

袁梦薇, 何宇, 王旭. 基于 SVM-SMOTE 算法的一维卷积神经网络电力系统暂态稳定评估模型[J]. 智能计算机与应用, 2024, 14(7): 50-56. DOI:10.20169/j.issn.2095-2163.240707

基于 SVM-SMOTE 算法的一维卷积神经网络电力系统暂态稳定评估模型

袁梦薇, 何宇, 王旭

(贵州大学 电气工程学院, 贵阳 550025)

摘要: 为了提高电力系统运行稳定性,降低大停电事故发生的概率,本文提出了一种基于 SVM-SMOTE 算法的一维卷积神经网络暂态稳定评估模型。为了避免人工特征选择引入的主观偏差对模型预测性能的影响,本文选择来自 PMU 的底层量测数据作为输入特征,并采用一维卷积神经网络(1D-CNN)捕捉输入特征的时序信息;考虑数据集样本不平衡带来的预测精度下降问题,采用 SVM-SMOTE 算法对样本进行均衡化。算例仿真结果表明,本文所提出的模型实现了端到端的时序特征提取和暂态稳定评估,可满足在线评估准确性、快速性和可靠性的要求,且有效解决了不平衡数据集中失稳样本漏判率高的问题。

关键词: 电力系统; 暂态稳定评估; SVM-SMOTE 算法; 一维卷积神经网络

中图分类号: TM712

文献标志码: A

文章编号: 2095-2163(2024)07-0050-07

A 1D convolutional neural network-based transient stability assessment model for power systems based on the SVM-SMOTE algorithm

YUAN Mengwei, HE Yu, WANG Xu

(College of Electrical Engineering, Guizhou University, Guiyang 550025, China)

Abstract: In order to improve the operational stability of power systems and reduce the probability of major outages, this paper proposes a 1D convolutional neural network transient stability assessment model based on the SVM-SMOTE algorithm. To avoid the impact of subjective bias introduced by manual feature selection on model prediction performance, the underlying measurement data from PMU is selected as input features and a one-dimensional convolutional neural network (1D-CNN) is used to capture the time-series information of the input features. At the same time, the SVM-SMOTE algorithm is used to equalize the samples, considering the degradation of prediction accuracy due to the imbalance of samples in the data set. The simulation results of the algorithm show that the proposed model achieves end-to-end timing feature extraction and transient stability evaluation, which can meet the requirements of online evaluation accuracy, rapidity and reliability, and effectively solve the problem of high omission rate of unstable samples in unbalanced datasets.

Key words: power systems; transient stability assessment; SVM-SMOTE algorithm; one-dimensional convolutional neural net

0 引言

电力系统的暂态稳定评估对电网维持安全稳定运行具有重要意义。随着现代电力系统规模的扩大,不同区域电网间的互联关系变得复杂,导致现代电力系统呈现高维非线性的特点。因此,有效、准确、快速的暂态稳定评估是十分重要的,可提供各种

事故下电力系统稳定性分析。

传统方法中,时域仿真法(TDS)被认为是最准确与可靠的^[1]。TDS 通过数据积分方法求解系统微分代数方程组,根据系统的受扰轨迹判断系统的稳定性。然而 TDS 的计算量大、计算效率低,难以实现在线应用。直接法用 Lyapunov 理论构造能量函数分析系统的暂态稳定性,可以快速给出系统稳定程度的结

基金项目: 黔科合支撑[2022]一般 014; 黔科合支撑[2022]一般 013。

作者简介: 袁梦薇(1997-),女,硕士研究生,主要研究方向:电力系统暂态稳定评估;王旭(1996-),男,硕士研究生,主要研究方向:电力大数据的应用。

通讯作者: 何宇(1978-),女,硕士,副教授,主要研究方向:电力系统规划,电力系统稳定与运行。Email: yhe7@gzu.edu.cn

收稿日期: 2023-05-16

论,但是对于不同负载水平和故障清除时间需要进行大量的计算工作^[2-3]。时域仿真法和直接法等传统方法难以满足暂态稳定评估在线应用的需求^[4]。

随着相量测量单元(Phasor Measurement Unit, PMU)在电力系统中的广泛应用,存储了大量电力数据,为数据驱动方法的发展提供了保障^[5]。机器学习方法可以构建输入特征到暂态稳定状态的映射^[6],文献[7]提出一种基于改进支持向量机(SVM)的电力系统实时暂稳评估方法;文献[8]利用自适应集成决策树(DT)进行在线动态安全评估;文献[9]提出了一种基于XGBoost算法的暂态稳定评估方法。然而,构建效果优秀的机器学习模型依赖于专家的专业知识设计特征提取器,模型的性能也受限于特征提取后的结果。随着电力数据的增加,机器学习模型有自身的局限之处,如泛化能力差、计算速度慢等。

