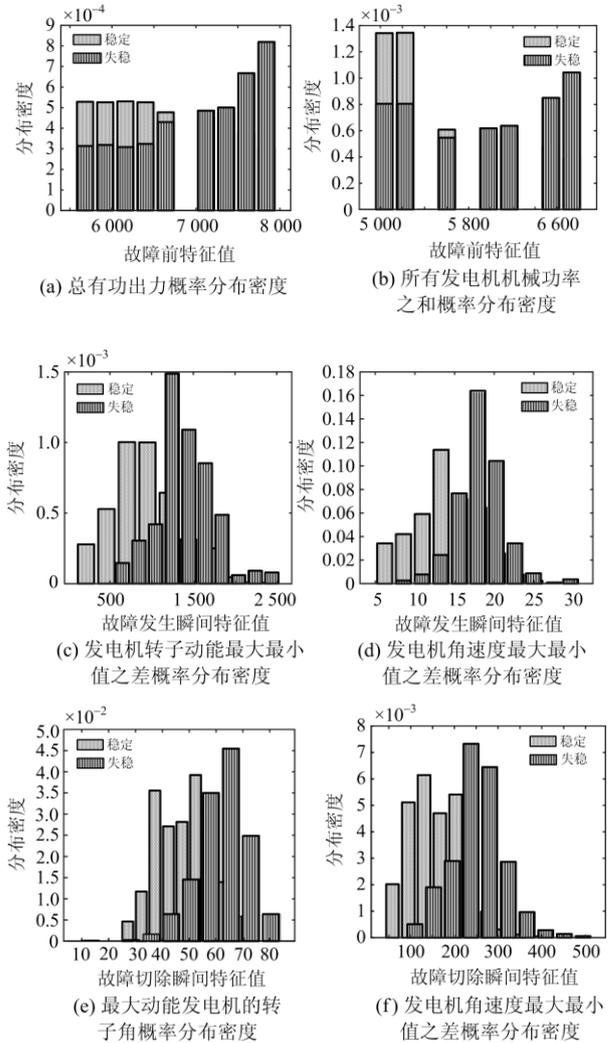


图 3 特征与暂态稳定相关性

Fig. 3 Correlation of feature and transient stability

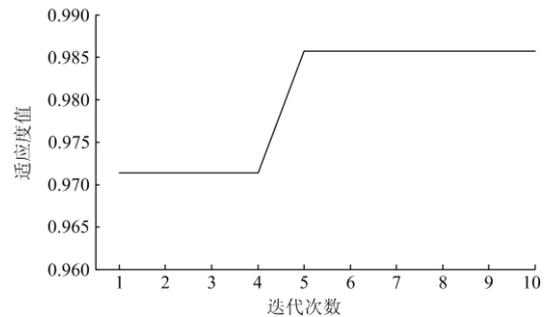


图 4 GA 优化 DBN 的适应度曲线

Fig. 4 Fitness curve of GA optimization DBN

地挖掘大数据特征与标签间的非线性映射关系。

经 GA 寻优, 在学习率、动量、迭代次数不改变的情况下, DBN 结构参数具体如表 2 所示。

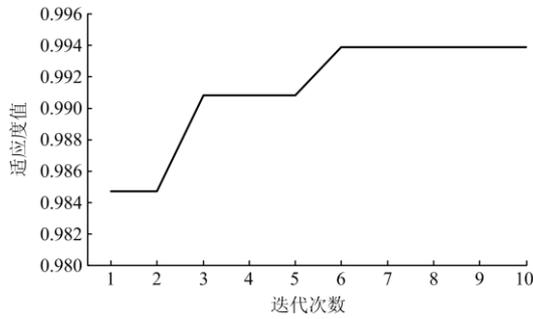


图 5 GA 优化 DBN 的适应度曲线

Fig. 5 Fitness curve of GA optimization DBN

表 2 各模型结构参数

Table 2 Model structure parameters

模型名称	隐藏层层数	每层神经元个数
无过采样传统 DBN	2	30,10
无过采样 GA-DBN	2	29,22
过采样后传统 DBN	2	30,10
过采样后 GA-DBN	3	29,22,16

3.4 模型性能

为了对比模型的性能, 将过采样后的 GA-DBN 模型分别与过采样前的 GA-DBN 模型和传统 DBN 模型、以及过采样前和过采样后两个场景下的 SVM 相对比。SVM 采用径向基函数 (Radial Basis Function, RBF), 参数选择为 $C = 10$ 、 $\gamma = 0.12$ [16]。考虑样本分组及模型自身都存在随机性, 文中测试 10 次, 去掉最大值和最小值后, 余下 8 组数据取平均值作为模型性能评估值, 具体结果见表 3。

