

考虑过采样器与分类器参数优化的变压器故障诊断策略

栗磊¹,王廷涛²,赫嘉楠¹,牛健¹,梁亚波¹,苗世洪²

(1. 国网宁夏电力有限公司 电力科学研究院,宁夏 银川 750002;
2. 华中科技大学 电气与电子工程学院,湖北 武汉 430074)

摘要:变压器故障样本的不平衡性使得故障诊断分类准确率低,且容易弱化少数类故障样本的分类效果。对此,采用过采样方法实现故障样本的均衡化,并提出一种考虑过采样器与分类器参数优化的变压器故障诊断策略。首先,搭建变压器故障诊断模型的整体结构,阐述故障诊断的实现过程。在此基础上,提出诊断模型中过采样器、分类器、参数优化器3种主要环节的算法实现:针对过采样器,提出一种基于近邻分布特性的改进合成少数过采样算法实现故障样本的均衡化;针对分类器,采用层次式有向无环图支持向量机算法实现故障样本的多标签分类;针对参数优化器,提出一种双层参数优化方法,上层采用层次搜索算法对过采样倍率寻优,下层采用改进哈里斯鹰算法对支持向量机参数寻优。最后,对所提策略进行算例分析,结果表明,所提策略能够合成质量更高的少数类故障样本,实现故障样本的准确分类。

关键词:电力变压器;故障诊断;不平衡样本;过采样;基于近邻分布特性的改进合成少数过采样;层次搜索-改进哈里斯鹰算法

中图分类号:TM 41

文献标志码:A

DOI:10.16081/j.epae.202206011

0 引言

电力变压器作为连接不同电压等级的关键设备,在电力系统的输、变、配电过程中起到不可替代的作用。因此,准确掌握变压器的健康状态,尤其是当变压器出现异常或故障后的及时诊断,对于保障电力系统的安全稳定运行具有重要意义。

电力变压器按绝缘介质可分为油浸式变压器、干式变压器和SF₆气体绝缘变压器,其中以油浸式变压器居多。针对油浸式变压器的故障,传统方法主要通过分析变压器油中溶解气体含量的比值特征进行诊断,其代表为IEC三比值法^[1]、立体图示法^[1-2]、大卫三角形法^[3-4]等。此类方法简便实用,但存在准确率较低、判据过于绝对等问题。近年来,基于人工智能算法的变压器故障诊断技术逐步发展起来。此类方法通常以变压器油中溶解气体含量等作为指标,通过大量历史故障样本来训练神经网络^[5-6]、极限学习机^[7-8]、相关向量机^[9-10]、支持向量机(support vector machine, SVM)^[11-12]等人工智能模型,使其具有识别变压器故障类型的能力。与传统方法相比,人工智能方法在诊断准确率方面有较大提升。然而,变压器故障样本通常具有类间样本数量不平衡的问题^[13],当采用人工智能方法对不平衡故障样本进行分类时,分类结果容易偏向多数类样本。

为提高人工智能方法对不平衡样本的分类性能,可以对样本进行均衡化处理,主要有欠采样和过采样2种思路。前者是通过删除部分多数类样本实现类间样本平衡,后者则是通过生成少数类样本实现。由于欠采样可能会丢失原样本集的有效信息,导致分类不准确^[14],因此目前相关研究大多采用过采样。过采样算法中应用最为广泛的是合成少数过采样技术(synthetic minority oversampling technique, SMOTE)^[15-18]算法及其改进算法,如自适应综合过采样(adaptive synthetic sampling, ADASYN)^[12,14]、SVM SMOTE^[13]、基于围绕中心点的划分聚类的SMOTE^[19]算法等。上述算法的应用使得变压器故障诊断的准确率进一步提升,但仍有可改进之处,具体有如下2个方面。

1) SMOTE算法存在一定的缺陷。首先,SMOTE算法依靠少数类样本集生成新样本,若所选样本为噪声样本,则生成样本同样属于噪声,扰乱样本集的正确分类。其次,SMOTE算法生成新样本时不考虑多数类样本的分布情况,容易加重多数类与少数类的边界重叠问题,使得类边界更加模糊。此外,SMOTE算法生成新样本时不考虑少数类样本的分布情况,若少数类样本内部分布不均匀,则经SMOTE算法过采样后不均匀程度会进一步加剧,使得少数类内部稀疏区样本不易识别。虽然现有改进算法对前两点缺陷进行了一定的改善^[20],但鲜有算法针对第三点缺陷提出改进措施。

2) 过采样倍率优化问题。过采样倍率用于衡量生成新样本的数量,若不对少数类样本进行过采样,则倍率为0,若采用过采样使少数类、多数类样本数

收稿日期:2022-03-09;修回日期:2022-05-16

在线出版日期:2022-06-12

基金项目:国网宁夏电力有限公司科技项目(5229DK20004Q)
Project supported by the Science and Technology Project of State Grid Ningxia Electric Power Co., Ltd.(5229DK20004Q)

量一致,则倍率为1。倍率越小,对原样本集改动越小,但不利于强化少数类样本的数据特征;倍率越大,少数类样本的数据特征越强,但易引入噪声。因此过采样倍率选择是一个参数优化问题^[21],而目前在变压器故障诊断领域鲜有研究考虑这一问题。

针对上述问题,本文提出一种考虑过采样器与分类器参数优化的变压器故障诊断策略。首先,针对SMOTE方法存在的缺陷,提出其改进方法——基于近邻分布特性的改进SMOTE(SMOTE based on nearest neighbor distribution, SMOTE-NND)算法,采用改进方法对变压器不平衡故障样本进行过采样;其次,选取SVM作为变压器故障诊断基准分类器,采用层次式有向无环图支持向量机(hierarchical directed acyclic graph SVM, HDAG-SVM)算法搭建变压器故障诊断的多标签分类结构;进而,提出基于层次搜索-改进 Harris 鹰(hierarchical search-modified harris hawks optimization, HS-MHMO)算法的双层参数优化方法,对过采样倍率、SVM参数进行寻优,以得到泛化能力更强的诊断模型;最后,开展案例分析,验证本文所提方法的有效性。

1 考虑过采样器与分类器参数优化的变压器故障诊断模型结构

1.1 变压器故障类型及特征量

根据标准DL/T 722—2014《变压器油中溶解气体分析和判断导则》^[1],油浸式变压器的故障类型主要有过热故障与放电故障2类,故障代码分别为T、D。过热故障可细分为低温过热、中温过热、高温过热,故障代码依次为T1、T2、T3;放电故障可细分为局部放电、低能放电、高能放电,故障代码依次为PD、D1、D2。故障样本的特征量主要有氢气(H₂)、甲烷(CH₄)、乙烷(C₂H₆)、乙烯(C₂H₄)、乙炔(C₂H₂)这5种气体的含量。本文参考该标准给出的故障类型与特征量开展变压器故障诊断研究。

1.2 变压器故障诊断模型结构

变压器故障诊断是一个六分类问题,本文将其分解为7个二分类问题,先构建7个不同的SVM二分类器,再采用HDAG-SVM算法对上述二分类器进行组合以实现故障诊断的六分类功能。本文变压器故障诊断策略分为数据预处理阶段、诊断模型训练阶段和诊断模型测试阶段,具体结构见附录A图A1。

