

基于Tri-training-SSAE半监督学习算法的电力系统暂态稳定评估

卫志农¹,李超凡¹,丁爱飞^{2,3},孙国强¹,黄蔓云¹,臧海祥¹,方熙程⁴

(1. 河海大学 能源与电气学院,江苏 南京 211100;2. 国电南瑞吉电新能源(南京)有限公司,江苏 南京 211106;
3. 国电南瑞科技股份有限公司,江苏 南京 211106;4. 国网江苏省电力有限公司扬中市供电分公司,江苏 镇江 212200)

摘要:基于机器学习的暂态稳定评估方法主要采用监督学习方法,为了解决监督学习方法所需的有标签样本难以获取的问题,提出基于三体训练-稀疏堆叠自动编码器(Tri-training-SSAE)半监督学习算法的电力系统暂态稳定评估方法。构建基于堆叠稀疏自动编码器的暂态稳定评估模型;在传统的三体训练过程中加入伪标签样本置信度判断,以减小噪声数据对模型训练的影响;以堆叠稀疏自动编码器为基分类器构建三体训练-稀疏堆叠自动编码器模型,利用大量的无标签样本提高模型的泛化能力。通过IEEE 39节点系统与华东某省级电网进行分析验证,结果表明,所提方法在有标签样本数较少时具有更高的评估准确度。

关键词:暂态稳定评估;机器学习;半监督学习;三体训练算法;堆叠稀疏自动编码器

中图分类号:TM712

文献标志码:A

DOI:10.16081/j.epae.202212009

0 引言

随着区域大电网之间的互联,电力系统的网络结构及运行特性日益复杂,暂态稳定性分析的难度进一步增大。在实际电网中,严重的停电事故通常由系统暂态失稳导致,而故障发生后暂态过程的持续时间通常为秒级,若不及时发现故障并进行有效处理,则会造成更严重的事故,影响电力系统的安全稳定运行^[1-2]。因此,快速准确地进行暂态稳定评估(transient stability assessment, TSA)对电力系统的稳定运行具有极其重要的意义。

传统的暂态稳定分析方法包括时域仿真法^[3-4]、直接法^[5-6]等,但这些方法在面对复杂电网时无法同时满足计算精度和速度的要求。基于数据挖掘的机器学习方法无需建立具体的数学模型,将TSA视为分类问题,建立系统特征量与暂态稳定性之间的映射关系,通过离线仿真获得大量样本进行训练,在线应用时能进行快速的稳定评估^[7]。在深度学习算法的发展还未成熟时,支持向量机(support vector machine, SVM)^[8]、人工神经网络^[9-10]、决策树^[11-12]等浅层模型应用于TSA中,但浅层模型对数据的挖掘能力有限,出现了泛化能力较差、评估准确率较低等问题。深度置信网络^[13]、堆叠自动编码器^[14-15]、卷积神经网络^[16]、门控循环单元^[17]等深度学习模型相较于浅层模型具有更强的特征提取能力,在TSA方面有更好的表现。上述深度学习模型大多采用的是监督

学习方法,在训练时需要大量的有标签样本,否则会出现模型过拟合的现象,给模型的准确率造成影响。

电力系统在绝大多数情况下处于正常运行状态,难以从历史数据库中获取TSA的有标签样本。现有方法主要通过暂态稳定时域仿真的方式批量生成有标签样本数据,而这需要准确的模型且会耗费大量的时间进行仿真计算。为此,文献[18]提出基于深度置信网络的TSA方法,使用大量的无标签样本对网络进行无监督学习,提高了模型在小样本情况下的准确率;文献[19]采用堆叠自动编码器,利用无标签样本实现了对数据的降维处理,在小样本情况下同样有较好的表现;文献[20]采用主动学习的方法来降低样本标注的代价,提升了训练效率,但是主动学习样本的标注需要人工干预且所选取的分类模型为浅层模型,准确率较低。半监督学习是监督学习与无监督学习相结合的一种学习方法,能够在有标签样本较少的情况下利用无标签样本进行训练,相较于监督学习与无监督学习对有标签训练样本数的要求更低,因此,本文基于半监督学习中的三体训练(Tri-training)算法对暂态稳定进行评估。

基于上述分析,本文提出基于三体训练-稀疏堆叠自动编码器(Tri-training-stacked sparse auto-encoder, Tri-training-SSAE)半监督学习算法的TSA方法,在安全域视角下,判定系统在发生预想故障时是否发生暂态失稳,指导系统进行安全预防控制。首先,将故障前的稳态潮流量作为原始特征,构建基于堆叠稀疏自动编码器(stacked sparse auto-encoder, SSAE)的分类模型以判别系统暂态稳定情况;然后,以SSAE模型为子模型,通过Tri-training半监督学习算法生成大量的伪标签样本,并利用这些样本进行

收稿日期:2022-06-01;修回日期:2022-11-01

在线出版日期:2022-12-13

基金项目:国家自然科学基金资助项目(U1966205)

Project supported by the National Natural Science Foundation of China(U1966205)