表 3 各模型评估性能测试结果

Table 3 Test results of different TSA models

是否过采样	模型名称	$A_{cc}/\%$	$P_{ma}/\%$	F_1
否	传统 DBN	97.14	2.94	0.959 5
否	GA-DBN	98.10	1.85	0.971 8
是	传统 DBN	98.47	1.20	0.985 0
是	GA-DBN	99.08	0.42	0.990 8
否	SVM	90.00	11.95	0.852 7
是	SVM	92.86	8.20	0.870 0

由表 3 可得:

1) 过采样后的 GA-DBN 评估性能在 A_{cc} 、 P_{ma} 和 F_1 分数的评估上都优于其他模型。GA-DBN 比传统 DBN 的 A_{cc} 提升了 0.96%, F_1 分数提升了 0.012 3, P_{ma} 降低了 1.09%。这说明 GA 为 DBN 结构寻找优化解的过程省去人工试验的步骤, 采用寻优结构后能达到提升 A_{cc} 、提升 F_1 分数、降低 P_{ma} 的良好效果, 体现了网络结构对模型性能有着较大的影响。

2) 将训练集用 SMOTE 算法过采样后, 训练集中的稳定样本和不稳定样本比例为 1:1。在训练集

样本平衡后, 传统 DBN 的 A_{cc} 为 98.47%, F_1 分数为 0.985 0, P_{ma} 为 1.20%。虽然 A_{cc} 只上升了 1.33%, 但是 F_1 分数上升了 0.025 5, P_{ma} 下降了 1.74%, 较为明显。 F_1 分数和 P_{ma} 更能体现对失稳样本的评估, 平衡后失稳样本的漏判减少。

3) 过采样后的 GA-DBN 模型相较未过采样的 GA-DBN 模型, 网络结构也有所变动, A_{cc} 、 F_1 分数分别提升 0.61%、0.005 8, P_{ma} 下降 0.78%。在训练集中增加失稳样本比例, 可帮助模型学习到更多失稳样本特征, 提升失稳样本的评估正确率。同时由表 3 中数据可知, 深度学习模型比浅层机器学习, 在挖掘暂态稳定特征与结果的非线性关系上具有明显优越性。

3.5 模型鲁棒性

为了验证模型的鲁棒性, 考虑实际量测单元存在量测误差, 在数据样本的输入特征值中加入信噪比分别为 50 dB、40 dB、30 dB、20 dB、10 dB 的高斯白噪声, 测试模型性能。各模型的评估指标变化分别如图 6—图 8 所示。

由图 6—图 8 可知, 信噪比为 50 dB 和 40 dB 的噪声对各模型的结果影响并不大。当信噪比为 30 dB 时, A_{cc} 呈现下降趋势, P_{ma} 则呈现上升趋势。传统 DBN 和 GA-DBN 深度神经网络模型与 SVM

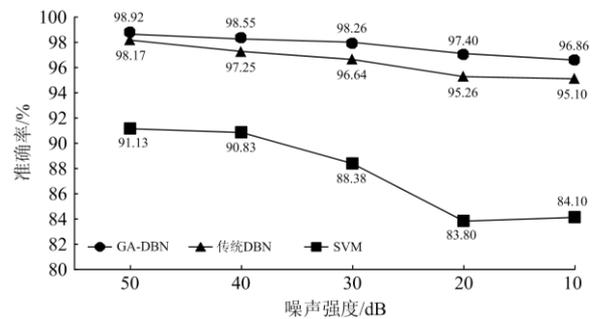
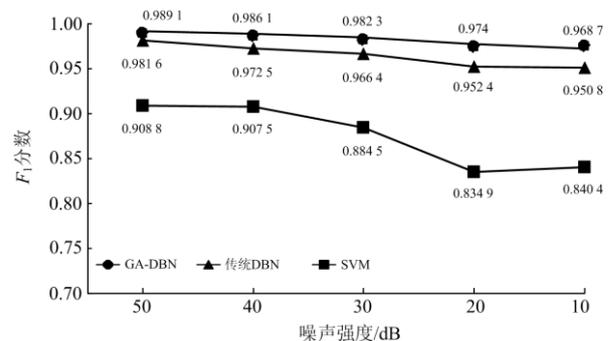


