

基于深度学习的暂态稳定评估与严重度分级

尹雪燕¹, 闫炯程¹, 刘玉田¹, 仇晨光²

(1. 山东大学 电网智能化调度与控制教育部重点实验室, 山东 济南 250061;

2. 国网江苏省电力有限公司, 江苏 南京 210032)

摘要:提出一种安全域概念下的堆叠降噪自动编码器和支持向量机集成模型相结合的暂态稳定评估方法。将故障前的潮流量作为输入,利用堆叠降噪自动编码器对输入量进行多层抽象表达,使用提取的各层特征训练支持向量机;建立支持向量机集成分类模型进行暂态稳定评估,对评估结果进行可信度分析,将输入空间划分为稳定区、边界区和失稳区;利用效用理论结合所提出的暂态稳定裕度指标对运行方式进行严重度分级。算例结果表明,所提暂态稳定评估方法具有更高的评估准确率和一定的泛化能力;所提严重度分级方法能够直观表现不同运行方式的危险程度。

关键词:暂态稳定评估;深度学习;集成学习;支持向量机;严重度分级

中图分类号:TM 761

文献标识码:A

DOI:10.16081/j.issn.1006-6047.2018.05.009

0 引言

特高压交直流混联电网产生的调度运行数据体量庞大,自然灾害的频发使电网可能出现的预想事故场景更加复杂^[1],传统的基于模型的安全稳定分析方法无法满足大电网的在线调度运行需求。基于数据挖掘技术进行在线安全稳定评估为大电网的智能调度控制提供了新的思路^[2]。

基于数据挖掘方法进行暂态稳定评估主要有3种思路。第一种思路以故障前、故障发生瞬间和故障切除时刻的系统变量(包括线路功率、母线电压等潮流量和发电机的转子角、角速度等动态参数)作为输入特征,判断预想事故集下多种运行方式的暂态稳定性,但这种方法对动态相量测量系统要求较高^[2];第二种思路是稳定域概念下的暂态稳定评估规则,以故障清除时刻的系统变量作为输入特征,判断预想事故集下固定运行方式的暂态稳定性,用于协助制定紧急控制策略,但由于故障已经发生,对评估的快速性和准确性有极高的要求^[3-4];第三种思路是安全域概念下的暂态稳定评估规则,以系统故障前的潮流量作为输入特征,判断固定预想事故下多种运行方式的暂态稳定性,如果系统存在失稳风险,可以及时采取预防控制措施^[5]。本文基于第三种思路开展研究工作。

目前用于暂态稳定评估的数据挖掘方法大多是浅层学习模型,如支持向量机 SVM(Support Vector Machine)^[6]、决策树 DT(Decision Tree)^[7]和极学

习机 ELM(Extreme Learning Machine)^[8]等,其局限性在于对复杂函数的表征能力有限,计算复杂度高,泛化能力差。因此,深度学习模型被引入暂态稳定评估问题中,如深度信念网络^[9]、堆叠自动编码器 SAE(Stacked AutoEncoder)^[4]等。深度学习利用多层非线性网络结构逼近复杂函数,学习输入数据的分布式特征表示,具有从少量样本集中提取本质特征的能力。然而,现有的基于深度学习的暂态稳定评估模型存在以下不足:第一,只利用了深度学习模型提取的最后一层隐层特征,造成数据资源浪费;第二,顶层分类器均采用 softmax 回归层,分类机制较为简单;第三,没有对系统的稳定程度进行评估。

本文将堆叠降噪自动编码器 SDAE(Stacked Denoising AutoEncoder)的特征提取能力和 SVM 的分类/回归性能相结合,提出一种基于 SDAE 特征集成模型的暂态稳定评估方法;基于效用理论建立暂态稳定裕度的严重度函数,根据暂态稳定裕度的严重度对运行方式进行分级。

1 SDAE 特征集成模型

1.1 降噪自动编码器

降噪自动编码器 DAE(Denoising AutoEncoder)是深度学习中的变形结构,通过在自动编码器的基础上引入降噪技术,迫使隐层发现更具鲁棒性的特征,避免学到无编码功能的恒等函数,具有超越其他结构的特征提取能力^[10]。DAE 的训练过程如图 1 所示。