模型训练;最后,集成输出子模型的TSA结果。IEEE 10机39节点系统与华东某省级电网算例结果验证了本文所提方法在有标签样本不足的情况下具有较高的TSA准确率。

1 算法原理介绍

1.1 基于机器学习的TSA原理

从机器学习的角度而言,电力系统的TSA实际是一个二分类问题,通过对大量样本的学习建立输入特征与稳定类别之间的映射关系。给定样本 $(\mathbf{x}_i, y_i)$ ($i=1, 2, \dots, n$),其中:输入特征 $\mathbf{x}_i \in \mathbf{R}^m$ 由电力系统的量测装置测得, m 为实数域维数; $y_i \in \{0, 1\}$ 表示暂态稳定类别,标签1表示暂态稳定,标签0表示暂态失稳; n 为样本数。

系统的暂态稳定情况根据式(1)所示的暂态稳定指标(transient stability index, TSI)进行判定。

$$I_{\text{TSI}} = \frac{360 - |\Delta\delta_{\max}|}{360 + |\Delta\delta_{\max}|} \quad (1)$$

式中: I_{TSI} 为TSI; $\Delta\delta_{\max}$ 为任意2台发电机功角差的最大值。对于每个样本:如果 I_{TSI} 值为正,则系统稳定;如果 I_{TSI} 值为负,则系统失稳。

1.2 SSAE算法原理

自动编码器是一种输入和输出相同的无监督神经网络,其结构如附录A图A1所示,由编码器与解码器构成,自动编码器通过编码和解码最小化输入向量 $\mathbf{X}$ 与输出向量 $\hat{\mathbf{X}}$ 间的重构误差 $J(\mathbf{X}, \hat{\mathbf{X}})$,将隐藏层向量 $\mathbf{H}$ 作为降维后的特征。

自动编码器的节点之间采用全连接的方式,通过式(2)将输入向量 $\mathbf{X}$ 转化为隐藏层向量 $\mathbf{H}$,再通过式(3)将隐藏层向量 $\mathbf{H}$ 还原为 $\hat{\mathbf{X}}$,重构输入向量。

$$\mathbf{H} = f(\mathbf{W}\mathbf{X} + \mathbf{b}) \quad (2)$$

$$\hat{\mathbf{X}} = g(\tilde{\mathbf{W}}\mathbf{H} + \tilde{\mathbf{b}}) \quad (3)$$

式中: $\mathbf{W}$ 、 $\tilde{\mathbf{W}}$ 分别为编码层、解码层的权值矩阵; $\mathbf{b}$ 、 $\tilde{\mathbf{b}}$ 为偏置向量; $f(\cdot)$ 、 $g(\cdot)$ 为Sigmoid激活函数。

稀疏自动编码器在自动编码器的基础上加入稀疏约束项,抑制隐藏层神经元的激活程度,防止过拟合,提高泛化能力。本文采用库尔贝克-莱布勒(Kullback-Leibler, KL)散度作为惩罚项,即:

$$D_{\text{KL}}(\rho // \hat{\rho}_j) = \rho \ln \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \ln \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (4)$$

式中: $D_{\text{KL}}(\cdot)$ 为KL散度; ρ 为稀疏正则化参数; $\hat{\rho}_j$ 为隐藏层第 j 个神经元的平均激活程度。当 $\hat{\rho}_j = \rho$ 时, $D_{\text{KL}}(\rho // \hat{\rho}_j) = 0$;当 $\hat{\rho}_j$ 偏离 ρ 时, $D_{\text{KL}}(\rho // \hat{\rho}_j)$ 的值增大。损失函数中加入稀疏项的约束,可以使 $\hat{\rho}_j$ 接近趋近于0的常数 ρ ,从而抑制神经元的激活程度^[14]。

因此,稀疏自动编码器的训练目标是通过调整

式(2)与式(3)中的网络参数使式(5)所示的损失函数 $J_{\text{SAE}}(\cdot)$ 最小化,从而使输入与输出接近。

$$J_{\text{SAE}}(\boldsymbol{\theta}) = J(\mathbf{X}, \hat{\mathbf{X}}) + \alpha \sum_{j=1}^l D_{\text{KL}}(\rho // \hat{\rho}_j) \quad (5)$$

式中: $\boldsymbol{\theta} = [\mathbf{W}, \tilde{\mathbf{W}}, \mathbf{b}, \tilde{\mathbf{b}}]$ 为网络参数;重构误差 $J(\mathbf{X}, \hat{\mathbf{X}})$ 采用平方误差函数 $\frac{1}{2n} \sum_{i=1}^n \|\hat{\mathbf{x}}_i - \mathbf{x}_i\|_2^2$, $\hat{\mathbf{x}}_i$ 为重构数据; α 为稀疏惩罚项的权重; l 为隐藏层神经元数。