数据预处理阶段主要包括训练样本分组、样本数据归一化和过采样3个部分,其中归一化公式为:

$$\tilde{x}_{i,j} = \frac{x_{i,j} - \min_{j=1,2,\dots,5} \{x_{i,j}\}}{\max_{j=1,2,\dots,5} \{x_{i,j}\} - \min_{j=1,2,\dots,5} \{x_{i,j}\}} \quad i=1,2,\dots,M \quad (1)$$

式中: $x_{i,j}$ 、 $\tilde{x}_{i,j}$ 分别为样本*i*第*j*个指标的实际值、归一化值;*M*为样本总量。

为使各组训练样本集内多数类样本与少数类样本的数量均衡化,需要对其中的少数类样本进行过采样。过采样后少数类的新增样本数如式(2)所示。

$$M_{os}^+ = \beta(M^- - M^+) \quad \beta \in [0, 1] \quad (2)$$

式中: M_{os}^+ 为少数类新增样本数; M^- 、 M^+ 分别为多数类、少数类样本原始数量; β 为过采样倍率。

训练阶段,需要对过采样倍率 β 及SVM参数进行优化。 β 决定过采样新增样本的数量,如果 β 过小则难以突出少数类样本的数据特征,如果 β 过大则容易引入噪声,因此需要对 β 的取值进行寻优。同样地,SVM的分类性能受其参数的影响,本文选用高斯核函数作为SVM的核函数,则待优化SVM参数为误差惩罚参数*C*和高斯核宽度 σ ^[11]。

测试阶段,将未知类别故障样本集送入已训练好的变压器故障诊断多标签分类器进行诊断,可得到故障样本的诊断结果集。

2 基于SMOTE-NND算法的变压器故障样本均衡化方法(过采样器)

由于变压器故障样本存在类间不平衡问题,需要对少数类样本进行过采样,其中最常用的方法为SMOTE方法,该方法通过线性插值的方式在2个少数类样本间生成新样本,其原理可参考文献[16]。鉴于传统SMOTE算法存在模糊类边界、易产生噪声、少数类内部不均匀等问题,本文提出一种SMOTE-NND算法,该方法综合考虑少数类样本近邻内各类样本的数量及欧氏距离,并据此分配每个少数类样本生成过采样样本的数量,方法流程图如图1所示。

SMOTE-NND算法的关键步骤如下。

1) 计算每个少数类样本在原始样本集范围内的*L*近邻,将*L*近邻内均为多数类样本的少数类样本认定为噪声。

2) 计算非噪声少数类样本的类别指标,*L*近邻内多数类样本越多,则类别指标越大,如式(3)所示。

$$R_i = \frac{m_i - \min_{j \in S} \{m_j\}}{\max_{j \in S} \{m_j\} - \min_{j \in S} \{m_j\}} \quad i \in S \quad (3)$$

式中:*S*为非噪声少数类样本集; R_i 为样本*i*的类别指标; m_i 为样本*i*的*L*近邻内多数类样本的数量。

3) 计算非噪声少数类样本在自身样本集范围内的*K*近邻,并计算距离指标,*K*近邻欧氏距离平均值越大,则距离指标越大,如式(4)所示。

$$Q_i = \frac{D_i - \min_{j \in S} \{D_j\}}{\max_{j \in S} \{D_j\} - \min_{j \in S} \{D_j\}} \quad i \in S \quad (4)$$

式中: Q_i 为样本*i*的距离指标; D_i 为样本*i*与其*K*近邻欧氏距离的平均值。

4) 依据类别指标和距离指标为非噪声少数类样




图1 SMOTE-NND算法流程图

Fig.1 Flowchart of SMOTE-NND algorithm

本分配过采样样本数量,如式(5)所示。

$$m_i^{os} = M_{os}^+ \frac{R_i + Q_i}{\sum_{i \in S} (R_i + Q_i)} \quad i \in S \quad (5)$$

式中: m_i^{os} 为分配给样本 i 的过采样样本数量。

5)将非噪声少数类样本作为过采样根样本,在 K 近邻内依据各近邻样本到根样本欧氏距离的几何概率随机选择过采样辅助样本。

6)将过采样根样本和辅助样本分别记为 $\mathbf{x}_{root}$ 、 $\mathbf{x}_{aux}$,则过采样生成的样本 $\mathbf{x}_{os}$ 如式(6)所示。

$$\mathbf{x}_{os} = \mathbf{x}_{root} + r(\mathbf{x}_{aux} - \mathbf{x}_{root}) \quad (6)$$

式中: r 为 $[0,1]$ 范围内的随机数。

由步骤1)可知,SMOTE-NND算法将 L 近邻内均为多数类样本的少数类样本认定为噪声,不对其进行过采样,可尽量避免引入新的噪声。由步骤2)、4)可知,SMOTE-NND算法使 L 近邻内多数类样本较多的非噪声少数类样本生成更多的过采样样本,从而避免类边界少数类样本被淹没,起到强化类边界的作用。由步骤3)—5)可知,SMOTE-NND算法使 K 近邻欧氏距离平均值较大的非噪声少数类样本生成更多的过采样样本,并且使 K 近邻内距离根样本更远的样本被选为辅助样本的概率更大,从而降低少数类样本内部分布的不均匀程度,提高分类器对少数类样本稀疏区的识别率。

3 基于HDAG-SVM算法的变压器故障样本多分类方法(分类器)

由于变压器属于高可靠性设备,其故障样本数量较少,因此变压器故障诊断问题属于多标签小样本分类问题。作为一种基于结构风险最小化原理的分类模型,SVM具有训练效率高、泛化能力强、不易陷入局部最优的优点,因此适用于解决变压器故障诊断问题^[11,15]。由于SVM是一种二分类模型,因此处理多标签分类问题时需要采取一定的SVM组合策略。本文采用HDAG-SVM算法对变压器故障样本进行分类,具体结构如附录A图A2所示。由图A1、A2可知,HDAG-SVM算法将训练所得的7个SVM二分类器组合为层次式有向无环图形式。在诊断阶段,对于任意未知类别的故障样本,HDAG-SVM算法仅需调用3个SVM二分类器即可给出诊断结果,且不存在分类重叠、不可分类等问题。

4 基于HS-MHMO算法的过采样器与分类器参数双层优化方法(参数优化器)

训练阶段,需要对过采样倍率 β 、SVM误差惩罚参数 C 、高斯核宽度 σ 这3种参数进行优化。本文采用双层优化方法求取参数最优解,上层采用层次搜索(hierarchical search, HS)算法对 β 寻优,下层采用改进哈里斯鹰算法(modified Harris hawks optimization, MHMO)对SVM参数 C 和 σ 寻优。

4.1 基于HS算法的过采样倍率优化方法

HS算法是对传统遍历搜索的改进,遵循“从整体到局部”的原则,首先采用大步距在整体范围内初步搜索,确定适应度最高的点,进而在以该点为中心的区间内小步距精细化搜索,最终求得全局最优解。采用HS优化 β 的具体步骤如下。

1)设置整体搜索的范围为 $[0,1]$,步距为 $\Delta\beta_w$,搜索点为 $\beta_t^w = t\Delta\beta_w$,其中 $t=0,1,2,\dots,1/\Delta\beta_w,1/\Delta\beta_w$ 为整数。在每个过采样倍率 β_t^w 下进行过采样,将利用过采样补充后的扩充训练样本集送入下层MHMO优化模块对SVM参数进行优化。优化完成后将下层适应度返回至上层HS优化模块。