给定样本集 $\{x_i\} (i=1, 2, \dots, n)$, $x_i \in \mathbf{R}^m$ 表示第 i 个样本有 m 维输入特征,对输入样本进行随机“破坏污染”^[10],得到样本集 $\{\tilde{x}_i\}$,定义代价函数为:

$$L(\mathbf{x}, \mathbf{z}) = \frac{1}{n} \sum_{i=1}^n \|z(\tilde{x}_i) - x_i\| \quad (1)$$

收稿日期:2018-02-09;修回日期:2018-03-30

基金项目:国家重点研发计划项目(2017YFB0902600);国家电网公司科技项目(SGJS0000DKJS1700840)

Project supported by the National Key R&D Program of China (2017YFB0902600) and the Science and Technology Project of State Grid Corporation of China(SGJS0000DKJS1700840)

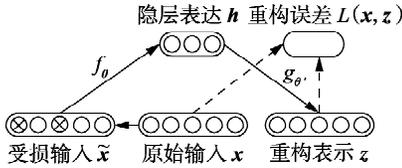


图 1 降噪自动编码器训练过程
Fig.1 Training process of DAE

其中, $z(\tilde{x}_i)$ 为受损输入 \tilde{x}_i 的重构表示。

首先将受损输入 \tilde{x}_i 通过编码过程映射为隐层表示 $h(\tilde{x}_i)$, 然后通过解码过程映射为重构表示 $z(\tilde{x}_i)$, 通过不断优化模型参数 θ 和 θ' , 使 $L(x, z)$ 足够小。编码和解码过程如下所示:

$$h = f_{\theta}(\tilde{x}) = s(W\tilde{x} + b) \quad (2)$$

$$z = g_{\theta'}(h) = s(W'h + b') \quad (3)$$

其中, 映射参数 $\theta = [W, b]$, $\theta' = [W', b']$; W, W' 为权值矩阵; b, b' 为偏移量; s 为激活函数, 采用 sigmoid 函数。

1.2 SDAE

SDAE 是由 DAE 栈式堆叠构成的深层结构, 在图像识别、缺陷检测等方面广泛应用^[10]。利用贪婪无监督学习算法对 SDAE 进行逐层预训练, 实现层次特征提取功能, 预训练过程如图 2 所示。

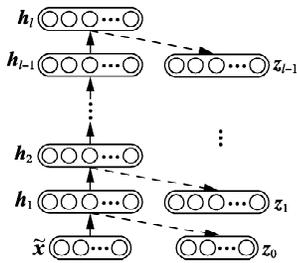


图 2 堆叠降噪自动编码器预训练过程
Fig.2 Pre-training process of SDAE

给定一个有 l 层隐层的 SDAE。使用受损输入 \tilde{x} 训练第一个 DAE, 学到特征表示 h_1 。第 $i(0 < i < l)$ 个 DAE 的隐层输出 h_i 训练第 $i+1$ 个 DAE, 学到特征表示 h_{i+1} , 依此类推, 学到原始输入 x 的 l 阶特征表示。

传统的特征提取方法通常需要人工的参与, 会引入主观因素的影响; 深度学习的优势在于能够自动完成特征提取工作, 保证了特征提取过程的客观性。

1.3 SVM

SVM 以统计学理论为基础, 基于结构风险最小化原则进行训练, 具有所需训练样本少、泛化能力强等特点, 常被用于模式识别和回归预测。

给定样本集 $(x_i, y_i) (i = 1, 2, \dots, n)$, $x_i \in \mathbf{R}^m$, $y_i \in \{+1, -1\}$ 表示暂态稳定类别, 设定 +1 表示稳定, -1 表示失稳。SVM 分类模型能够提供概率输出形式^[11]:

$$P(C_{+1} | x) = 1 / (1 + e^{-g(x)}) \quad (4)$$

$$P(C_{-1} | x) = 1 / (1 + e^{g(x)}) \quad (5)$$

其中, $P(C_{+1} | x)$ 和 $P(C_{-1} | x)$ 分别为样本 x 被识别为 +1 类和 -1 类的概率, $P(C_{+1} | x) + P(C_{-1} | x) = 100\%$; $g(x)$ 为样本与最优分类超平面的位置关系, 如式 (6) 所示。