SSAE结构图如附录A图A2所示,SSAE是将多个稀疏自动编码器进行级联,并由编码器与softmax分类器组合而成的有更强拟合高维非线性函数能力的深度网络模型。SSAE通过编码器网络完成输入量测数据的特征提取后将其连接到softmax分类层,输出在该量测对应工况下系统的暂态稳定性辨识。

softmax分类层能输出样本所属类别的概率,假设分类问题包含 k 个类别,softmax分类层的输出函数 $h_{\theta}(\cdot)$ 为:

$$h_{\theta}(\mathbf{x}_i) = \begin{bmatrix} P(y_i=1 | \mathbf{x}_i, \boldsymbol{\theta}) \\ P(y_i=2 | \mathbf{x}_i, \boldsymbol{\theta}) \\ \vdots \\ P(y_i=k | \mathbf{x}_i, \boldsymbol{\theta}) \end{bmatrix} = \frac{1}{\sum_{j=1}^k e^{\theta_j^T \mathbf{x}_i}} \begin{bmatrix} e^{\theta_1^T \mathbf{x}_i} \\ e^{\theta_2^T \mathbf{x}_i} \\ \vdots \\ e^{\theta_k^T \mathbf{x}_i} \end{bmatrix} \quad (6)$$

式中: $P(y_i=j | \mathbf{x}_i, \boldsymbol{\theta})$ ($j=1, 2, \dots, k$)为在网络参数 $\boldsymbol{\theta}$ 下softmax分类层将样本 $\mathbf{x}_i$ 归为类别 j 的概率,其中概率最大的类别可认为是该样本从属的类别,即为该样本的标签; θ_j 为第 j 个输出类别的权重。

SSAE的训练由2个阶段组成:第1阶段为无监督预训练,通过对无标签样本的学习将预处理后的电力系统中的量测数据进行重构,得到输入特征的降维表达;第2阶段对网络参数微调,输入有标签样本进行训练,通过反向传播法更新整个评估模型的参数,在微调过程中,训练的目标是最小化模型分类结果与样本真实类别间的误差,对于仅含2种类别的电力系统TSA问题,采用如式(7)所示的交叉熵函数 $L_{\text{SSAE}}(\cdot)$ 作为误差函数。

$$L_{\text{SSAE}}(\boldsymbol{\theta}) = -\frac{1}{n} \sum_{i=1}^n \left[y_i \ln p_i + (1 - y_i) \ln (1 - p_i) \right] = -\frac{1}{n} \sum_{i=1}^n \left[y_i \ln \frac{e^{\theta_1^T \mathbf{x}_i}}{\sum_{j=1}^2 e^{\theta_j^T \mathbf{x}_i}} + (1 - y_i) \ln \frac{e^{\theta_2^T \mathbf{x}_i}}{\sum_{j=1}^2 e^{\theta_j^T \mathbf{x}_i}} \right] \quad (7)$$

式中: p_i 为样本 $\mathbf{x}_i$ 为稳定的概率,由式(6)输出,第1类别为稳定,第2类别为失稳。

1.3 Tri-training-SSAE半监督学习算法原理

基于分歧的方法是半监督学习算法的一个重要分支,协同训练算法是这类方法中的一种重要代表方法。在标准协同训练算法中,数据样本必须能由

2个完全独立的特征子集进行描述,并且每个特征子集必须能够代表数据样本的特征分布,但在电力系统的TSA问题中,若仅选取1类数据(如仅选取电压幅值或线路有功功率)作为输入特征,则此时的输入特征不能代表样本数据的特征分布,训练出的模型性能很差,且不是完全独立的。文献[21]对标准协同训练算法进行改进,提出Tri-training法,该算法综合半监督训练与集成学习的思想,在提升模型性能的同时,对数据集没有严格的要求,也无需使用不同类型的模型,能更好地应用于电力系统TSA问题中^[22]。因此,本文采用Tri-training半监督学习算法,算法流程如附录B图B1所示。

假设通过仿真生成或历史数据库得到初始少量暂态稳定有标签样本集 $L=\{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_n, y_n)\}$,利用bootstrap重复抽样法获得3个训练子集 $L_1 \sim L_3$,用训练子集分别训练3个具有差异的网络,得到3个不同的分类器 $H_1 \sim H_3$ 。

假设暂态稳定与否未知的无标签样本集为 U ,若 H_2 和 H_3 对无标签样本 $\mathbf{x}_i$ 的TSA结果 $H_2(\mathbf{x}_i)$ 和 $H_3(\mathbf{x}_i)$ 一致,则可以将样本 $\mathbf{x}_i$ 标记上伪标签并生成伪标签样本,将伪标签样本集 S_1 加入 H_1 的训练集形成 H_1 的新训练集 L'_1 ,如式(8)所示。

$$L'_1 = L_1 \cup S_1 = L_1 \cup \{\mathbf{x}_i | \mathbf{x}_i \in U, H_2(\mathbf{x}_i) = H_3(\mathbf{x}_i)\} \quad (8)$$

同理,将 H_2 和 H_3 的训练集分别扩充为 L'_2 和 L'_3 ,再对3个分类器重新进行训练,重复迭代,直至分类器 $H_1 \sim H_3$ 均没有变化或迭代次数达到设定值,完成训练。