2)选取下层适应度最优的 β_t^w 作为整体搜索的结果,记为 β_{best}^w ,若 β_{best}^w 为0或1,则按式(7)进行更新。

$$\begin{cases} \beta_{best}^w = \Delta\beta_w & \beta_{best}^w = 0 \\ \beta_{best}^w = 1 - \Delta\beta_w & \beta_{best}^w = 1 \end{cases} \quad (7)$$

3)设置局部搜索的范围为 $[\beta_{best}^w - \Delta\beta_w, \beta_{best}^w + \Delta\beta_w]$,步距为 $\Delta\beta_p$,搜索点为 $\beta_t^p = \beta_{best}^w - \Delta\beta_w + t\Delta\beta_p$,其中 $t=0,1,2,\dots,2\Delta\beta_w/\Delta\beta_p,2\Delta\beta_w/\Delta\beta_p$ 为整数。对每个过采样倍率 β_t^p 执行与步骤1)相同的操作。

4)选取下层适应度最优的 β_t^p 作为局部搜索的

结果,即为全局最优过采样倍率。

4.2 基于MHHO算法的SVM参数优化方法

4.2.1 MHHO算法

在上层优化 β 的过程中,需要将扩充训练样本集送入下层并对SVM进行参数优化。本文采用MHHO算法优化SVM的误差惩罚参数 C 和高斯核宽度 σ ,该算法是在哈里斯鹰(Harris hawks optimization, HHO)算法的基础上改进而来。HHO算法是一种新型群体智能算法,其通过模拟哈里斯鹰的群体捕猎行为,并结合Lévy飞行来实现对高维、非连续、不可微等复杂问题的求解,具体算法实现详见文献[22]。

HHO算法搜索范围较大,搜索效率较高,且针对多极值问题的收敛性能较好,但仍存在一定的缺陷,主要体现在两方面。一是参数设置过于简单,HHO算法中控制迭代进程的2个重要参数分别为猎物逃逸能量 E 和猎物跳跃强度 J ,其中 E 设置为简单的线性衰减,在迭代后期只进行局部开发,易陷入局部最优;而 J 设置为随机数,忽略了其与 E 之间的关系。二是位置更新时仅依赖种群个体信息,当种群陷入局部最优后无法产生新位置,使得迭代停滞,算法收敛早熟。针对上述问题,本文提出一系列改进措施,具体如下。

1)改进猎物迭代参数。

将 E 和 J 的更新公式改进为:

$$\begin{cases} E = 2(2r-1)[1-(g/G)^{1/e}]^{1/e} \\ J = r(1+|E|) \end{cases} \quad (8)$$

式中: g 为当前迭代次数; G 为迭代次数上限。改进后 E 的最值在迭代中后期变化较为平缓,在进行局部开发的同时保留了进行全局探索的可能性,降低了陷入局部最优的风险。改进后 J 的最值由当前的 E 值决定,一方面有助于扩大局部开发阶段前期的搜索范围,另一方面有助于提高局部开发阶段后期的搜索精度。

2)logistic混沌映射生成初始位置。

混沌映射具有良好的拟随机性、非周期性、遍历性,常用于启发式算法种群初始位置的生成,以使种群尽量均匀分布,从而扩大搜索范围,提高全局收敛性能。本文采用logistic混沌映射生成HHO算法的种群初始位置,计算方法详见文献[23]。

3)精英保留策略。

HHO算法在迭代过程中没有将当前代的种群最优适应度与上一代进行比较,难以保证每一代的种群最优适应度单调不减。针对此问题,本文在每一代位置更新后增加1个判断环节,若当前代种群最优个体位置更新后适应度变差,则不更新该个体位置,从而保证种群最优适应度向理论最优值不断逼近。

4)随机变异。

为降低HHO算法陷入局部最优的风险,引入个体随机变异机制,若变异后个体的适应度更优,则将个体位置更新为变异位置,如式(9)、(10)所示。

$$p_{\text{var}} = \begin{cases} p_{h,g} + 0.02(2r-1) \circ (p_{\text{max}} - p_{\text{min}}) & r \leq \frac{g}{2G} \\ p_{h,g} & r > \frac{g}{2G} \end{cases} \quad (9)$$

$$p_{h,g+1} = \begin{cases} p_{\text{var}} & f_{\text{var}} > f_{h,g} \\ p_{h,g} & f_{\text{var}} \leq f_{h,g} \end{cases} \quad (10)$$

式中: r 为 $[0,1]$ 范围内的随机数向量;“ $\circ$ ”表示矩阵的Hadamard乘积; p_{max} 、 p_{min} 分别为个体位置的上、下限,即待寻优变量的范围; $p_{h,g}$ 、 $f_{h,g}$ 分别为个体 h 第 g 代的位置及适应度; p_{var} 、 f_{var} 分别为个体 h 的变异位置及适应度。由式(9)可知,个体 h 是否变异取决于随机数 r 的值,且迭代后期的变异概率更大,从而提高HHO算法在局部开发阶段跳出局部最优的能力。

4.2.2 MHHO算法在SVM参数优化中的应用

采用MHHO算法优化SVM参数的关键点在于个体维度及适应度函数的设置,其中哈里斯鹰个体设置为2维向量,分别对应SVM的误差惩罚参数 C 和高斯核宽度 σ 。适应度函数如式(11)所示。

$$\begin{cases} f = \alpha_{\text{Acc}} F_{\text{Acc}} + \alpha_{\text{Sen}} F_{\text{Sen}} + \alpha_{\text{Spe}} F_{\text{Spe}} \\ F_{\text{Acc}} = \frac{M_{\text{T}}^+ + M_{\text{T}}^-}{M^+ + M^-}, F_{\text{Sen}} = \frac{M_{\text{T}}^+}{M^+}, F_{\text{Spe}} = \frac{M_{\text{T}}^-}{M^-} \end{cases} \quad (11)$$

式中: F_{Acc} 为准确率指标,是正确分类的样本数占总样本数的比例; F_{Sen} 为灵敏度指标,是少数类样本被正确分类的比例; F_{Spe} 为特效性指标,是多数类样本被正确分类的比例; M_{T}^+ 、 M_{T}^- 分别为被正确分类的少数类样本数、多数类样本数; α_{Acc} 、 α_{Sen} 、 α_{Spe} 分别为准确率、灵敏度、特效性指标的权值。

本文采用留一法计算准确率、灵敏度、特效性指标。设多数类原始样本集、少数类原始样本集、少数类过采样样本集分别为 X^- 、 X^+ 、 X_{os}^+ ,不重复地从 $X^- \cup X^+$ 中取1个样本作为验证样本,将 $X^- \cup X^+ \cup X_{\text{os}}^+$ 中的所有样本(验证样本除外)作为训练样本,训练SVM并给出验证样本的分类结果。重复此步骤 $M^- + M^+$ 次,遍历 $X^- \cup X^+$ 内所有样本,最后按式(11)计算准确率、灵敏度和特效性指标。

综合本节分析,基于HS-MHHO算法的过采样器与分类器参数双层优化算法流程见附录A图A3。

5 算例分析

5.1 算例样本及参数设置

本文共搜集到979条变压器故障样本数据,其来源主要有国家电网公司监测数据以及公开发表的刊物、文献等。将所有样本划分为训练样本和测试样本,样本数量分配情况如表1所示。

表 1 变压器故障样本数量

故障类型	训练样本数量	测试样本数量
T1	50	31
T2	100	40
T3	150	104
PD	50	38
D1	100	63
D2	150	103
总计	600	379