$$g(x) = \sum_{i=1}^{N_{SV}} \alpha_i y_i^{SV} K(x_i^{SV}, x) + b \quad (6)$$

其中, N_{SV} 为支持向量个数; x_i^{SV} 为第 i 个支持向量; y_i^{SV} 为其稳定类别编号; α_i 为拉格朗日乘子; 本文采用径向基核函数 $K(x_i^{SV}, x) = \exp(-\gamma |x_i^{SV} - x|^2)$, $\gamma \in \mathbf{R}$ 为核参数。

可信度指标^[11] $R = \max\{P(C_{+1} | x), P(C_{-1} | x)\}$, R 的取值范围为 50% ~ 100%。

SVM 回归模型的原理与 SVM 分类模型相似。利用核函数将输入空间转换到高维特征空间, 在高维特征空间中构造最优回归超平面:

$$f(x) = \sum_{i=1}^{N_{SV}} (\alpha_i - \alpha_i^*) K(x_i^{SV}, x) + b \quad (7)$$

其中, α_i^* 为拉格朗日乘子; $K(x_i^{SV}, x)$ 同样采用径向基核函数。

1.4 基于 SDAE 层次特征的 SVM 集成模型

SDAE 的结构和参数由训练样本集的预测结果决定。当对其他样本集进行暂态稳定评估时如果使用 SDAE 提取的最高隐层特征作为 SVM 的输入, 则并不能保证具有最好的评估性能。因此, 建立 SVM 集成模型进行分类或回归, 吸收集成学习模型预测性能优于子学习器的优点^[2], 提高暂态稳定评估性能; 为了构造具有差异性的子学习器, 使用 SDAE 提取的各个隐层特征训练 SVM, 充分利用所有隐层提取的特征信息。SDAE 特征集成模型的结构如图 3 所示。

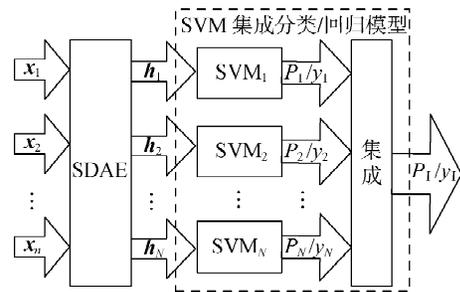


图 3 SDAE 特征集成分类/回归模型结构图

Fig.3 Structure of classification/regression model for feature integration of SDAE

给定样本集 $\{x_i\} (i = 1, 2, \dots, n)$, 使用 SDAE 作为可训练的特征提取工具, 假设 SDAE 有 N 个隐层, 得到层次特征 $h_j (j = 1, 2, \dots, N)$, h_j 的特征维数和隐层节点数相同; 使用特征集 h_j 训练 SVM_j 模型, 采用

“平均法”整合子学习器的输出。

对于 SVM 集成分类模型,输出 $P_1(C_{+1(-1)}|\mathbf{x})$:

$$P_1(C_{+1(-1)}|\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N P_i(C_{+1(-1)}|\mathbf{x}) \quad (8)$$

其中, $P_i(C_{+1(-1)}|\mathbf{x})$ 为第 i 个子分类器的概率输出。

对于 SVM 集成回归模型,输出 y_1 :

$$y_1 = \frac{1}{N} \sum_{i=1}^N y_i \quad (9)$$

其中, y_i 为第 i 个子回归器的暂态稳定裕度预测值。

2 基于 SDAE 特征集成模型的暂态稳定评估与严重度分级

现有基于数据挖掘的暂态稳定评估方法大多只给出稳定与否的二元信息^[12],本文基于暂态稳定裕度对运行方式进行严重度分级,直观展示不同运行方式的危险程度。使用一个回归模型预测所有样本的暂态稳定裕度^[12],不能保证安全域边界附近样本的预测精度,且时域仿真法虽然精度高,但耗时长,为了快速准确地获得暂态稳定裕度值,对 SDAE 特征集成分类模型的暂态稳定评估结果进行可信度分析,将输入空间划分为 3 个区域:稳定区内的样本大多远离安全域边界,可以利用 SDAE 特征集成回归模型快速预测;边界区内的样本位于安全域边界附近,存在漏警和误警现象,利用时域仿真法得到精确的暂态稳定裕度;失稳区内样本的暂态稳定裕度均小于 0。具体分析过程如图 4 所示。