图 6 噪声对准确率的影响

Fig. 6 Effect of noise features on accuracy

图 7 噪声对 F_1 分数的影响Fig. 7 Effect of noise features on F_1 -score

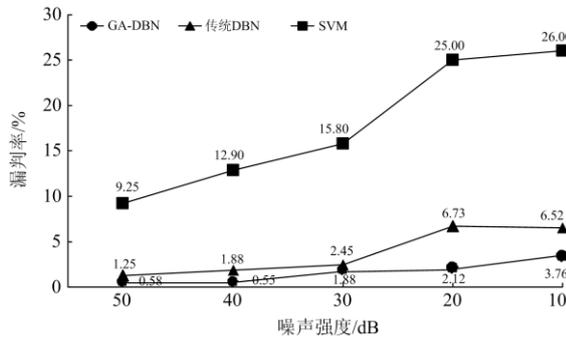


图8 噪声对漏判率的影响

Fig. 8 Effect of noise features on P_{ma}

相比较,受噪声影响较小, A_{cc} 和 F_1 分数下降的趋势在2%左右, P_{ma} 上升4%左右,而SVM波动较大, A_{cc} 下降7%左右, P_{ma} 上升16.75%。SVM的决策取决于支持向量,噪声逐渐增强影响支持向量,导致性能大幅下降。传统DBN与GA-DBN模型在特征逐层重构降维时,各神经元处于激活或不激活状态,取值为1或0,可规避噪声干扰,呈现较强的鲁棒性。

4 结论

针对电力系统暂态安全状态感知问题,提出了一种经SMOTE算法过采样后的GA-DBN模型。在新英格兰39节点系统上仿真,得到以下结论:

(1) 特征选取时,根据各特征数值分布将概率分布密度可视化,可知故障后的动态响应特征更能反映暂态稳定情况。

(2) 采用SMOTE算法过采样使得训练集中稳定样本与失稳样本比例平衡,从而使模型在训练时特征学习不偏向于稳定样本,提高了不稳定样本识别率。

(3) DBN各层神经元处于0或1状态,在特征降维的同时规避噪声。

(4) 采用遗传算法全局寻优DBN的网络结构,避免了人工反复调试结构参数,提升了模型性能,并且具有较好的鲁棒性。

参考文献

[1] 夏世威,徐英,郭志忠,等. 多维导数阶数控制的多步Taylor级数暂态稳定计算方法[J]. 电力系统及其自动化学报, 2019, 31(3): 107-112.
XIA Shiwei, XU Ying, GUO Zhizhong, et al. Multi-dimensional derivative order controlled multi-step Taylor series method for transient stability calculation[J]. Proceedings of the CSU-EPSA, 2019, 31(3): 107-112.

[2] ODUN-AYO T, CROW M L. Structure-preserved power system transient stability using stochastic energy functions[J]. IEEE Transactions on Power Systems, 2012,

27(3): 1450-1458.

[3] 王增平,朱劭璇,王彤,等. 基于故障全景信息的电力系统暂态稳定分析方法[J]. 电力系统保护与控制, 2020, 48(15): 34-42.
WANG Zengping, ZHU Shaoxuan, WANG Tong, et al. Transient stability analysis for a power system based on fault panoramic information[J]. Power System Protection and Control, 2020, 48(15): 34-42.

[4] HADIDI R, JEYASURYA B. Reinforcement learning based real-time wide-area stabilizing control agents to enhance power system stability[J]. IEEE Transactions on Smart Grid, 2013, 4(1): 489-497.

[5] HE Miao, ZHANG Junshan, ROBUST V V. Online dynamic security assessment using adaptive ensemble decision-tree learning[J]. IEEE Transactions on Power Systems, 2013, 28(4): 4089-4098.

[6] 王亮,韩冬,王长江,等. 基于MVEE和LSPTSVM的电力系统暂态稳定评估[J]. 电力系统保护与控制, 2020, 48(17): 45-54.
WANG Liang, HAN Dong, WANG Changjiang, et al. Power system transient stability assessment based on MVEE and LSPTSVM[J]. Power System Protection and Control, 2020, 48(17): 45-54.

[7] 李海英,薛琢成. 基于相关向量机的故障后功角稳定分析[J]. 系统仿真学报, 2018, 30(8): 3098-3104.
LI Haiying, XUE Zhuocheng. Stability analysis of post-fault power angle based on relevance vector machine[J]. Journal of System Simulation, 2018, 30(8): 3098-3104.

[8] 曲锐,王世荣,辛文龙. 基于半监督MPSVM的电力系统暂态稳定评估[J]. 广东电力, 2020, 33(4): 74-81.
QU Rui, WANG Shirong, XIN Wenlong. Power system transient assessment based on semi-supervised and manifold proximal support vector machine[J]. Guangdong Electric Power, 2020, 33(4): 74-81.