本文算例在 CPU 型号为 Intel Xeon Gold 2.70 GHz、内存为 256 GB 的计算机上进行测试。SMOTE-NND 算法中,若近邻数 L 、 K 取值过大则难以筛查噪声少数类样本,若取值过小则难以充分反映少数类样本的周围样本分布情况,本文取常用经验值 5^[16-17]。HS 算法中,过采样倍率 β 优化范围取 $[0, 1]$,为保证 β 整体搜索的遍历性与快速性以及 β 局部搜索的精细度,整体搜索步距 $\Delta\beta_w$ 取 0.1^[15],局部搜索步距 $\Delta\beta_p$ 取 0.01。由表 1 可知,在 $\Delta\beta_p=0.01$ 的情况下,局部搜索点每前进一次,过采样样本数量仅增加 1 个,从而达到最大精细度。MHHO 算法中,优化范围、迭代次数上限 G 、种群容量 H 对算法性能有重要影响。若取值过大则算法收敛慢、计算效率低;若取值过小则算法搜索能力差,容易陷入局部最优。本文对上述参数均取常用经验值,其中 SVM 误差惩罚参数 C 的优化范围取 $(0, 100]$, SVM 高斯核宽度 σ 优化范围取 $(0, 10]$, G 取 100, H 取 30^[11-12];为使分类器对少数类及多数类样本具有同等的泛化能力,3 种适应度指标权值 α_{Acc} 、 α_{Sen} 、 α_{Spe} 均取 1/3。

5.2 过采样倍率对诊断模型的影响

5.2.1 过采样倍率训练结果分析

采用本文算法训练变压器故障诊断模型,具体训练结果如表 2 所示,其中展示的子分类器即为附录 A 图 A2 中 HDAG-SVM 结构的 7 个二分类器。由表 1 可知,子分类器 SVM_{T/D} 的原始训练样本集已平衡,因此无需进行过采样,对应表 2 中的过采样倍率 β 为 0。

表 2 诊断模型训练结果

Table 2 Training results of diagnostic model

子分类器	β	C	σ	适应度	$F_{Acc}/\%$	$F_{Sen}/\%$	$F_{Spe}/\%$	训练用时/s
SVM _{T/D}	0	76.66	4.325	0.958	95.83	96.33	95.33	3 802.69
SVM _{T1/T2}	0.80	25.27	0.607	0.936	92.67	98.00	90.00	1 904.37
SVM _{T1/T3}	0.87	0.66	0.075	0.943	95.00	92.00	96.00	4 265.69
SVM _{T2/T3}	0.68	0.39	0.113	0.966	96.80	95.00	98.00	4 289.55
SVM _{PD/D1}	0.96	1.63	0.027	0.940	94.00	94.00	94.00	1 857.68
SVM _{PD/D2}	0.70	94.95	0.033	0.984	98.50	98.00	98.67	3 789.45
SVM _{D1/D2}	0.52	42.43	0.360	0.883	88.00	91.00	86.00	7 091.91

由表 2 可知,除 SVM_{T/D} 外,其他子分类器的最优过采样倍率均小于 1,可以在充分强化少数类样本数据特征的同时,尽量避免引入噪声样本。训练阶

段采用留一法验证的准确率基本都在 90% 以上,说明本文所提双层优化方法效果较好。各子分类器的训练用时均在 0.5~2 h 范围内,训练用时不同主要是由各子分类器原始训练样本数量及不平衡度差异造成的,同时也受训练期间计算机 CPU 及内存占用情况的影响。由于变压器故障诊断模型的训练过程是离线的,因此表 2 中的训练用时是可以接受的。

为进一步展示过采样倍率的训练效果,以 SVM_{T1/T3} 为例,绘制其过采样倍率搜索过程中下层适应度的变化曲线,如图 2 所示。




图 2 下层适应度变化曲线

Fig.2 Fitness curve of lower layer

由图 2 可知,在整体搜索过程中,下层适应度在 $\beta=0.9$ 处达到峰值 0.934。进一步地,局部搜索在 β 为 $[0.8, 1]$ 的范围内进行。在局部搜索过程中,下层适应度在 $\beta=0.87$ 处达到峰值 0.943,即为最终的优化结果。从整个搜索过程看,随着过采样倍率的增大,下层适应度逐渐增大,达到峰值之后略有减小。这说明过采样倍率的增大使得少数类样本的数据特征不断增强,当过采样倍率达到一定值后少数类样本数据特征的可强化空间趋于饱和,此后继续增加倍率并不会使得下层适应度有明显增大,反而可能引入噪声样本导致分类性能下降。

5.2.2 不同过采样倍率的诊断测试对比分析

为验证不同过采样倍率对诊断模型分类性能的影响,设计 3 组算例 CE₁—CE₃。CE₁ 的过采样倍率取为 5.2.1 节的优化结果,CE₂ 不进行过采样,CE₃ 中各子分类器的过采样倍率均取 1,其余参数设置与 5.1 节相同。分别采用 CE₁—CE₃ 训练所得的诊断模型对 379 个测试样本进行诊断分类,得到混淆矩阵如图 3 所示,准确率及诊断用时如附录 A 表 A1 所示,379 个测试样本的具体诊断结果如附录 A 表 A2 所示。

由图 3 及表 A1 可知:CE₁ 的整体准确率及各类样本的准确率均在 90% 以上,且明显高于 CE₂、CE₃ 的各项准确率。这说明与不进行过采样和完全平衡过采样相比,对过采样倍率进行优化后的故障诊断模型具有更强的故障样本区分能力;CE₁—CE₃ 的诊断用时均在 1 s 以内,体现了故障诊断模型的高

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	29	0	2	0	0	0
	T2	0	38	2	0	0	0
	T3	1	0	103	0	0	0
	PD	0	0	0	36	2	0
	D1	0	0	0	1	60	2
	D2	0	0	0	0	2	101

(a) CE₁

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	23	1	7	0	0	0
	T2	4	36	0	0	0	0
	T3	1	4	99	0	0	0
	PD	0	0	0	37	1	0
	D1	0	0	0	9	42	12
	D2	0	0	0	4	4	99

(b) CE₂

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	29	1	1	0	0	0
	T2	2	36	2	0	0	0
	T3	1	2	101	0	0	0
	PD	0	0	0	30	8	0
	D1	0	0	0	0	54	9
	D2	0	0	0	0	3	100

(c) CE₃

图3 算例CE₁—CE₃的混淆矩阵Fig.3 Confusion matrix of CE₁ to CE₃

效性。

由表A2可知,存在极少一部分样本,采用本文方法及其他对比方法(包括后续的算例)都无法对其进行正确识别。可能造成该现象的原因主要有2种:一是采样装置、监测系统、数据记录等本身具有一定的误差,导致记录的样本与其故障类型实际上并不匹配,从而产生诊断错误;二是现有的样本指标体系不足以完全刻画变压器的故障特征,需要增加新的指标以完善故障诊断模型。

5.3 过采样方法对诊断模型的影响

为验证不同过采样方法对诊断模型分类性能的影响,另设计2组算例CE₄、CE₅与CE₁进行对比。相较于CE₁,CE₄、CE₅的过采样方法分别为SMOTE算法、ADASYN算法,2种方法的近邻数均取5。除上述设置外,CE₄、CE₅的其他设置与CE₁相同。

5.3.1 不同过采样方法的过采样样本分布对比分析


分别对CE₁、CE₄、CE₅的诊断模型进行训练,以各算例的子分类器SVM_{T1/T3}为例,采用t-SNE算法对不同过采样方法的高维过采样样本分布情况进行降维可视化,CE₁、CE₄、CE₅的过采样样本分布分别如图4、附录A图A4、图A5所示。