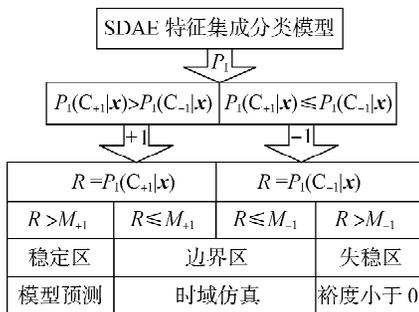


图 4 暂态稳定类别判断及可信度分析过程示意图

Fig.4 Schematic diagram of classification and confidence analysis of transient stability

2.1 暂态稳定评估及可信度分析

根据 SDAE 特征集成分类模型对测试样本集的评估结果和概率输出设置可信度阈值 M_{+1} 和 M_{-1} ^[11],可信度分析过程如图 4 所示。利用式(8)计算 SDAE 特征集成分类模型的概率输出,如果 $P_1(C_{+1}|\mathbf{x}) > P_1(C_{-1}|\mathbf{x})$,则 $y_1 = +1$,评估结果为稳定,当 $R = P_1(C_{+1}|\mathbf{x})$, $R > M_{+1}$ 时,评估结果可信,当 $R \leq M_{+1}$ 时,评估结果不可信;否则 $y_1 = -1$,评估结果为失稳,当 $R = P_1(C_{-1}|\mathbf{x})$, $R > M_{-1}$ 时,评估结果可信,当 $R \leq M_{-1}$ 时,评估结果不可信。根据上述规则,将输

入空间划分为稳定区、边界区和失稳区。在线应用时,可定期更新可信度阈值以适应未知工况。

2.2 稳定裕度及严重度分级

采用基于临界清除时间的暂稳裕度指标 M ^[12]:

$$M = t_{\text{CCT}} - t_{\text{cl}} \quad (10)$$

其中, t_{cl} 为故障切除时间; t_{CCT} 为临界清除时间。

当 $M > 0$ 时,系统稳定,反之失稳。利用图 4 所示的方法分别得到 3 个分区内样本的暂态稳定裕度,基于效应理论^[13]构造严重度函数:设置阈值 T ,当 $M > T$ 时,认为系统完全没有暂态失稳风险,严重度函数值为 0;当 $M < 0$ 时,认为系统会发生暂态失稳,严重度函数值为 3;当 M 属于区间 $[0, T]$ 时,使用指数函数作为该区间内的严重度函数,见式(11)。

$$S_m = a_1 e^{-M} + a_2 \quad (11)$$

其中, a_1 和 a_2 为系数。

由于严重度函数是连续函数,所以函数过点 $(T, 0)$ 和 $(0, 3)$,将这 2 点的坐标代入,得到指数函数为:

$$S_m = \frac{3}{1-e^{-T}} e^{-M} - \frac{3e^{-T}}{1-e^{-T}} \quad (12)$$

综上所述,得到暂态稳定裕度的严重度函数:

$$S_m = \begin{cases} 0 & M > T \\ \frac{3}{1-e^{-T}} e^{-M} + 3 - \frac{3}{1-e^{-T}} & 0 \leq M \leq T \\ 3 & M < 0 \end{cases} \quad (13)$$

将样本的严重度分为 5 级,令 S_r 代表严重度等级,则获得本文的严重度分级规则:

$$S_r = \begin{cases} 0 & S_m = 0 \\ 1 & 0 < S_m \leq 1 \\ 2 & 1 < S_m \leq 2 \\ 3 & 2 < S_m < 3 \\ 4 & S_m = 3 \end{cases} \quad (14)$$

严重度等级为 3 的样本处于安全域边界附近,暂态稳定裕度较低;严重度等级为 4 的样本包括失稳样本和临界稳定样本。在实际调度运行时,将严重度等级为 3 和 4 的运行方式优先呈现给调度人员,为调度人员针对高危运行方式制定预防控制措施提供参考信息。