显然,在伪标签样本生成的过程中,如果 H_2 和 H_3 同时对 $\mathbf{x}_i$ 分类错误,则会贴上错误的标签,可通过在 H_1 的训练集中引入噪声影响训练结果。文献[21]证明,引入噪声所带来的负面影响可以被大量未标记样本正确标记所带来的正面影响抵消,即在一定条件下累积的标记噪声可以通过大量未标记数据进行补偿。为了进一步提升伪标签样本的质量,本文在生成伪标签样本时加入置信度阈值判断,提高伪标签样本的置信度,进一步减少噪声的引入。对于只有稳定与失稳2个类别的电力系统TSA问题,引入置信度指标 R ,如式(9)所示。

$$R = \max \{P(y_i = 0 | \mathbf{x}_i), P(y_i = 1 | \mathbf{x}_i)\} \quad (9)$$

R 可由softmax分类层输出的所属类别概率向量确定,其取值范围为 $[0.5, 1]$ 。

只有当2个分类器对同一个无标签样本分类一致且 R 均大于设定阈值 ε 时,才能将该无标签样本贴上伪标签并添加到扩充样本池中进行训练,否则将该样本视为噪声,且不加入样本池中进行训练。

Tri-training算法的分类器模型除采用浅层学习

模型外,还可以采用深度学习模型^[23],其中SSAE可以更好地提取电力系统数据中的潜在信息,提高分类的准确率,因此,本文采用SSAE作为基分类器,提出一种Tri-training-SSAE模型。

2 基于Tri-training-SSAE的TSA

2.1 TSA模型的输入与输出

基于数据挖掘的TSA一般有2种思路:①稳定域概念下,以故障前、故障过程中及故障后的系统变量为原始特征,在发生故障后判断是否会发生暂态失稳;②安全域概念下,当故障地点、位置及持续时间确定时,以故障前稳态的潮流数据为原始特征,预判该工况下发生预想事故时的暂态稳定情况^[7]。稳定域概念下的TSA不受故障性质的限制,多用于故障后的控制策略研究,在发生故障后才进行评估,一旦判断为失稳,就需立即进行紧急控制,代价较大。而安全域概念下的TSA利用故障前的系统潮流数据来评估在该工况下若发生预想事故是否会出现暂态失稳,能够提前进行预防控制。因此,本文建立安全域概念下的TSA模型,建立给定故障下故障前的系统潮流分布与故障后的系统稳定状态之间的映射关系,判断在预想事故集下不同运行方式的暂态稳定性,而输入特征的选取对模型评估性能影响很大。文献[24]证明,母线电压相量能快速准确地表征电力系统的动态变化,非常适用于TSA问题。因此,本文将易于测量的故障前节点电压相角 ϕ 与电压幅值 V 以及节点的有功功率 P 和无功功率 Q 作为原始特征 $X=[V, \phi, P, Q]^T$ 。配置的相量测量单元等量测装置能够直接测得上述电气量,本文将原始量测数据进行归一化处理后作为模型的输入特征。

2.2 TSA流程

基于Tri-training-SSAE的TSA流程如附录B图B2所示,具体步骤如下。

1)获取原始数据集。在仿真软件中搭建测试算例系统模型,通过暂态稳定域仿真获取有标签样本集 L ,通过潮流计算获取无标签样本集 U 。

2)数据预处理。对底层的量测数据进行归一化处理,以提升模型的收敛速度与精度。

3)样本划分。根据设定的比例将有标签样本集随机划分为训练集和测试集。

4)SSAE基分类器初始训练。SSAE基分类器的训练分为预训练与微调:首先,使用部分无标签样本对SSAE进行无监督预训练,完成特征提取;然后,对有标签样本重复采样3次,得到3个有标签样本子集,对3个分类器进行有监督的参数微调,完成分类器的初始训练。

5)Tri-training半监督训练。利用无标签样本集产生伪标签样本,用新的有标签样本集对3个分类器

重新进行参数微调训练,直至迭代次数达到设定值。

6)模型评估。使用训练完成的模型对测试集数据进行性能测试,根据评估指标评估模型的性能。

7)在线应用。所有训练均为离线训练,在线应用时,将预处理后的实时量测数据输入训练好的基于Tri-training-SSAE的TSA模型中,即可得到在该工况下对应故障的TSA结果。

2.3 TSA 指标

TSA中存在样本数不平衡现象,可能导致评估出现偏向性,因此,需分析评估结果中误判与漏判的情况,以测试集样本的分类准确率 P_{ac} 、安全度 P_{as} 和可靠度 P_{au} 来衡量模型分类效果^[13],各指标定义如下。