由表1可知,SVM_{T1/T3}的少数类训练样本为T1故障样本。由图4、图A4、图A5可知,3种过采样方法均围绕T1原始样本生成过采样样本,以增强T1原始样本的数据特征。然而,SMOTE、ADASYN算法生成了大量与T1原始样本重合的过采样样本,这部分样本不具有数据增强价值,造成了过采样冗余。且上述2种方法的过采样样本均围绕T1原始样本呈小团体式、紧凑式分布,难以改善T1原始样本的内部稀疏问题。相比之下,SMOTE-NND算法的过采样样本在T1原始样本小团体之间建立联系,降低了T1原始样本分布的内部不均匀程度,提高了过采样质量。

5.3.2 不同过采样方法的诊断测试对比分析

分别采用CE₁、CE₄、CE₅训练所得的诊断模型对379个测试样本进行分类,得到混淆矩阵如图5所示,准确率及诊断用时如附录A表A1所示,379个测试样本的具体诊断结果如附录A表A2所示。

由图5及表A1可知,CE₁的各项准确率均优于CE₄、CE₅,这说明SMOTE-NND算法通过降低合成噪声风险、强化类边界、强化少数类样本内部稀疏区等

图4 算例CE₁(SMOTE-NND算法)的过采样样本分布图Fig.4 Oversampling sample distribution of CE₁ (SMOTE-NND algorithm)

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	29	0	2	0	0	0
	T2	0	38	2	0	0	0
	T3	1	0	103	0	0	0
	PD	0	0	0	36	2	0
	D1	0	0	0	1	60	2
	D2	0	0	0	0	2	101

(a) CE₁

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	27	2	2	0	0	0
	T2	1	36	3	0	0	0
	T3	1	2	101	0	0	0
	PD	0	0	0	36	2	0
	D1	0	0	0	5	51	7
	D2	0	0	0	0	3	100

(b) CE₄

		诊断类别					
		T1	T2	T3	PD	D1	D2
真实类别	T1	28	1	2	0	0	0
	T2	3	36	1	0	0	0
	T3	2	1	101	0	0	0
	PD	0	0	0	35	3	0
	D1	0	0	0	2	56	5
	D2	0	0	0	0	2	101

(c) CE₅

图5 算例CE₁、CE₄、CE₅的混淆矩阵Fig.5 Confusion matrix of CE₁, CE₄ and CE₅


措施,使得生成的过采样样本质量高于SMOTE、ADASYN算法生成的样本,从而训练得到分类性能更强的诊断模型。

5.4 参数优化方法对诊断模型的影响

为验证不同参数优化方法对诊断模型分类性能的影响,另设计2组算例CE₆、CE₇与CE₁进行对比。相较于CE₁,CE₆、CE₇的下层SVM参数优化方法分别为标准HHO算法、粒子群优化(particle swarm optimization, PSO)算法,HHO、PSO算法的种群数量、迭代次数上限均与5.1节相同,PSO算法的自我学习因子、群体学习因子均取2。除上述设置外,CE₆、CE₇的其他设置与CE₁相同。

5.4.1 不同参数优化方法的优化过程对比分析

分别对CE₁、CE₆、CE₇的诊断模型进行训练,以各算例的子分类器SVM_{T1/T3}为例,CE₁、CE₆、CE₇的寻优过程分别如图6、附录A图A6、图A7所示。

图6 算例CE₁(MHHO算法)的迭代过程Fig.6 Iterative process of CE₁(MHHO algorithm)

由图6、图A6、图A7可知,针对SVM_{T1/T3} 3组算例在各自的最优过采样倍率下分别采用MHHO、HHO、PSO算法对SVM参数进行优化,最终适应度优化结果分别为0.943、0.935、0.92,达到最优适应度时的迭代次数分别为54、32、14。这说明MHHO算法的变异机制使算法进入局部开发阶段后依然有跳出局部最优解的能力,相较于HHO、PSO算法,算法早熟及陷入局部最优的风险更小。此外,MHHO算法的初始适应度最高,这是因为logistic混沌映射生成的哈里斯鹰个体初始位置几乎均匀地散布在算法的搜索空间当中,从而保障了算法的全局搜索性能。

5.4.2 不同参数优化方法的诊断测试对比分析

分别采用CE₁、CE₆、CE₇训练所得的故障诊断模型对379个测试样本进行分类,得到混淆矩阵如图7所示,准确率及诊断用时如附录A表A1所示,379个测试样本的具体诊断结果如附录A表A2所示。

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	29	0	2	0	0	0
T2	0	38	2	0	0	0
T3	1	0	103	0	0	0
PD	0	0	0	36	2	0
D1	0	0	0	1	60	2
D2	0	0	0	0	2	101

(a) CE₁

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	27	0	4	0	0	0
T2	0	36	4	0	0	0
T3	0	2	102	0	0	0
PD	0	0	0	35	3	0
D1	0	0	0	1	51	11
D2	0	0	0	0	3	100

(b) CE₆

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	28	0	3	0	0	0
T2	3	34	3	0	0	0
T3	2	1	101	0	0	0
PD	0	0	0	33	5	0
D1	0	0	0	1	56	6
D2	0	0	0	0	2	101

(c) CE₇

图7 算例CE₁、CE₆、CE₇的混淆矩阵

Fig.7 Confusion matrix of CE₁,CE₆ and CE₇

由图7及表A1可知,CE₁的各项准确率均优于CE₆、CE₇,这说明MHHO算法前期全局探索-后期局部开发的最优解搜索模式,配合其变异机制、混沌映射等改进措施,能够有效降低SVM参数寻优过程中的收敛早熟及局部最优风险,从而能够搜索到使故障诊断模型泛化能力更强的SVM参数。

5.5 基准分类器对诊断模型的影响

为验证不同基准分类器对诊断模型分类性能的影响,另设计2组算例CE₈、CE₉与CE₁进行对比。相较于CE₁,CE₈、CE₉的基准分类器分别为分类回归树(classification and regression tree,CART)分类器、K最近邻(K-nearest neighbor,KNN)分类器。其中,CART分类器的待优化参数为最大决策分支数和最小叶节点观测数,优化范围均为[1,50]内的整数;KNN分类器的待优化参数为近邻搜索数,优化范围为[1,50]内的整数。由于CART分类器和KNN分类器均为二分类器,因此CE₈、CE₉的多分类策略同样采用层次式有向无环图形式,如附录A图A2所示。除上述设置外,CE₈、CE₉的其他设置与CE₁相同。分别采用CE₁、CE₈、CE₉训练所得的诊断模型对379个测试样本进行分类,得到混淆矩阵如图8所示,准确率及诊断用时如附录A表A1所示,379个测试样本的具体诊断结果如附录A表A2所示。

由图8及表A1可知:除CE₉在PD准确率上略高

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	29	0	2	0	0	0
T2	0	38	2	0	0	0
T3	1	0	103	0	0	0
PD	0	0	0	36	2	0
D1	0	0	0	1	60	2
D2	0	0	0	0	2	101

(a) CE₁

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	24	6	1	0	0	0
T2	5	35	0	0	0	0
T3	3	3	95	0	1	2
PD	3	0	0	33	2	0
D1	7	0	0	4	43	9
D2	1	1	4	0	14	83