2.3 暂态稳定评估流程

基于 SDAE 特征集成模型的暂态稳定评估流程分为离线训练、实时应用和在线更新 3 个环节。

离线训练环节:考虑电网拓扑结构、发电机出力 and 负荷变化等因素,随机生成样本集及相应的离线预想故障集;对每个故障下的样本集分别进行模型训练,得到各个故障下的 SDAE 特征集成模型。

实时应用环节:启动方式为周期性(15 min)触

发。基于在线运行方式,利用计划数据(如断面功率计划、检修计划等)和预测数据(如超短期负荷预测等),生成多个未来运行方式及在线预想事故集,利用各个预想事故对应的 SDAE 特征集成模型进行暂态稳定评估。

在线更新环节:从能量管理系统中获取在线运行数据,更新暂态稳定评估模型的结构和参数。当在线预想事故集中出现没有训练过的预想事故时,在线训练该事故下的暂态稳定评估模型。

由于各个故障对应的暂态稳定评估过程相互独立,以上 3 个阶段均可与现有的分布式并行计算技术相结合,提高评估效率,满足在线应用的要求。

3 算例分析

3.1 样本集构造

将 2 个双馈型风电场分别接入新英格兰 10 机 39 节点系统的母线 35 和母线 37,等容量替换这 2 条母线上的同步发电机。在 80%、85%、...、120% 的基准负荷水平下,风电场出力随机波动,并相应改变同步发电机出力。假定母线 1 和母线 2 之间的线路发生三相短路故障,故障位于母线 1 侧,0.1 s 后切除故障线路,仿真时长 5 s。以仿真时长内任意 2 台同步发电机的最大相对功角差是否大于 180° 作为判稳标准。由于安全域是定义在功率注入空间上的概念,选取易于量测的发电机出力、线路功率、母线电压以及负荷等故障前的潮流量构成原始特征空间,共 143 维。仿真软件采用中国电科院的 PSD-BPA,共生成 7 839 个有效样本,其中失稳样本 4 712 个,暂态稳定样本 3 127 个。随机选取其中 6 000 个样本作为训练样本,剩余样本作为测试样本。为了测试模型的泛化能力,选取 75% 和 125% 这 2 种基准负荷水平重复上述步骤,分别生成样本容量为 1 000 的新运行方式测试集。

3.2 暂态稳定评估性能比较及结果可信度分析

使用准确率 P_{ACC} 、漏警率 P_{FD} 和误警率 P_{FA} 作为分类性能的评价指标^[3]。由于漏警带来的危害远大于误警,通过逐层搜索、依次叠加的网络构造方式^[4],选择使训练样本集漏警率最低的结构和参数作为 SDAE 的结构和参数,最终确定 SDAE 的层数为 5 层,每层节点数依次为 143-400-500-400-100。

SVM 直接采用经验参数^[14]进行训练;DT 模型采用 C4.5 算法,置信因子设为 0.25;ELM 通过五折交叉验证方法搜索最优隐层节点数。

将本文提出的 SDAE 特征集成分类模型与其他分类模型进行对比,结果如表 1 所示。由表 1 可知,SDAE 特征集成分类模型的评估性能明显优于 ELM、DT 和 SVM 这 3 种浅层模型;模型 4—6 的对比结果表明,以主成分分析 PCA (Principal Component Analysis) 法特征集作为输入的 SVM 模型分类性能较差,因为 PCA 基于特征空间的线性变化进行降维,对输入数据的抽象能力有限,SAE 对输入数据进行多层非线性变换,对输入数据的表达能力更强,而 SDAE 在 SAE 的基础上引入降噪技术,提取的特征更具鲁棒性;模型 6 和 7 的对比结果表明,使用 SVM 作为 SDAE 的顶层分类器,模型的分类性能更好,因为与 SVM 相比,softmax 回归层利用非线性的激活函数进行暂态稳定类别判断,分类机制相对简单。