1)准确率 P_{ac} 表示正确预测的样本数占样本总数的比例,即:

$$P_{ac} = (T_s + T_u) / (T_s + T_u + F_s + F_u) \quad (10)$$

2)安全度 P_{as} 表示正确判断为稳定的样本数占稳定样本总数的比例,即:

$$P_{as} = T_s / (T_s + F_u) \quad (11)$$

3)可靠度 P_{au} 表示正确判断为失稳的样本数占失稳样本总数的比例,即:

$$P_{au} = T_u / (T_u + F_s) \quad (12)$$

式中: T_s 、 T_u 分别为稳定、失稳样本评估正确的样本数; F_s 、 F_u 分别为稳定、失稳样本评估错误的样本数。

3 算例分析

3.1 IEEE 10机39节点系统算例

3.1.1 数据集生成与样本划分

本文选取IEEE 10机39节点系统作为测试算例,对算法的性能进行测试验证,系统接线图如附录C图C1所示。设置负荷波动范围为0.8~1.2 p.u.,在潮流等约束限制内随机设置机组出力,生成不同的运行工况;设置线路4-14为故障发生线路,故障类型为三相接地短路故障,故障位置位于线路全长的50%处,持续时间为0.2 s,仿真时长为5 s。利用电力系统分析综合程序(power system analysis software package, PSASP)进行暂态稳定仿真,生成5 000个有标签样本并且将其组成有标签样本集,其中包含3 127个稳定样本和1 873个失稳样本,将有标签样本按照3 500:1 500随机划分为训练集与测试集。通过稳态潮流计算获取5 000个随机工况下的潮流值,并将其组成无标签样本集。

3.1.2 不同暂态评估模型的性能比较

对于SSAE模型,需要确定模型结构参数、稀疏参数等。为了保证3个子分类器的差异性,3个SSAE模型均采用不同的结构与参数,预训练次数与微调次数均分别为100和200,通过逐次调试后选取表现性能较好的参数作为测试模型的参数,具体参数设置如附录D表D1所示。

在无监督预训练阶段均从5 000个无标签样本中随机抽取3 000个样本进行无监督训练,随机采样的差异性保证了3个SSAE网络初始参数的差异性。

为了体现本文算法的优越性,将SVM模型、深度神经网络(deep neural network, DNN)模型、SSAE模型和Tri-training-DNN模型作为对比模型来验证所提算法的性能。SVM模型采用径向基核函数,惩罚系数 $C=200$,核参数 $\gamma=0.01$;DNN模型采用与3个SSAE模型相同的结构参数,激活函数选取ReLU函数,采用Adam算法进行优化,学习率为0.001,监督训练迭代次数均设置为100,设置dropout参数为0.5,以防止模型出现过拟合。

本文从3 500个有标签样本中分别重复采样200、500、1 000、1 500、2 000、2 500、3 000、3 500个样本作为监督训练的样本,利用5 000个未标记样本进行Tri-training半监督训练,生成伪标签样本,置信度阈值 ε 取值为0.70,最大迭代次数设定为20。各模型的评估结果如图1所示,图中DNN和SSAE分别表示未经三体训练的子模型中表现最优的DNN和




图1 不同模型的评估指标对比
Fig.1 Comparison of assessment indexes among different models

SSAE子模型,后同。由图可以看出:参与训练的有标签样本数对模型的训练结果具有重要影响,当样本数较小时,直接将高维数据输入模型容易导致模型出现梯度爆炸现象,从而影响模型的评估精度;对比SVM模型、DNN模型与SSAE模型的评估结果可知,当参与有监督训练的有标签样本数相同时,浅层学习模型SVM很难学习到数据的特征,评估的准确率最低,容易出现误判、漏判的现象,SSAE模型通过无监督预训练对原始的输入特征进行压缩,在参与训练的有标签样本数相同时,比DNN模型能更好地学习到输入特征所隐含的信息,具有最优的模型评估性能;相较于Tri-training-DNN模型,本文模型各方面的表现均更优。因此,将SSAE作为子分类器对算法的评估性能有更大的提升。

此外,当参与训练的有标签样本较少时,引入Tri-training半监督学习算法能明显提升模型的评估性能:在仅有200个有标签训练样本时,相较于SSAE模型,本文模型的准确率提升了9.32%,其各评估指标的表现接近于1500个有标签样本参与训练的SSAE模型;当有标签训练样本数达到3500时,本文模型的评估准确率达到98.62%。因此,Tri-training半监督学习算法能通过对大量未标记样本的利用生成伪标签样本,使伪标签样本参与模型训练,有效提高了模型在少量有标签样本情况下的分类性能,能较好地解决TSA中有标签样本较少的问题。

3.1.3 伪标签样本置信度阈值对模型性能的影响

在伪标签样本生成的过程中,置信度阈值 ε 取值的不同会使所产生伪标签样本的数量和质量发生相应变化,这会给本文模型性能带来影响。在Tri-training训练过程中, ε 在区间[0.55,0.90]中以0.05间隔均匀采样,参与监督训练的有标签样本数为500,模型评估结果如表1所示。

表1 不同置信度阈值下的评估结果

Table 1 Assessment results under different confidence thresholds

ε	$P_{ac} / \%$	$P_{as} / \%$	$P_{au} / \%$
0.55	90.79	91.82	90.14
0.60	91.85	92.39	90.83
0.65	92.37	93.24	91.39
0.70	92.98	93.61	92.48
0.75	92.21	93.11	91.29
0.80	91.64	92.57	90.42
0.85	91.33	91.79	90.78
0.90	91.27	91.72	90.53