深度学习方法可以自动地从数据中提取特征,从而减少人为设计带来的误差。文献[10]提出基于卷积神经网络(Convolutional Neural Network, CNN)的评估方法,直接对底层量测数据提取时序特征并完成分类评估,突破了浅层学习评估模型的瓶颈;文献[11]提出了一种将CNN与连续学习算法相结合的方法,用于解决电网拓扑结构变化及数据冗余的问题;文献[12]将CNN应用于暂态稳定评估和失稳模式预测,在判断是否稳定的基础上还能进一步判断失稳的模式。

基于深度学习的预测模型在实际应用时仍然存在一些不足。由于失稳样本数量较少,存在样本数据集类别分布不均匀的问题,导致失稳样本的漏判率远高于对稳定样本的误判率,从而无法保证故障样本的分类精度,进而造成电力系统解列甚至崩溃。

针对样本不平衡问题,目前主流的解决方案主要从算法的改进和数据集的改进两个方向展开。文献[13-14]通过引入焦点损失函数来改善样本不平衡问题,但是此类方法存在一定的主观性。从数据方面进行优化的方法主要包括过采样和欠采样。文献[15]采用合成少数类过采样技术(Synthetic Minority Oversampling Technique, SMOTE)增加失稳样本数量,但是该算法存在数据分布边缘化等缺点。

综上,本文采用SVM-SMOTE算法对暂态稳定数据集进行均衡化,解决传统SMOTE过采样所存在的边界模糊的问题,提高对失稳样本的预测精度;为了避免人工特征选择引入的主观偏差对模型预测性能的影响,本文选择PMU的底层量测数据作为输

入特征,为捕捉输入特征的时序信息,提出了一种基于一维卷积神经网络(1D-CNN)的暂态稳定评估方法;最后,在新英格兰10机39节点系统中验证了所提出模型的有效性。

1 SVM-SMOTE 过采样

暂态稳定评估问题的样本集是典型的不平衡样本,若不针对样本不平衡问题加以处理,则会使模型学习到稳定样本多样的先验信息,从而导致实际预测时在稳定类别的预测上精度高、失稳样本上表现差,从而无法保证失稳样本预测的正确率,导致运行人员无法及时采取措施。为解决样本不均衡问题,本文采用SVM-SMOTE算法对暂态失稳样本进行过采样,以达到样本均衡化,提高对失稳情况的预测精度。

文献[16]指出,SVM-SMOTE算法可有效解决传统SMOTE算法在过采样时存在的数据分布边缘化及边界模糊的问题。SMOTE算法通过在训练集上的随机失稳样本与其 k 近邻之间进行随机线性插值,形成新的样本。 X_{new} 为所生成的样本,公式(1):

$$X_{new} = X_m + \lambda(X_n - X_m) \quad (1)$$

其中, X_m 为属于少数类的失稳样本; X_n 为样本 X_m 的 k 近邻样本; λ 是一个取值范围在0~1之间的随机数。

SVM在训练集上训练出SVM分类器,得到不稳定样本和稳定样本之间的边界区域,可以根据少数类支持向量周围的多数类样本的密度生成不同的插值策略,SVM-SMOTE算法流程如图1所示。