(b) CE₈

真实类别	诊断类别					
	T1	T2	T3	PD	D1	D2
T1	26	1	4	0	0	0
T2	3	33	4	0	0	0
T3	1	0	103	0	0	0
PD	0	0	0	37	1	0
D1	2	0	1	8	31	21
D2	0	0	2	1	2	98

(c) CE₉

图8 算例CE₁、CE₈、CE₉的混淆矩阵

Fig.8 Confusion matrix of CE₁,CE₈ and CE₉

于CE₁之外,CE₁的其他各项准确率均优于CE₈、CE₉,这说明与CART分类器、KNN分类器相比,SVM作为处理变压器故障诊断问题的基准分类器更具优势。CART分类器、KNN分类器对T2、D1等类型故障样本分类性能较差,且存在T、D大类故障样本间错分的问题,在诊断用时方面也略高于SVM,因此不适合用于变压器的故障诊断。

6 结论

针对变压器故障样本不平衡导致的故障诊断准确率低、诊断效果偏向多数类样本的问题,本文提出一种考虑过采样器与分类器参数优化的变压器故障诊断策略,所得结论如下。

1)与不进行过采样及完全平衡过采样相比,最优倍率过采样能够充分强化少数类样本的数据特征,且降低引入噪声的风险,可有效提高过采样合成少数类样本的质量。相较于不进行过采样及完全平衡过采样的诊断模型,测试样本诊断准确率分别提高了8.18%、4.49%。

2)本文提出的SMOTE-NND过采样方法能够尽量避免合成噪声,降低少数类与多数类的边界模糊度,降低少数类样本内部分布的不均匀程度,从而合成高质量的少数类样本。相较于采用SMOTE、ADASYN算法进行过采样的故障诊断模型,测试样本诊断准确率分别提高了4.22%、2.64%。

3)本文提出的基于MHHO算法的下层SVM参数优化方法,收敛性能良好,不易陷入局部最优,使得优化后SVM的泛化能力更强。相较于采用HHO、PSO算法进行下层SVM参数优化的诊断模型,测试样本诊断准确率分别提高了4.22%、3.69%。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 国家能源局. 变压器油中溶解气体分析和判断导则:DL/T 722—2014[S]. 北京:中国电力出版社,2015.
- [2] IEC. Mineral oil-impregnated electrical equipment in service-guide to the interpretation of dissolved and free gases analysis:IEC 60599-2007[S]. Geneva,Switzerland:IEC Central Office,2007.
- [3] DUVAL M. A review of faults detectable by gas-in-oil analysis in transformers[J]. IEEE Electrical Insulation Magazine,2002,18(3):8-17.

- [4] DUVAL M, DUKARM J. Improving the reliability of transformer gas-in-oil diagnosis[J]. IEEE Electrical Insulation Magazine, 2005, 21(4): 21-27.
- [5] 赵玲玲, 王群京, 陈权, 等. 基于IBBOA优化BP神经网络的变压器故障诊断[J]. 电工电能新技术, 2021, 40(9): 39-46.
ZHAO Lingling, WANG Qunjing, CHEN Quan, et al. Fault diagnosis of transformer based on BP neural network optimized by IBBOA[J]. Advanced Technology of Electrical Engineering and Energy, 2021, 40(9): 39-46.
- [6] 赵文清, 严海, 周震东, 等. 基于残差BP神经网络的变压器故障诊断[J]. 电力自动化设备, 2020, 40(2): 143-148.
ZHAO Wenqing, YAN Hai, ZHOU Zhendong, et al. Fault diagnosis of transformer based on residual BP neural network[J]. Electric Power Automation Equipment, 2020, 40(2): 143-148.
- [7] 苑津莎, 张利伟, 王瑜, 等. 基于极限学习机的变压器故障诊断方法研究[J]. 电测与仪表, 2013, 50(12): 21-26.
YUAN Jinsha, ZHANG Liwei, WANG Yu, et al. Study of transformers fault diagnosis based on extreme learning machine[J]. Electrical Measurement & Instrumentation, 2013, 50(12): 21-26.
- [8] 吴杰康, 覃炜梅, 梁浩浩, 等. 基于自适应极限学习机的变压器故障识别方法[J]. 电力自动化设备, 2019, 39(10): 181-186.
WU Jiekang, QIN Weimei, LIANG Haohao, et al. Transformer fault identification method based on self-adaptive extreme learning machine[J]. Electric Power Automation Equipment, 2019, 39(10): 181-186.
- [9] 黄新波, 马玉涛, 朱永灿. 基于信息融合和M-RVM的变压器故障诊断方法[J]. 电力自动化设备, 2020, 40(12): 218-225.
HUANG Xinbo, MA Yutao, ZHU Yongcan. Transformer fault diagnosis method based on information fusion and M-RVM[J]. Electric Power Automation Equipment, 2020, 40(12): 218-225.
- [10] 尹金良, 刘玲玲. 代价敏感相关向量机的研究及其在变压器故障诊断中的应用[J]. 电力自动化设备, 2014, 34(5): 111-115.
YIN Jinliang, LIU Lingling. CS-RVM and its application in fault diagnosis of power transformers[J]. Electric Power Automation Equipment, 2014, 34(5): 111-115.
- [11] 张懿议, 焦健, 汪可, 等. 基于帝国殖民竞争算法优化支持向量机的电力变压器故障诊断模型[J]. 电力自动化设备, 2018, 38(1): 99-104.
ZHANG Yiyi, JIAO Jian, WANG Ke, et al. Power transformer fault diagnosis model based on support vector machine optimized by imperialist competitive algorithm[J]. Electric Power Automation Equipment, 2018, 38(1): 99-104.
- [12] 余松, 胡东, 唐超, 等. 基于TLR-ADASYN平衡化数据集的MSSA-SVM变压器故障诊断[J]. 高电压技术, 2021, 47(11): 3845-3853.
YU Song, HU Dong, TANG Chao, et al. MSSA-SVM transformer fault diagnosis method based on TLR-ADASYN balanced data set[J]. High Voltage Engineering, 2021, 47(11): 3845-3853.
- [13] 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.
LIU Yunpeng, HE Jiahui, XU Ziqiang, et al. Equalization method of power transformer fault sample based on SVM SMOTE[J]. High Voltage Engineering, 2020, 46(7): 2522-2529.
- [14] 王文博. 基于不平衡数据集的变压器缺陷预测[D]. 北京: 华北电力大学, 2020.
WANG Wenbo. Transformer defect prediction based on imbalanced data set[D]. Beijing: North China Electric Power University, 2020.
- [15] 李亮, 范瑾, 闫林, 等. 基于混合采样和支持向量机的变压器故障诊断[J]. 中国电力, 2021, 54(12): 150-155.
LI Liang, FAN Jin, YAN Lin, et al. Transformer fault diagnosis based on hybrid sampling and support vector machines[J]. Electric Power, 2021, 54(12): 150-155.
- [16] 谢桦, 陈俊星, 赵宇明, 等. 基于SMOTE和决策树算法的电力变压器状态评估知识获取方法[J]. 电力自动化设备, 2020, 40(2): 137-142.
XIE Hua, CHEN Junxing, ZHAO Yuming, et al. Knowledge acquisition method of power transformer condition assessment based on SMOTE and decision tree algorithm[J]. Electric Power Automation Equipment, 2020, 40(2): 137-142.
- [17] 王文博, 曾小梅, 赵引川, 等. 基于SMOTE-XGBoost的变压器缺陷预测[J]. 华北电力大学学报(自然科学版), 2021, 48(5): 54-60, 71.
WANG Wenbo, ZENG Xiaomei, ZHAO Yinchuan, et al. A transformer defect prediction model based on SMOTE-XGBoost[J]. Journal of North China Electric Power University (Natural Science Edition), 2021, 48(5): 54-60, 71.
- [18] 李帅兵. 基于大数据分析的牵引变压器绝缘老化特征提取与状态诊断研究[D]. 成都: 西南交通大学, 2018.
LI Shuaibing. Research on insulation aging feature extraction and condition diagnosis of traction transformer based on big data analytics[D]. Chengdu: Southwest Jiaotong University, 2018.
- [19] 马玉涛, 黄新波, 朱永灿, 等. 面向多源异构数据的牵引变压器故障诊断平台设计[J]. 广东电力, 2020, 33(2): 131-138.
MA Yutao, HUANG Xinbo, ZHU Yongcan, et al. Design of traction transformer fault diagnosis platform for multi-source heterogeneous data[J]. Guangdong Electric Power, 2020, 33(2): 131-138.
- [20] 石洪波, 陈雨文, 陈鑫. SMOTE过采样及其改进算法研究综述[J]. 智能系统学报, 2019, 14(6): 1073-1083.
SHI Hongbo, CHEN Yuwen, CHEN Xin. Summary of research on SMOTE oversampling and its improved algorithms[J]. CAAI Transactions on Intelligent Systems, 2019, 14(6): 1073-1083.
- [21] 李刘杰. 基于过采样与集成学习的不平衡数据分类方法研究[D]. 重庆: 重庆邮电大学, 2019.
LI Liujie. Research of imbalanced data classification method based on oversampling and ensemble learning[D]. Chongqing: Chongqing University of Posts and Telecommunications, 2019.
- [22] HEIDARI A A, MIRJALILI S, FARIS H, et al. Harris Hawks optimization: algorithm and applications[J]. Future Generation Computer Systems, 2019, 97: 849-872.
- [23] 周斌, 彭敏放, 黄清秀, 等. 基于节点撕裂和化学反应优化算法的接地网故障诊断[J]. 电力自动化设备, 2017, 37(1): 163-168, 175.
ZHOU Bin, PENG Minfang, HUANG Qingxiu, et al. Grounding grid fault diagnosis based on node tearing and chemical reaction optimization algorithm[J]. Electric Power Automation Equipment, 2017, 37(1): 163-168, 175.