由表1可知:当 ε 在[0.55,0.70]中变化时,模型的评估性能随着 ε 的增大而提高,伪标签样本质量也随之提高,加入噪声的样本数减少;而当 ε 在[0.70,0.90]中变化时,模型的评估性能基本随着 ε 的增大而降低,这是因为当 ε 过高时,产生的伪标签样本数

减少,参与训练的样本数也变少,从而使模型的泛化能力降低。因此, ε 在[0.65,0.75]中取值时能提高伪标签样本质量,提升Tri-training模型的评估能力。

3.1.4 无标签训练样本数对模型性能的影响

将参与监督训练的有标签样本数固定为200,设定 ε 为0.70,迭代次数最大值为20,分别从无标签样本集中抽取1000、2000、 $\dots$ 、5000个样本进行Tri-training训练,比较参与训练的无标签样本数不同对网络性能的影响,不同无标签样本数下的评估结果如表2所示。

表2 不同无标签样本数下的评估结果

Table 2 Assessment results under different numbers of unlabeled samples

无标签样本数	$P_{ac} / \%$	$P_{as} / \%$	$P_{au} / \%$
1000	85.39	86.37	84.10
2000	87.72	88.45	87.14
3000	90.87	91.30	90.18
4000	91.52	91.87	91.26
5000	92.15	92.42	91.19

由表2可知,在有标签样本较少的情况下,随着参与Tri-training训练的无标签样本数的增加,大量伪标签样本加入训练,得到的模型使系统暂态稳定性的评估性能明显提高,模型的泛化能力表现更优。

3.2 华东某省级电网算例

为了进一步验证本文算法的实用性,对华东某省级电网进行测试分析。测试系统包括1251条母线、2005条输电线路、235台变压器与125台发电机组,部分节点配置量测装置,以量测值作为原始特征。利用PSD-BPA软件进行仿真,设置三相接地短路故障发生于某500 kV电压等级输电线路全长的25%处,故障持续时间为0.1 s,以夏季高峰工况为基础进行负荷波动,生成6000个有标签样本,并通过潮流计算快速生成10000个无标签样本。

将本文模型与SVM、SSAE模型进行测试对比,模型参数如附录D表D2所示。设定 ε 为0.70,Tri-training迭代次数最大值为20。随机抽取2000个有标签样本组成测试集,其余样本组成训练集。表3给出了不同有标签训练样本数下各模型的评估准确率。各模型的其余评估指标如附录D表D3所示。

表3 华东某省级电网算例评估准确率

Table 3 Assessment accuracy rate of a provincial power grid in East China

有标签样本数	$P_{ac} / \%$		
	Tri-training-SSAE	SSAE	SVM
500	91.62	84.10	78.39
1000	95.14	90.71	83.82
2000	96.83	93.42	87.94
3000	98.15	95.49	91.09
4000	98.72	96.53	93.26

由表3可知:在有标签训练样本数相同的情况下,本文模型均有最优表现,模型性能随着有标签样本数的增加而提升,当有标签样本数达到4000时,准确率达到98.72%;在有标签样本数为500时,SVM模型的准确率仅为78.39%,很难对系统暂态稳定与否进行正确的判断,相较于SSAE模型与SVM模型,本文模型的准确率分别提升7.52%、13.23%。因此,即使在大规模电网的情况下,本文模型也能提升少量有标签样本参与训练的TSA能力。

当TSA模型离线训练好后进行在线应用时,将预处理后的量测数据输入评估模型即可快速、准确地完成该工况下的TSA。若在预想事故下该运行工况的系统被判定为暂态失稳,则可立刻进行安全预防控制。本文的测试环境为个人计算机,配置为Inter(R) Core(TM) i5-11300H CPU @ 3.20 GHz, 16 GB内存,单个样本的评估时间仅需1.19 ms,满足在线应用实时性的要求。

4 结论

本文针对实际电网中暂态稳定的有标签样本较少的问题,提出一种基于Tri-training-SSAE半监督学习算法的电力系统TSA方法,并以IEEE 10机39节点系统与华东某省级电网为算例进行仿真验证。结果表明:

1)与传统的监督学习算法相比,基于SSAE的无监督学习能够更有效地利用大量无标签样本,将SSAE作为半监督Tri-training的子分类器有更高的评估准确性;

2)利用Tri-training半监督学习算法生成伪标签样本并使这些样本参与训练,提高了模型的泛化能力,有效地解决了TSA中有标签样本较少的问题;

3)在传统Tri-training算法伪标签样本生成过程中的投票机制上加入置信度阈值的判断,减少了噪声样本的加入,提高了伪标签样本的质量。

本文将半监督学习算法应用于电力系统的TSA问题中,所提算法能在大规模电网中快速、准确地进行安全域下的TSA,对电力系统暂态失稳进行预防控制。如何应对系统拓扑实时变换的问题,提高模型自适应性将是笔者后续研究的重点。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 易俊,卜广全,郭强,等.巴西“3·21”大停电事故分析及对中国电网的启示[J]. 电力系统自动化,2019,43(2):1-6.
YI Jun, BU Guangquan, GUO Qiang, et al. Analysis on blackout in Brazilian Power Grid on March 21, 2018 and its enlightenment to power grid in China[J]. Automation of Electric Power Systems, 2019, 43(2): 1-6.
- [2] 臧海洋,郭镜玮,黄蔓云,等.基于改进Wasserstein生成式对抗网络的电力系统不良数据辨识[J]. 电力自动化设备,2022,42

(9):50-56,110.