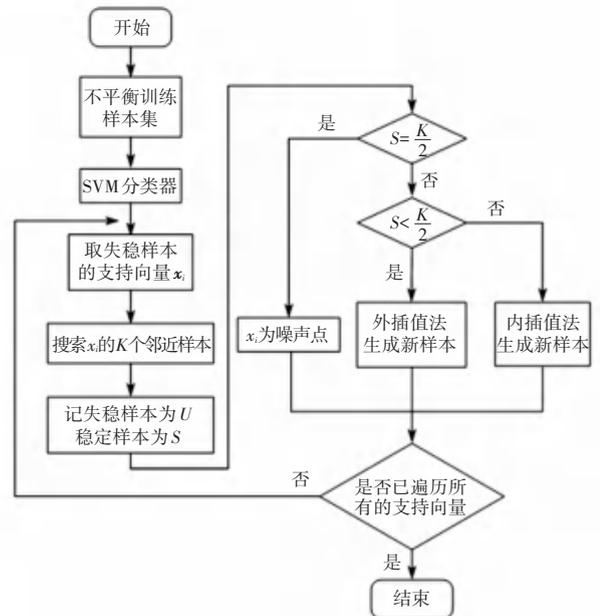


图1 SVM-SMOTE 算法流程图

Fig. 1 SVM-SMOTE algorithm flow chart

2 1D-CNN 模型

2.1 1D-CNN 模型概述

1D-CNN 模型由一维卷积层、汇聚层、全连接层交叉堆叠而成。

2.1.1 卷积层与池化层

1D-CNN 中一维卷积核的作用是对时序数据的局部特征进行提取。池化层则用于减少特征维度和参数规模,便于模型训练,通常放在卷积层之后。1D-CNN 计算过程,见式(2):

$$x^l = \text{LeakyReLU}(w^l \times x^{l-1} + b^l) \quad (2)$$

其中, x^{l-1} 为第 $l-1$ 层中的输入序列; w^l 为第 l 层中的一维卷积核; b^l 为第 l 层的偏置。

本文选用的 LeakyReLU 激活函数是一种带泄露的 ReLU 函数,可以有效解决梯度消失问题及传统 ReLU 函数所带来的死亡 ReLU 的问题。LeakyReLU 的表达式见式(3):

$$\text{LeakyReLU}(x) = \begin{cases} x & \text{if } x > 0 \\ \gamma x & \text{if } x \leq 0 \end{cases} = \max(0, x) + \gamma_{\min}(0, x) \quad (3)$$

其中, γ 是一个很小的常数,可让输入 $x < 0$ 时,也保持一个很小的梯度。

池化层通过池化 (pooling) 操作实现特征选择,在保留原有显著特征的同时缩减模型参数量。本文采用的是最大池化 (Max pooling),通过选择区域中最大值表示此区域。

2.1.2 全连接层

全连接层用于合并卷积层的输出数据。本文采用全局平均池化层 (Global Average Pooling, GAP) 替换密集的全连接层。与全连接层相比,全局平均池化层减小了模型参数量,同时可以防止过拟合,使学习到的特征鲁棒性更好。

2.1.3 BN 层

BN (Batch Normalization) 层是一种以小批量 (mini-batch) 为单位的标准化的方法,在卷积神经网络模型中加入 BN 层可以有效地增大学习率,抑制过拟合。通常将 BN 层放置于激活函数层之前,其计算过程可公式化为式(4):

$$\begin{aligned} \hat{\mu}_B &\leftarrow \frac{1}{m} \sum_{i=1}^m x_i \\ \hat{\sigma}_B^2 &\leftarrow \frac{1}{m} \sum_{i=1}^m (x_i - \mu_B)^2 \\ \hat{x}_i &\leftarrow \frac{x_i - \mu_B}{\sqrt{\hat{\sigma}_B^2 + \epsilon}} \\ \hat{y}_i &\leftarrow \gamma \hat{x}_i + \beta \end{aligned} \quad (4)$$

其中, γ 和 β 会进行自适应更新。

2.2 1D-CNN 网络结构

本文提出了一种四卷积层的电力系统暂态稳定评估模型,如图2所示。

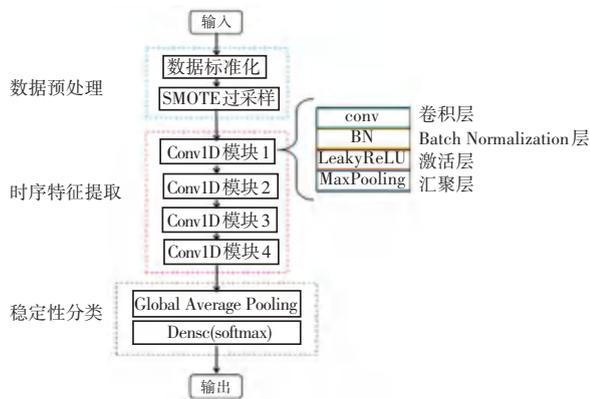


图2 本文暂态稳定评估模型的模型结构

Fig. 2 Model structure of the transient stability assessment model in this paper

单个样本的输入为一个 146 通道、50 个时间步长的时序数据,输出为失稳或者稳定的分类结果。CNN 模型由数据预处理器、时序特征提取器、稳定性分类器 3 个部分组成。数据预处理器包括去数据量纲的标准化操作与针对样本不平衡性进行处理的 SVM-SMOTE 过采样算法;时序特征提取器由 4 个卷积模块组成,每个模块包含一个卷积层、BN 层、激活层与汇聚层;最后经过全局平均池化层对所提取的特征进行全局整合,通过 softmax 分类器输出稳定或失稳的分类结果。