表 1 不同分类模型性能对比结果

Table 1 Comparison of performance among different classification models

模型编号	分类器	$P_{ACC}/\%$	$P_{FD}/\%$	$P_{FA}/\%$
1	ELM	95.00	2.34	2.66
2	DT	96.25	1.63	2.12
3	SVM	97.12	1.25	1.63
4	PCA+SVM	97.28	1.25	1.47
5	SAE+SVM	97.99	0.76	1.25
6	SDAE+SVM	98.04	0.71	1.25
7	SDAE+softmax	97.82	0.87	1.31
8	本文 SDAE+SVMs	98.20	0.60	1.20

将 SDAE 特征集成分类模型与使用 SDAE 提取的各层特征作为输入的子分类器进行对比,结果如表 2 所示。由表 2 可知,与子分类器相比,SDAE 特征集成分类模型提高了评估准确率,同时漏警率和误警率都有所降低;对未训练过的新运行方式测试集仍有较好的评估性能,具有一定的泛化能力。

以测试集为例,进一步分析 SVM 集成分类模型的评估性能优于子分类器的原因,结果如表 3 所示。对表 3 分析可知,SDAE 特征集成分类模型能够校正样本分类错误的原因在于:这些样本虽然被部分子分类器错误分类,但可信度均在 50%~60% 之间,位于安全域边界上;这些样本在其他子分类器中的分

表 2 SDAE 特征集成分类模型和子分类器的暂态稳定分类性能对比结果

Table 2 Comparison of performance among SDAE feature integration classification model and its sub-classifiers

样本集	子分类器 1			子分类器 2			子分类器 3			子分类器 4			SDAE 特征集成分类模型		
	P_{ACC}	P_{FD}	P_{FA}	P_{ACC}	P_{FD}	P_{FA}									
训练集	97.85	0.80	1.35	98.05	0.80	1.15	98.25	0.75	1.00	98.55	0.55	0.90	98.80	0.50	0.70
测试集	97.61	1.14	1.25	97.77	1.03	1.20	97.88	0.82	1.30	98.04	0.71	1.25	98.20	0.60	1.20
新测试集 1	97.20	1.30	1.50	97.40	1.20	1.40	97.70	1.10	1.20	97.60	0.90	1.50	97.80	0.70	1.50
新测试集 2	97.00	1.40	1.60	97.30	1.20	1.50	97.60	1.10	1.30	97.60	1.00	1.40	97.80	0.90	1.30

类结果具有较高的可信度,远离安全域边界,对错分类器起到校正作用,使 SDAE 特征集成分类模型输出正确的评估结果。SDAE 特征集成分类模型出现部分子分类器分类正确而集成结果分类错误的原因在于:样本位于各子分类器的安全域两侧或边界上,将子分类器的概率输出集成后,可信度在 50%~60% 之间,位于 SDAE 特征集成分类模型的安全域边界上,容易发生分类错误。因此,需要对 SDAE 特征集成分类模型的评估结果进行可信度分析。

表 3 测试集分析结果

Table 3 Analysis results of test set

子分类器	样本数			
	校正漏警	校正误警	增加漏警	增加误警
1	13	5	3	4
2	11	2	3	2
3	4	3	0	1
4	6	4	4	3

设定可信度阈值 $M_{+1}=93.50\%$ 和 $M_{-1}=90.00\%$, 根据阈值将样本集划分为稳定区、边界区和失稳区,各个分区内的样本数如表 4 所示。由仿真结果可知,新运行方式测试集的稳定区/失稳区内都是稳定/失稳的样本,证明了可信度阈值设置的合理性。

表 4 不同样本集的分区分结果

Table 4 Partition results of different sample sets

样本集	样本数		
	稳定区	边界区	失稳区
训练集	2 077	523	3 400
测试集	678	151	1 010
新测试集 1	621	81	298
新测试集 2	367	92	541