ZANG Haixiang, GUO Jingwei, HUANG Manyun, et al. Bad data identification of power system based on WGAN-GP[J]. Electric Power Automation Equipment, 2022, 42(9): 50-56, 110.

- [3] XUE Y, VAN CUTSEM T, RIBBENS-PAVELLA M. A simple direct method for fast transient stability assessment of large power systems[J]. IEEE Transactions on Power Systems, 1988, 3(2): 400-412.
- [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, 4577.
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, 4577.
- [5] 吴红斌,丁明.用于电力系统暂态稳定仿真的可变步长牛顿法[J]. 中国电机工程学报,2010,30(7):36-41.
WU Hongbin, DING Ming. Newton method with variable step size for power system transient stability simulation[J]. Proceedings of the CSEE, 2010, 30(7): 36-41.
- [6] VU T L, TURITSYN K. Lyapunov functions family approach to transient stability assessment[J]. IEEE Transactions on Power Systems, 2016, 31(2): 1269-1277.
- [7] 鞠平,周孝信,陈维江,等.“智能电网+”研究综述[J]. 电力自动化设备,2018,38(5):2-11.
JU Ping, ZHOU Xiaoxin, CHEN Weijiang, et al. “Smart Grid Plus” research overview[J]. Electric Power Automation Equipment, 2018, 38(5): 2-11.
- [8] 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.
- [9] KARAMI A. Power system transient stability margin estimation using neural networks[J]. International Journal of Electrical Power & Energy Systems, 2011, 33(4): 983-991.
- [10] 姚德全,贾宏杰,赵帅.基于复合神经网络的电力系统暂态稳定评估和裕度预测[J]. 电力系统自动化,2013,37(20):41-46.
YAO Dequan, JIA Hongjie, ZHAO Shuai. Power system transient stability assessment and stability margin prediction based on compound neural network[J]. Automation of Electric Power Systems, 2013, 37(20): 41-46.
- [11] 孙宏斌,王康,张伯明,等.采用线性决策树的暂态稳定规则提取[J]. 中国电机工程学报,2011,31(34):61-67.
SUN Hongbin, WANG Kang, ZHANG Boming, et al. Rule extraction in transient stability study using linear decision trees[J]. Proceedings of the CSEE, 2011, 31(34): 61-67.
- [12] RAHMATIAN M. Transient stability assessment via decision trees and multivariate adaptive regression splines[J]. Electric Power Systems Research, 2017, 142: 320-328.
- [13] 李宝琴,吴俊勇,邵美阳,等.基于集成深度置信网络的精细化电力系统暂态稳定评估[J]. 电力系统自动化,2020,44(6): 17-26.
LI Baoqin, WU Junyong, SHAO Meiyang, et al. Refined transient stability evaluation for power system based on ensemble deep belief network[J]. Automation of Electric Power Systems, 2020, 44(6): 17-26.
- [14] 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.
- [15] 林楠,王怀远,陈启凡. 基于后验分布信息的SSAE暂态稳定评估模型倾向性修正方法[J]. 电力自动化设备, 2022, 42(3): 135-141.
LIN Nan, WANG Huaiyuan, CHEN Qifan. Tendency correction method of SSAE transient stability assessment model based on posterior distribution information[J]. Electric Power Automation Equipment, 2022, 42(3): 135-141.
- [16] 高昆仑,杨帅,刘思言,等. 基于一维卷积神经网络的电力系统暂态稳定评估[J]. 电力系统自动化, 2019, 43(12): 18-26.
GAO Kunlun, YANG Shuai, LIU Siyan, et al. Transient stability assessment for power system based on one-dimensional convolutional neural network[J]. Automation of Electric Power Systems, 2019, 43(12): 18-26.
- [17] 孙黎霞,彭嘉杰,田屹昀,等. 基于混合门控循环单元子层的多任务暂态稳定评估[J]. 电力建设, 2022, 43(2): 63-69.
SUN Lixia, PENG Jiajie, TIAN Yiyun, et al. Multi-task transient stability assessment based on sub-layer of hybrid gated recurrent unit[J]. Electric Power Construction, 2022, 43(2): 63-69.
- [18] 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.
- [19] 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.
YIN 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.
- [20] 卢东昊,王莉,张少凡,等. 基于聚类自适应主动学习的电力系统暂态稳定评估[J]. 电力自动化设备, 2021, 41(7): 176-181.
LU Donghao, WANG Li, ZHANG Shaofan, et al. Transient stability assessment of power system based on clustering adaptive active learning[J]. Electric Power Automation Equipment, 2021, 41(7): 176-181.
- [21] ZHOU Z H, LI M. Tri-training: exploiting unlabeled data using three classifiers[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(11): 1529-1541.
- [22] 唐滢淇,董树锋,朱承治,等. 基于Tri-Training-LASSO-BP网络的静态电压稳定裕度在线预测方法[J]. 中国电机工程学报, 2020, 40(12): 3824-3835.
TANG Yingqi, DONG Shufeng, ZHU Chengzhi, et al. Online prediction method of static voltage stability margin based on Tri-Training-LASSO-BP network[J]. Proceedings of the CSEE, 2020, 40(12): 3824-3835.
- [23] CHEN D D, WANG W, GAO W, et al. Tri-net for semi-supervised deep learning[C]//Proceedings of the Twenty-seventh International Joint Conference on Artificial Intelligence. Stockholm, Sweden: International Joint Conferences on Artificial Intelligence Organization, 2018: 2014-2020.
- [24] ZHANG R, XU Y, DONG Z 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.