3 暂态稳定预测流程

3.1 模型输入与输出

3.1.1 模型输入

模型的输入特征很大程度上影响了模型的预测性能,目前主流的暂态稳定评估输入特征构建的方法有两种,一种是根据专家经验,选择在故障后能反映电力系统受扰特性的“组合特征”^[17];另一种是选择由基于同步相量测量单元 (Phasor Measurement Unit, PMU) 的电力系统广域测量系统 (Wide Area Measurement System, WAMS) 所直接采集到的测量数据^[18]。根据专家经验得到的组合特征会带有一定的主观因素,会对模型的性能表达产生影响,因此本文选择 PMU 量测数据作为输入特征。

深度学习模型从底层量测数据中自动提取和学习特征,实现了量测数据端到端的暂态稳定在线评估。使用这样的特征构建方法可以最大程度地保证

输入信息的完整性,避免人工特征所带来的主观因素对模型性能的影响。本文选择母线电压幅值、相角和输电线路的有功潮流、无功潮流作为输入特征,表达如式(5)所示:

$$\mathbf{X} = [V_1, \dots, V_m, \theta_1, \dots, \theta_m, P_1, \dots, P_n, Q_1, \dots, Q_n] \quad (5)$$

其中, $(V_m, \theta_m, P_n, Q_n) \in R^T$, m 为母线线路编号; n 为输电线路编号; T 为采样点个数。

因此所对应的输入特征 \mathbf{X} 是一个形如 $R^{T \times 2(m+n)}$ 的二维矩阵。

为了更好地反映故障后的暂态过程,时序特征应尽可能涵盖故障发生前稳态时刻、故障发生时、故障切除后 3 个阶段,由于本文仿真实验中设置的最长故障持续时间为 0.42 s,因此将样本的采样区间设置为 $[t_f - 5T, t_f + 45T]$, T 为 20 ms。本文所采用的算例系统为新英格兰 10 机 39 节点系统,含母线线路 39 条及除含变压器的输电线路 34 条,由式(5)可知,输入特征 \mathbf{X} 是一个 50×146 维的矩阵。

3.1.2 模型输出

暂态稳定评估模型的输出结果即为模型的样本标签,暂态评估问题是一个二分类问题,采用暂态稳定指数(Transient Stability Index, TSI) 判断故障发

生后的功角稳定性, TSI 公式(6):

$$TSI = \frac{360^\circ - |\Delta\delta_{\max}|}{360^\circ + |\Delta\delta_{\max}|} \quad (6)$$

其中, $\Delta\delta_{\max}$ 为仿真时长内两发电机的最大相对功角。

若 $TSI > 0$, 则说明该样本为稳定样本,标签设置为 1;若样本的 $TSI \leq 0$, 则判定为失稳样本,标签设置为 0。

3.1.3 数据预处理

由于输入特征含母线电压值、相角和输电线路的有功潮流、无功潮流,各个数据量纲不同,因此需要进行数据归一化。本文使用 Min-Max 标准化对原始数据进行线性变换,将归一化后的结果映射至 $[0, 1]$ 的区间。对于待归一化的序列 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 标准化过程如式(7)所示:

$$x' = \frac{x_i - \min_{1 \leq j \leq n} \{x_j\}}{\max_{1 \leq j \leq n} \{x_i\} - \min_{1 \leq j \leq n} \{x_i\}} \quad (7)$$