作者简介:



梁磊

梁磊(1982—),男,高级工程师,硕士,主要研究方向为电力系统保护与控制、电网设备可靠性等(**E-mail**: 15109618755@139.com);

王廷涛(1997—),男,硕士研究生,通信作者,主要研究方向为电力系统优化规划与运行技术(**E-mail**: hustwt@hust.edu.cn);

苗世洪(1963—),男,教授,博士研究生导师,博士,主要研究方向为电力系统保护与控制、压缩空气储能系统等(**E-mail**: shmiao@hust.edu.cn)。

(编辑 任思思)

Transformer fault diagnosis strategy considering parameter optimization of oversampler and classifier

LI Lei¹, WANG Tingtao², HE Jianan¹, NIU Jian¹, LIANG Yabo¹, MIAO Shihong²

(1. Electric Power Research Institute, State Grid Ningxia Electric Power Co., Ltd., Yinchuan 750002, China;

2. School of Electrical and Electronic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: The imbalance of transformer fault samples makes the accuracy of fault diagnosis and classification low, and it is easy to weaken the classification effect of a few types of fault samples. Therefore, the oversampling method is used to realize the equalization of fault samples, and a transformer fault diagnosis strategy considering the parameter optimization of oversampler and classifier is proposed. Firstly, the overall structure of transformer fault diagnosis model is built, and the implementation process of fault diagnosis is described. On this basis, the algorithm implementation of three main links of oversampler, classifier and parameter optimizer in the diagnosis model is proposed. For the oversampler, an improved synthetic minority oversampling technique based on nearest neighbor distribution (SMOTE-NND) algorithm is proposed to realize the equalization of fault samples. For the classifier, the hierarchical directed acyclic graph support vector machine (HDAG-SVM) algorithm is used to realize the multi-label classification of fault samples. For the parameter optimizer, a double-layer parameter optimization method is proposed. The upper layer uses the hierarchical search (HS) algorithm to optimize the oversampling ratio, and the lower layer uses modified harris hawks optimization (MHHO) algorithm to optimize the parameters of support vector machine. Finally, an example is given to analyze the proposed strategy. The results show that the proposed strategy can synthesize a few fault samples with higher quality and realize the accurate classification of fault samples.

Key words: power transformers; fault diagnosis; unbalanced samples; oversample; SMOTE-NND; HS-MHHO algorithm

附录 A




Fig.A1 Structure diagram of transformer fault diagnosis model




Fig.A2 Structure diagram of HDAG-SVM




图 A3 HS-MHHO 算法流程图
Fig.A3 Flowchart of HS-MHHO algorithm




图 A4 算例 CE_4 (SMOTE) 的过采样样本分布
Fig.A4 Oversampling sample distribution of CE_4 (SMOTE)




图 A5 算例 CE₅ (ADASYN) 训练样本分布图

Fig.A5 Oversampling sample distribution of CE₅ (ADASYN)




图 A6 算例 CE₆ (HHO) 迭代过程

Fig.A6 Iterative process of CE₆ (HHO)




图 A7 算例 CE₇ (PSO) 迭代过程

Fig.A7 Iterative process of CE₇ (PSO)

电力自动化设备

表 A1 算例 CE₁—CE₉ 的准确率及诊断用时
Table A1 Accuracy and diagnostic time of CE₁ to CE₉

算例	整体准确率/%	T1 准确率/%	T2 准确率/%	T3 准确率/%	PD 准确率/%	D1 准确率/%	D2 准确率/%	诊断用时/s
CE ₁	96.83	93.55	95.00	99.04	94.74	95.24	98.06	0.875
CE ₂	88.65	74.19	90.00	95.19	97.37	66.67	96.12	0.754
CE ₃	92.35	93.55	90.00	97.12	78.95	85.71	97.09	0.998
CE ₄	92.61	87.10	90.00	97.12	94.74	80.95	97.09	0.894
CE ₅	94.20	90.32	90.00	97.12	92.11	88.89	98.06	0.829
CE ₆	92.61	87.10	90.00	98.08	92.11	80.95	97.09	0.785
CE ₇	93.14	90.32	85.00	97.12	86.84	88.89	98.06	0.844
CE ₈	82.59	77.42	87.50	91.35	86.84	68.25	80.58	1.598
CE ₉	86.54	83.87	82.50	99.04	97.37	49.21	95.15	2.785