作者简介:



卫志农

卫志农(1962—),男,教授,博士研究生导师,博士,主要研究方向为电力系统运行分析与控制(E-mail: wzn_nj@263.net);

李超凡(1998—),男,硕士研究生,主要研究方向为深度学习在电力系统中的应用(E-mail: hhulcf@163.com)。

(编辑 王锦秀)

Power system transient stability assessment based on Tri-training-SSAE semi supervised learning algorithm

WEI Zhinong¹, LI Chaofan¹, DING Aifei^{2,3}, SUN Guoqiang¹, HUANG Manyun¹,
ZANG Haixiang¹, FANG Xicheng⁴

(1. College of Energy and Electrical Engineering, Hohai University, Nanjing 211100, China;

2. NARI Jidian New Energy(Nanjing) Co., Ltd., Nanjing 211106, China;

3. NARI Technology Co., Ltd., Nanjing 211106, China;

4. Yangzhong Power Supply Company of State Grid Jiangsu Electric Power Co., Ltd., Zhenjiang 212200, China)

Abstract: The transient stability assessment methods based on machine learning mainly use supervised learning method, in order to solve the problem that it is difficult to obtain the labeled samples needed by supervised learning method, a power system transient stability assessment method based on Tri-training-stacked sparse auto-encoder(Tri-training-SSAE) semi supervised learning algorithm is proposed. A transient stability assessment model based on stacked sparse auto-encoder(SSAE) is constructed. The pseudo label sample confidence judgment is added to the traditional Tri-training process to reduce the impact of noise data on model training. The SSAE is taken as the base classifier, a Tri-training-SSAE model is constructed, and a large number of unlabeled samples are used to improve the generalization ability of the model. The analysis and verification are carried out through IEEE 39-bus system and a provincial power grid in East China, and the results show that the proposed method has higher assessment accuracy rate when the number of labeled samples is small.

Key words: transient stability assessment; machine learning; semi supervised learning; Tri-training algorithm; stacked sparse auto-encoder

附录 A




图 A1 自动编码器结构
Fig.A1 Structure of auto-encoder




图 A2 SSAE 结构图
Fig.A2 Structure diagram of SSAE

附录 B




图 B1 Tri-training 算法流程图
Fig.B1 Flowchart of Tri-training algorithm




图 B2 基于 Tri-training-SSAE 的 TSA 流程图
Fig.B2 Flowchart of TSA based on Tri-training-SSAE

附录 C




图 C1 IEEE 39 节点系统

Fig.C1 IEEE 39-bus system

附录 D

表 D1 IEEE 39 节点系统算例的 SSAE 模型参数

Table D1 SSAE model parameters of IEEE 39-bus system example

参数	SSAE ₁	SSAE ₂	SSAE ₃
输入层维数	156	156	156
隐层神经元	[128-64-32]	[128-64-64]	[128-64]
输出层维数	2	2	2
稀疏参数 ρ	0.001	0.005	0.001
稀疏项权重 α	0.01	0.01	0.01

表 D2 华东某省网算例的 SSAE 模型参数

Table D2 SSAE model parameters of a provincial power grid example in East China

参数	SSAE ₁	SSAE ₂	SSAE ₃
隐层神经元	[512-256-128-64]	[512-256-128-128]	[512-256-128]
稀疏参数 ρ	0.001	0.0005	0.0005
稀疏项权重 α	0.01	0.01	0.01
预训练次数		200	
微调次数		500	

表 D3 华东某省网算例评估结果

Table D3 Assessment results of a provincial power grid example in East China

有标签样本数	$P_{as}/\%$			$P_{av}/\%$		
	本文算法	SSAE	SVM	本文算法	SSAE	SVM
500	91.97	84.63	79.13	91.21	83.72	77.25
1 000	95.82	91.56	84.41	94.29	90.14	82.06
2 000	97.04	93.87	88.73	96.32	92.93	86.42
3 000	98.72	96.13	92.85	98.15	94.37	90.13
4 000	99.15	97.81	94.53	98.26	95.62	92.71