3.2 在线暂态稳定评估流程图

基于 SVM-SMOTE 的卷积神经网络暂态稳定评估模型预测过程如图 3 所示。

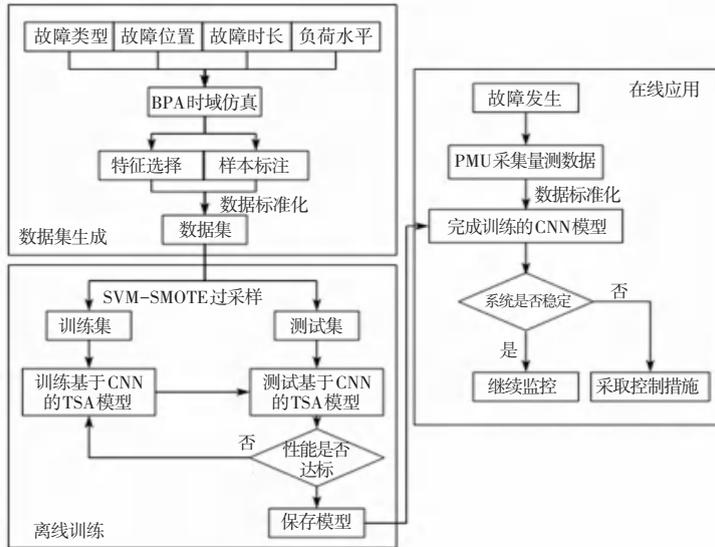


图 3 本文暂态稳定评估模型的预测过程

Fig. 3 Prediction process of the transient stability assessment model in this paper

3.2.1 数据集生成

通过时域仿真的方式在 PSD-BPA 软件中设置不同的故障信息与运行工况,得到暂态过程下的时序数据;采用暂态稳定指数作为稳定与失稳的判断

指标,为每条数据打上相应的标签;将筛选后的特征进行去量纲的标准化处理,构成训练模型所需的数据集。

3.2.2 离线训练

将数据集按照 4 : 1 的比例划分为训练集和测试集,训练集通过 SVM-SMOTE 过采样算法实现训练样本均衡化,然后与验证集的数据一起输入 CNN 模型进行训练,CNN 模型通过反向传播算法进行模型参数的寻优。模型完成训练后需要由测试集来判断输出模型是否达到应用标准,若未达到要求,则修改模型结构或超参数后继续训练。

3.2.3 在线评估

采用与离线训练相同的方式对 PMU 所采集到的量测数据进行标准化操作,然后输出到已训练好的模型之中,快速给出稳定或失稳的预测结果,操作人员可以根据模型的预测结果采取相应的措施,以最大限度减少故障可能造成的损失。

3.3 模型评价指标

电力系统暂态稳定评估问题有如下特点:

- (1) 稳定样本数量远大于不稳定样本数量;
- (2) 失稳样本误判为稳定样本(漏判)比将稳定样本误判为失稳样本(误判)对电力系统影响各异。

漏判可能使运行人员不能及时对即将失稳的电力系统采取控制措施,进而引发系统崩溃和大面积停电;误判则会导致采取过于保守的控制措施,如过早切除发电机或负荷,从而带来不必要的经济损失。因此,本文采用准确率、精准率、召回率和 $F1$ 来衡量该不平衡样本的分类效果,这 4 个指标由混淆矩阵(Confusion Matrix)计算得到。混淆矩阵基于预测标签与实际标签两种属性与稳定和失稳两种分类结果组合出了 4 种状态,见表 1。

表 1 暂态稳定评估模型的混淆矩阵

Table 1 Confusion matrix for transient stability assessment

状态	预测稳定	预测不稳定
实际稳定	T_s	F_{us}
实际不稳定	F_s	T_{us}

其中, F_{us} 为误判,表示将稳定样本误判为失稳样本; F_s 为漏判,表示将稳定样本漏判为失稳样本。

准确率 (Accuracy): 指分类结果中正确结果占总样本个数的比例,公式(8):

$$Accuracy = \frac{T_s + T_{us}}{T_s + F_{us} + T_{us} + F_s} \times 100\% \quad (8)$$

精准率 (Precision): 预测失稳样本的评估准确率,此指标数值越高,代表被误判为失稳样本的情况越少,公式(9):

$$Precision = \frac{T_{us}}{T_{us} + F_{us}} \times 100\% \quad (9)$$

召回率 (Recall): 实际失稳样本的评估准确率,此指标数值越高,代表失稳样本被漏判的现象越少,公式(10):

$$Recall = \frac{T_{us}}{T_{us} + F_s} \times 100\% \quad (10)$$

$F1$ - score: 精准率与召回率的调和平均值,用于评价模型的综合性能,公式(11):

$$F1 = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (11)$$

4 算例分析

4.1 算例参数

新英格兰 10 机 39 节点在暂态稳定分析领域中被广泛使用^[19]。代表美国新英格兰州的一个 345 kV 的电力系统,包含了 10 台发电机、39 个节点、12 个变压器与 34 条传输线路,系统的基准功率为 100 MVA,基准电压为 345 kV。