3.3 裕度指标预测误差分析及样本严重度分级

SDAE 特征集成回归模型的建模过程和 SDAE 特征集成分类模型相似,以训练集样本的平均绝对误差 MAE (Mean Absolute Error) 最低为目标搜索 SDAE 的结构和参数,最终确定 SDAE 的结构和参数是 [143-500-200-50]; 根据文献 [15] 中的方法确定 SVM 回归模型的参数:不敏感系数 $\varepsilon=0.0128$,核参数 $\gamma=0.1895$,惩罚因子 $C=2.1126$ 。SDAE 特征集成回归模型的裕度预测误差分析结果如表 5 所示,表 5 中样本集的暂态稳定裕度预测结果的平均绝对误差均小于 0.01 s,可满足实际应用要求,这表明 SDAE 特征集成回归模型具有较高的预测精度和一定的泛化能力。

表 5 SDAE 特征集成回归模型的平均绝对误差分析结果

Table 5 MAE of SDAE feature integration regression model

样本集	MAE	样本集	MAE
训练集	0.001 6	新测试集 1	0.007 5
测试集	0.003 3	新测试集 2	0.008 1

设定阈值 $T=0.1\text{ s}^{[12]}$, 根据式 (13) 和 (14) 对运

行方式进行严重度分级,分级结果如表 6 所示。

表 6 严重度分级结果

Table 6 Results of severity grading

严重度等级	样本数			
	训练集	测试集	新测试集 1	新测试集 2
4	4 086	1 231	432	666
3	571	175	138	92
2	987	335	277	183
1	273	71	88	41
0	83	27	65	18

分析表 6 的严重度分级结果可知,严重度等级为 4 和 3 的运行方式具有部分母线负荷较重或部分输电线路潮流接近极限传输容量的特点,在给定预想事故下会发生失稳或暂态稳定裕度较低,表明所提严重度分级方法有利于调度人员从海量运行方式中快速识别出失稳和接近安全域边界的运行方式。

4 结论

本文提出一种安全域概念下的基于 SDAE 特征集成模型的暂态稳定评估和严重度分级方法。该方法使用 SDAE 提取的层次特征和 SVM 模型分别作为集成学习模型的输入和子学习器,融合了深度学习和集成学习的优势;根据可信度对输入空间进行划分,兼顾了评估的快速性和准确性;基于效用理论对运行方式进行严重度分级,使暂态稳定评估结果更加直观。算例分析结果表明:本文提出的暂态稳定评估方法具有更低的漏警率和误警率,对未知工况具有一定的泛化能力;提出的严重度分级方法可以筛选出接近安全域边界的高危运行方式。使用与系统规模无关的统计特征构建原始特征空间,包括故障前潮流量的平均值、最大值等常见的统计特征以及标准差、中位数等稳健统计特征^[14],将提出的暂态稳定评估与严重度分级方法在实际电网算例中进行验证,是下一步要开展的工作。

参考文献:

- [1] BIE Z, LIN Y, LI G, et al. Battling the extreme: a study on the power system resilience [J]. Proceedings of the IEEE, 2017, 105 (7): 1253-1266.
- [2] 刘玉田, 林飞. 基于相量测量技术和模糊径向基网络的暂态稳定性预测[J]. 中国电机工程学报, 2000, 20(2): 19-23. LIU Yutian, LIN Fei. Application of PMU and fuzzy radial basis function network to power system transient stability prediction [J]. Proceedings of the CSEE, 2000, 20(2): 19-23.
- [3] 张玮灵, 胡伟, 闵勇, 等. 稳定域概念下考虑保守性的电力系统在线暂态稳定评估方法[J]. 电网技术, 2016, 40(4): 992-998. ZHANG Weiling, HU Wei, MIN Yong, et al. Conservative online transient stability assessment in power system based on concept of stability region [J]. Power System Technology, 2016, 40(4): 992-998.
- [4] 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[EB/OL]. (2017-06-12)[2018-01-20]. <http://www.cnki.net/>.
- ZHU Qiaomu, CHEN Jinfu, LI Hongyi, et al. Transient stability assessment based on stacked autoencoder[EB/OL]. (2017-06-12)[2018-01-20]. <http://www.cnki.net/>.
- [5] 戴远航,陈磊,张玮灵,等. 基于多支持向量机综合的电力系统暂态稳定评估[J]. 中国电机工程学报, 2016, 36(5): 1173-1180.
- DAI Yuanhang, CHEN Lei, ZHANG Weiling, et al. Power system transient stability assessment based on multi-support vector machines [J]. Proceedings of the CSEE, 2016, 36(5): 1173-1180.
- [6] WANG B, FANG B, WANG Y, 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.
- [7] AMRAEE T, RANIBAR S. Transient instability prediction using decision tree technique [J]. IEEE Transactions on Power Systems, 2013, 28(3): 3018-3037.
- [8] 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 Automatic Equipment, 2016, 36(2): 118-123.
- [9] 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.
- [10] ZHENG Y J, CHEN S Y, XUE Y, et al. A pythagorean-type fuzzy deep denoising autoencoder for industrial accident early warning [J]. IEEE Transactions on Fuzzy Systems, 2017, 25(6): 1561-1575.
- [11] 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.
- [12] 周艳真,吴俊勇,于之虹,等. 基于转子角轨迹簇特征的电力系统暂态稳定评估[J]. 电网技术, 2016, 40(5): 1482-1487.
- ZHOU Yanzhen, WU Junyong, YU Zhihong, et al. Power system transient stability assessment based on cluster features of rotor angle trajectories [J]. Power System Technology, 2016, 40(5): 1482-1487.
- [13] 张国华,段满银,张建华,等. 基于证据理论和效用理论的电力系统风险评估[J]. 电力系统自动化, 2009, 33(23): 1-4, 47.
- ZHANG Guohua, DUAN Manyin, ZHANG Jianhua, et al. Power system risk assessment based on the evidence theory and utility theory [J]. Automation of Electrical Power Systems, 2009, 33(23): 1-4, 47.
- [14] 黄彦浩,于之虹,史东宇,等. 基于海量在线历史数据的大电网快速判稳策略[J]. 中国电机工程学报, 2016, 36(3): 596-603.
- HUANG Yanhao, YU Zhihong, SHI Dongyu, et al. Strategy of huge electric power system stability quick judgment based on massive historical online data [J]. Proceedings of the CSEE, 2016, 36(3): 596-603.
- [15] 闫国华,朱永生. 支持向量机回归的参数选择方法[J]. 计算机工程, 2009, 35(14): 218-220.
- YAN Guohua, ZHU Yongsheng. Parameters selection method for support vector machine regression [J]. Computer Engineering, 2009, 35(14): 218-220.

作者简介:



尹雪燕

尹雪燕(1993—),女,山东泰安人,硕士研究生,主要研究方向为电力系统运行与控制(**E-mail**: yinxxy@mail.sdu.edu.cn);

闫炯程(1994—),男,山东潍坊人,硕士研究生,主要研究方向为电力系统运行与控制(**E-mail**: yanjc@mail.sdu.edu.cn);

刘玉田(1964—),男,山东青州人,教授,博士研究生导师,博士,通信作者,主要研究方向为电力系统运行与控制(**E-mail**: liuyt@sdu.edu.cn);

仇晨光(1977—),男,江苏盐城人,高级工程师,硕士,主要研究方向为大电网运行控制及安全分析(**E-mail**: cg_qiu@hotmail.com)。

Deep learning based transient stability assessment and severity grading

YIN Xueyan¹, YAN Jiongcheng¹, LIU Yutian¹, QIU Chenguang²

(1. Key Laboratory of Power System Intelligent Dispatch and Control of Ministry of Education,

Shandong University, Ji'nan 250061, China; 2. State Grid Jiangsu Electric Power Company, Nanjing 210032, China)

Abstract: A transient stability assessment method combining SDAE (Stacked Denoising AutoEncoder) and an ensemble model based on SVMs (Support Vector Machines) is proposed under the concept of security region. The power flow data before the fault are set as inputs, from which the multi-level features are abstracted by SDAE for training SVMs. An ensemble classification model based on SVMs is established to assess the transient stability, and the confidence analysis of the results is carried out to divide the input space into stable area, boundary area and unstable area. The utility theory combined with the proposed transient stability margin index is used to grade the severity of operation modes. Case results show that, the proposed transient stability assessment method has higher accuracy and better generalization ability, and the proposed severity grading method can directly show the risk degree of different operation modes.

Key words: transient stability assessment; deep learning; ensemble learning; support vector machines; severity grading