[9] 刘伟鹏,张国钢,刘亚魁,等. 基于主成分分析和支持向量机的高压断路器机械状态识别方法[J]. 高压电器, 2020, 56(9): 267-272, 278.
LIU Weipeng, ZHANG Guogang, LIU Yakui, et al. Mechanical status identification of high voltage circuit breakers based on principal component analysis and support vector machines[J]. High Voltage Apparatus, 2020, 56(9): 267-272, 278.

[10] 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.
- [11] 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.
- [12] AZMAN S K, ISBEIH Y J, MOURSI M S E, et al. A unified online deep learning prediction model for small signal and transient stability[J]. *IEEE Transactions on Power Systems*, 2020, 35(6): 4585-4598.
- [13] LI N, LI B L, HAN Y Q, et al. Dual cost-sensitivity factors based power system transient stability assessment[J]. *IET Generation Transmission & Distribution*, 2020, 14(24): 5858-5869.
- [14] 周艳真, 查显煜, 兰健, 等. 基于数据增强和深度残差网络的电力系统暂态稳定预测[J]. *中国电力*, 2020, 53(1): 22-31.
ZHOU Yanzhen, CHA Xianyu, LAN Jian, et al. Transient stability prediction of power systems based on deep residual network and data augmentation[J]. *Electric Power*, 2020, 53(1): 22-31.
- [15] 赵清华, 张艺豪, 马建芬, 等. 改进 SMOTE 的非平衡数据集分类算法研究[J]. *计算机工程与应用*, 2018, 54(18): 168-173.
ZHAO Qinghua, ZHANG Yihao, MA Jianfen, et al. Research on classification algorithm of imbalanced datasets based on improved SMOTE[J]. *Computer Engineering and Applications*, 2018, 54(18): 168-173.
- [16] 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.
- [17] LE ROUX N, BENGIO Y. Representational power of restricted Boltzmann machines and deep belief networks[J]. *Neural Computation*, 2008, 20(6): 1631-1649.
- [18] 李益兵, 王磊, 江丽. 基于 PSO 改进深度置信网络的滚动轴承故障诊断[J]. *振动与冲击*, 2020, 39(5): 89-96.
LI Yibing, WANG Lei, JIANG Li. Rolling bearing fault diagnosis based on DBN algorithm improved with PSO[J]. *Journal of Vibration and Shock*, 2020, 39(5): 89-96.
- [19] SUN Jinlei, LIU Wei, TANG Chuanyu, et al. A novel active equalization method for series-connected battery packs based on clustering analysis with genetic algorithm[J]. *IEEE Transactions on Power Electronics*, 2021, 36(7): 7853-7865.
- [20] 石宪, 钱玉良. 基于改进深度信念网络的燃气轮机故障诊断[J]. *上海电力大学学报*, 2020, 36(2): 123-130.
SHI Xian, QIAN Yuliang. Diagnosis method based on genetic algorithm optimization for deep belief network[J]. *Journal of Shanghai University of Electric Power*, 2020, 36(2): 123-130.
- [21] WANG B, FANG B W, WANG Y J, 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.
- [22] 周艳真, 吴俊勇, 于之虹, 等. 用于电力系统暂态稳定预测的支持向量机组合分类器及其可信度评价[J]. *电网技术*, 2017, 41(4): 1188-1196.
ZHOU Yanzhen, WU Junyong, YU Zhihong, et al. Support vector machine ensemble classifier and its confidence evaluation for transient stability prediction of power systems[J]. *Power System Technology*, 2017, 41(4): 1188-1196.
- [23] 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.
- [24] 王忠震, 黄勃, 方志军, 等. 改进 SMOTE 的不平衡数据集分类算法[J]. *计算机应用*, 2019, 39(9): 2591-2596.
WANG Zhongzhen, HUANG Bo, FANG Zhijun, et al. Improved SMOTE unbalanced data integration classification algorithm[J]. *Journal of Computer Applications*, 2019, 39(9): 2591-2596.

收稿日期: 2021-06-01; 修回日期: 2021-08-27

作者简介:

李海英(1975—), 女, 博士, 副教授, 研究方向为大数
据在智能电网中的应用; E-mail: hlyi@usst.edu.cn

沈益涛(1995—), 男, 通信作者, 硕士研究生, 研究方
向为电力系统安全运行; E-mail: 594937204@qq.com

罗雨航(1996—), 男, 硕士, 研究方向为电力系统暂态
分析. E-mail: 767222789@qq.com

(编辑 魏小丽)