本文使用 PSD-BPA 电力系统仿真软件批量仿真生成暂态稳定评估数据集,故障具体设置如下:用负荷水平 80%、100%、120% 的变化体现运行方式的变化。由于三相故障是最为严重的故障,因此通常选用三相故障作为时域仿真实验的故障场景。在不含变压器的 34 条输电电路上分别发生永久性三相故障,故障位置分别在 10%、30%、50%、70%、90% 处,故障切除时间从 0.1 s 以 0.02 的步长增加至 0.42 s,共计 17 个不同的故障切除时间。仿真时长 10 s,采样频率 50 Hz。生成时域仿真样本数量 8 670 个,其中稳定样本 7 159 个,失稳样本 1 601 个。

4.2 模型性能比较

为验证本文所提出的基于 SVM-SMOTE 算法的一维卷积神经网络暂态稳定评估模型的优越性,将其与常用的随机森林(RF)、支持向量机(SVM)、多层感知机模型(MLP)及未改进的 CNN 模型进行对比,由于 RF、SVM 这类的机器学习模型要求输入必须是一维向量,因此将二维时序特征展开为一维特征作为机器学习模型的输入。

本文在训练阶段参数设置:一次训练所选取的样本数量设置为 128,优化算法使用 Adamax,学习率设置为 $lr = 0.01$,损失函数使用交叉熵函数,MLP 模型与 CNN 模型均进行了 100 个 epoch 的训练。

各类模型在测试集上的评估结果见表 2。

表 2 暂态稳定评估结果

Table 2 Performance metrics on TSA

模型	Precision/%	Recall/%	F1 - score	Accuracy/%	训练时长/s	预测时长/s
RF	87.040	86.470	0.868	95.390	0.170	0.010
SVM	92.810	93.730	0.933	97.640	12.430	0.280
MLP	96.070	94.520	0.953	98.330	37.550	0.250
CNN	96.400	97.360	0.969	98.900	82.160	0.280
本文模型	96.780	99.340	0.980	99.310	119.760	0.270

可以看到,本文所采用的 CNN 模型在准确率、精准率、召回率与 $F1$ 分数上表现良好,证明所提出模型的有效性。经过 SVM-SMOTE 采样算法处理后的评估结果与未经过此数据处理方法的结果相比,准确度、召回率与 $F1$ 分数都有所提升,证明了采用 SMOTE 算法优化后的训练集能有效提升 CNN 模型的性能,提高模型对失稳样本的识别准确率。由于使

用 SVM-SMOTE 过采样算法后会对数据集进行扩充,因此训练时间对比未采用过采样算法的 CNN 模型有所增加,但预测速度各模型之间并无较大差距。

为进一步验证 SVM-SMOTE 的有效性,不使用过采样、使用 SMOTE 进行过采样与采用 SVM-SMOTE 过采样方法处理数据,得到的模型在测试集上的混淆矩阵如图 4 所示。

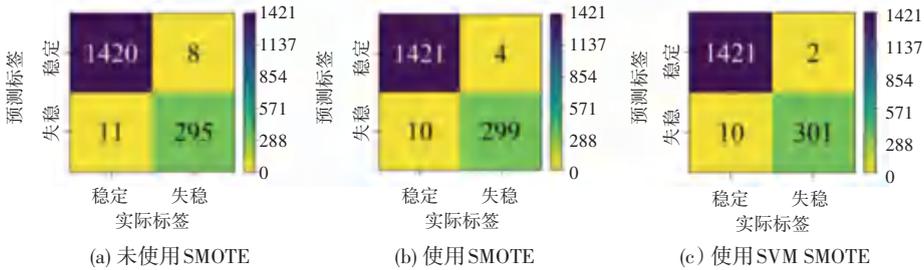


图 4 测试集混淆矩阵

Fig. 4 Confusion matrix on test set

4.3 模型鲁棒性分析

4.3.1 噪声实验

实际电力系统运行过程中所采集到的 PMU 信号必然存在噪声,本文参考文献[20]的设置方式,将此类噪声视为高斯白噪声进行模拟与分析,为了更接近在线应用时的真实情况,在 PSD-BPA 软件所生成的仿真数据中叠加一定的噪声作为 PMU 的量测值,使用信噪比(Signal-to-Noise Ratio, SNR)来衡量加入噪声的强度,见公式(12):

$$SNR = 10 \lg \frac{P_{\text{signal}}}{P_{\text{noise}}} \quad (12)$$

其中, P_{signal} 为信号功率, P_{noise} 为噪声功率。

信噪比越高,代表噪声相对于原信号的比例越低。本文在测试集中加入噪声,将信噪比设置为 10~50 dB 的区间内,步长为 10 dB。各模型在不同噪声水平下的评估结果如图 5 所示。

在不同噪声水平下,本文所提出的 CNN 模型性能都优于其他模型,在 10 dB 的强噪声水平下,对于 RF、SVM、MLP 模型的准确率则分别下降了 6.1%、7.4%、2.7%,CNN 模型的准确率指标仅下降了

0.5%,较其他模型在抗噪声水平上有一定优势;加入噪声后的 CNN 模型在精准率、召回率、 $F1$ - score 的指标上仍能保持在一个较好的水平,证明了本文所提出的 CNN 模型对于含噪声的数据具有一定的鲁棒性。

4.3.2 PMU 数据缺失实验

电力系统的实际运行中,可能会由于出现故障和干扰导致采集到的数据异常或丢失,为模拟此类情况,本文随机设置每个时间断面上一定比例的特征值为 0,数据缺失的比例分别为:5%、10%、15%。各个模型在不同数据缺失比例下的评估结果如图 6 所示。

在不同数据缺失比例下,只有 SVM 模型与 CNN 模型能保持一个较好的水平,RF、MLP 模型在 15% 数据缺失的情况下准确率分别下降了 5.99%、1.79%,而 SVM 模型与 CNN 模型仅下降了 0.75% 与 0.70%,其余指标也仅在一个很小的范围内波动,说明在 PMU 信息不完全的情况下,模型仍能保持较高的预测准确率和 $F1$ 得分,CNN 模型具有较强的鲁棒性。

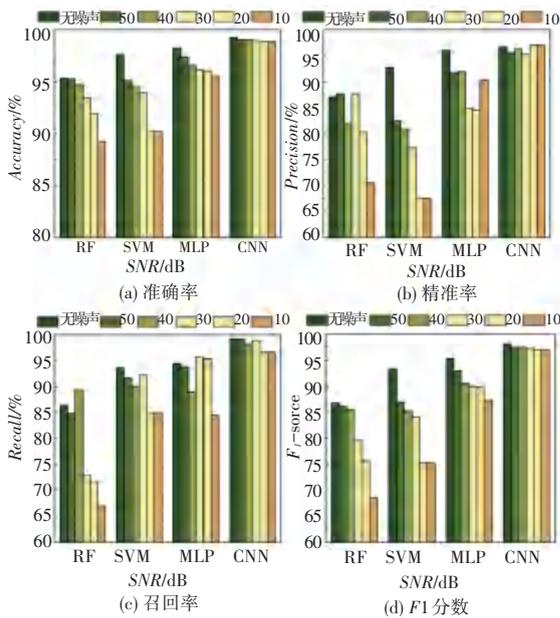


图5 不同噪声水平下的评价结果

Fig. 5 Evaluation results at different noise levels

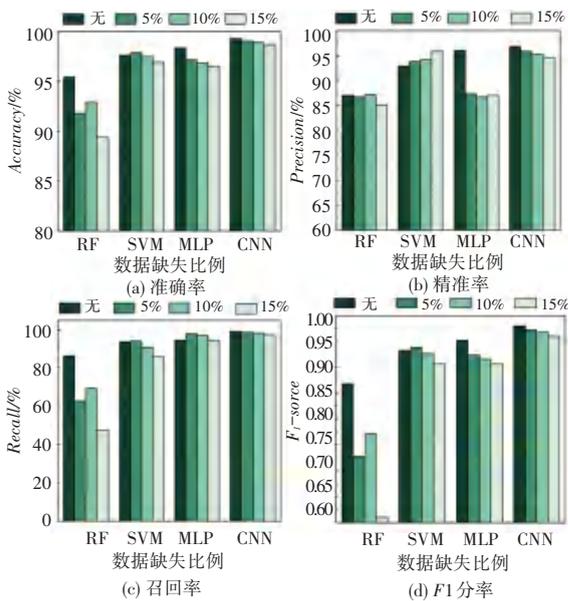


图6 不同数据缺失比例下的评价结果

Fig. 6 Evaluation results with different percentage of missing data

5 结束语

本文考虑到暂态稳定样本的不平衡性,通过SVM-SMOTE算法对原始样本进行过采样,将失稳样本与稳定样本的数量均衡化,使得模型可以更好学习失稳样本的特征。同时,采用CNN模型进行暂态稳定评估,可自动从底层量测数据中提取有效特征并进行学习,实现PMU量测数据端到端的暂态稳定在线评估。仿真算例表明,SVM-SMOTE算法有效增强了CNN模型对于失稳样本的识别能力和分类性能,有效提高了预测精度,并缓解了数据不平衡

问题对预测结果的负面影响。

参考文献

- [1] PRABHASHANKAR K, JANISCHEWSYJ W. Digital simulation of multimachine power systems for stability studies [J]. IEEE Transactions on Power Apparatus and Systems, 1968, 87(1): 73-80.
- [2] 周先哲, 刘靖, 黄雯. 电力系统暂态稳定直接法综述[J]. 中国科技信息, 2013(4): 37-38.
- [3] 傅书逊. 势能界面法 (PEBS) 暂态稳定分析的综述及展望[J]. 电力系统自动化, 1998(9): 16-18.
- [4] 颜融. 基于数据驱动的电力系统暂态稳定评估[D]. 杭州: 浙江大学, 2021.
- [5] 段刚, 严亚勤, 谢晓冬, 等. 广域相量测量技术发展现状与展望[J]. 电力系统自动化, 2015, 39(1): 73-80.
- [6] 张若愚. 基于卷积神经网络的电力系统暂态稳定评估[D]. 北京: 北京交通大学, 2020.
- [7] HU W, LU Z, WU S, et al. Real-time transient stability assessment in power system based on improved SVM[J]. Journal of Modern Power Systems and Clean Energy, 2019, 7(1): 26-37.
- [8] HE M, ZHANG J, VITTAL V. Robust online dynamic security assessment using adaptive ensemble decision-tree learning [J]. IEEE Transactions on Power Systems, 2013, 28(4): 4089-4098.
- [9] SHEN S, LIU Q, TAO X, et al. Application of the XGBoost on the assessment of transient stability of power system [M]. Atlantis Press, 2019: 6-10.
- [10] 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.
- [11] LI X, YANG Z, GUO P, et al. An intelligent transient stability assessment framework with continual learning ability [J]. IEEE Transactions on Industrial Informatics, 2021, 17(12): 8131-8141.
- [12] SHI Z, YAO W, ZENG L, et al. Convolutional neural network-based power system transient stability assessment and instability mode prediction[J]. Applied Energy, 2020, 263: 114586.
- [13] 卢锦玲, 郭鲁豫. 基于改进深度残差收缩网络的电力系统暂态稳定评估[J]. 电工技术学报, 2021, 36(11): 2233-2244.
- [14] 李保罗. 基于焦点损失轻梯度提升机的暂态稳定评估方法[D]. 吉林: 东北电力大学, 2021.
- [15] 李海英, 沈益涛, 罗雨航. 基于改进深度置信网络的智能电网暂态安全状态感知[J]. 电力系统保护与控制, 2022, 50(5): 171-177.
- [16] 张忠林, 冯宜邦, 赵中恺. 一种基于SVM的非均衡数据集过采样方法[J]. 计算机工程与应用, 2020, 56(23): 220-228.
- [17] 刘云鹏, 和家慧, 许自强, 等. 基于SVM SMOTE的电力变压器故障样本均衡化方法[J]. 高电压技术, 2020, 46(7): 2522-2529.
- [18] 赵恺, 石立宝. 基于改进一维卷积神经网络的电力系统暂态稳定评估[J]. 电网技术, 2021, 45(8): 2945-2957.
- [19] ATHAY T, PODMORE R, VIRMANI S. A practical method for the direct analysis of transient stability [J]. IEEE Transactions on Power Apparatus and Systems, 1979, 98(2): 573-584.
- [20] 任继红. 基于数据驱动的电力系统暂态稳定评估方法研究[D]. 吉林: 东北电力大学, 2021.