表 A2 测试样本诊断结果
Table A2 Diagnostic results of test samples

样本编号	油中溶解气体含量 (μL · L ⁻¹)					真实故障	CE ₁ 诊断	CE ₂ 诊断	CE ₃ 诊断	CE ₄ 诊断	CE ₅ 诊断	CE ₆ 诊断	CE ₇ 诊断	CE ₈ 诊断	CE ₉ 诊断
	H ₂	CH ₄	C ₂ H ₆	C ₂ H ₄	C ₂ H ₂	类型	结果	结果	结果	结果	结果	结果	结果	结果	结果
1	19.24	110	181.38	3.38	0.33	T1	T3	T3	T3	T3	T3	T3	T3	T1	T3
2	73.38	157.49	244.65	35.68	0	T1	T1	T3	T1	T1	T1	T1	T1	T1	T1
3	70.84	148.56	238.36	35.24	0	T1	T1	T3	T1	T1	T1	T1	T1	T1	T1
4	58.54	116.04	175.74	34.12	0.72	T1	T1	T3	T1	T1	T1	T1	T1	T1	T1
5	207	416	347	134.5	20	T1	T1	T1	T1	T1	T1	T3	T1	T2	T1
6	5.07	26.26	3.17	2.77	0.21	T1	T1	T1	T1	T1	T1	T1	T1	T2	T1
7	59.26	120.18	185.6	36.84	0.05	T1	T1	T3	T1	T1	T1	T1	T1	T1	T1
8	137	251	32	14	0	T1	T1	T1	T1	T2	T1	T1	T1	T1	T1
9	32.76	44.25	10.92	12.07	0	T1	T1	T1	T1	T1	T1	T1	T1	T2	T1
10	5.5	9.2	7.7	2	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T3
11	11.03	22.51	111.3	7.967	3.314	T1	T1	T3	T1	T1	T1	T1	T3	T1	T3
12	5.5	9.2	7.7	2	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T3
13	16	38.4	70	28	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
14	18.6	110.2	162.3	50.7	0.7	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
15	33.19	31.03	7.88	22.91	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
16	33.56	33.56	9.23	23.49	0.15	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
17	60	60	16	40	0.3	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
18	81	204	96	3	0	T1	T3	T2	T2	T3	T2	T3	T3	T3	T2
19	102	168	597	35	0	T1	T1	T3	T1	T1	T1	T1	T1	T1	T1
20	110.4	112	32.5	81.8	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
21	161	128	29	98	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
22	120	120	33	84	0.55	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
23	57	77	19	21	0	T1	T1	T1	T1	T1	T1	T1	T1	T2	T1
24	137	251	32	14	0	T1	T1	T1	T1	T2	T1	T1	T1	T1	T1
25	159.9	129.8	42	98	0.1	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
26	160	130	33	96	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
27	121	120	32	86	0.55	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
28	62.5	209.1	16.6	4.8	0.4	T1	T1	T1	T1	T1	T3	T3	T1	T2	T1
29	100	95	24	70	0	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
30	119.2	118.9	35	82.2	0.6	T1	T1	T1	T1	T1	T1	T1	T1	T1	T1
31	57	77	19	21	0	T1	T1	T1	T1	T1	T1	T1	T1	T2	T1
32	72	2442	221	461	0.7	T2	T3	T1	T1	T3	T1	T3	T1	T1	T1
33	139	714	351	634	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
34	19	136	55	164	0.29	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
35	23.6	170.6	180.4	450.9	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
36	18.4	29.1	9.7	26.9	0.4	T2	T2	T2	T2	T3	T2	T2	T2	T2	T2
37	22.7	150.3	160.8	400.8	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2

电力自动化设备

续表															
38	972	3411	1436	1639	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
39	194.8	917.7	565.89	1460.9	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
40	139	345	184	533	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
41	70.2	246.6	171.5	371	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
42	211	769.2	465	1210.4	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
43	13.6	46.5	45	116.1	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
44	300	490	180	360	95	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
45	5.1	195.2	118	125	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
46	15.3	26.2	21	52.8	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
47	20	41.9	20.2	44.2	0.38	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
48	25	255.8	200.2	199.9	0.86	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
49	26.7	90.6	49.2	95	0.5	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
50	27	90	42	63	0.2	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
51	27.5	48.2	18.4	46	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
52	29	130	34	82	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
53	45	431	210	517	2	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
54	46.9	161.6	94.1	193.3	0.56	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
55	47	120	90	198	3	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
56	68.4	159.6	45.7	51.3	0	T2	T2	T2	T3	T2	T2	T3	T3	T2	T3
57	72	442	221	461	0.7	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
58	92.85	58.12	44.96	37.15	0	T2	T2	T1	T2	T1	T1	T2	T1	T1	T1
59	93	58	43	37	0	T2	T2	T1	T2	T2	T1	T2	T1	T1	T1
60	93	68.99	43	20	0	T2	T3	T1	T3	T3	T3	T3	T3	T2	T3
61	101.2	98.12	87.5	202.63	6.35	T2	T2	T2	T1	T2	T2	T2	T2	T2	T1
62	110.6	458.8	242.6	706.4	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
63	128	419	269.4	614.1	0.35	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
64	200	700	250	740	1	T2	T2	T2	T2	T2	T2	T2	T2	T2	T3
65	259	863	393	994	6	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
66	259.3	866.2	359.3	1000.1	6.3	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
67	65	150	45	54	0	T2	T2	T2	T2	T2	T2	T3	T3	T2	T3
68	58	290	149	373	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
69	81	98	89	213	0	T2	T2	T2	T2	T2	T2	T2	T2	T1	T2
70	680	4895	1846	3662	0	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
71	230	572.3	243	768.9	0.51	T2	T2	T2	T2	T2	T2	T2	T2	T2	T2
72	26	88.3	46	196	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
73	5.49	35.9	28.1	156	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
74	12	23	9	98	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
75	14	29	18	174	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
76	117	357	92	486	4	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
77	18.95	46.97	6.94	61.54	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
78	1.963	29.08	11.288	57.669	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
79	4.079	20.83	6.992	67.589	0.51	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
80	32	41.6	10.1	120.5	2.61	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
81	34	48.5	12.9	141	3.31	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
82	11	102.4	57.9	277.6	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
83	24	137	62	329.5	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
84	43	50.9	11.6	127.9	2.9	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
85	3.76	26.88	7.22	61.8	0.31	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
86	171.19	628.34	354.87	1619.9	46.26	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
87	157.2	718.13	727.56	2434.3	153.36	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
88	58.54	116.04	34.12	175.74	0.72	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
89	159	212.4	82.4	260	0.35	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
90	14.42	44.83	3.26	72.63	0	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3
91	152	247.3	101.2	313.2	0.35	T3	T3	T3	T3	T3	T3	T3	T3	T3	T3

电力自动化设备

[illegible]

电力自动化设备

[illegible]

电力自动化设备

续表																
200	195.9	14.5	11.6	2.4	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
201	1309	124	113	6	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
202	1567	94	36	48	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
203	980	73	58	12	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
204	650	53	34	20	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
205	1565	93	34	47	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
206	260	8	2.5	2	0	PD	PD	PD	PD	PD	PD	PD	PD	D1	PD	PD
207	2587.2	7.88	4.7	1.4	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
208	180.85	0.57	0.23	0.19	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
209	124	20.67	17.81	15.33	0	PD	D1	PD	D1	D1	D1	D1	D1	D1	T1	PD
210	324	18	19	12	0.7	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
211	654	74	32	12	0	PD	PD	PD	D1	PD	PD	PD	PD	PD	PD	PD
212	894	100	38	19	0	PD	PD	PD	D1	PD	PD	PD	PD	PD	PD	PD
213	568	26.5	6.9	2.1	0	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD	PD
214	21.4	3.5	1.4	0.88	9.14	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
215	13.9	3.5	1.3	1.5	0.44	D1	D1	PD	D1	D1	D1	D1	D1	D1	T1	D1
216	4.1	3.5	0.68	1.2	5.2	D1	D1	D2	D2	D1	D1	D2	D1	D1	D1	D2
217	332	28.7	2.35	25.66	196.8	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
218	41.28	4.51	1.5	1.8	16.2	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
219	61.52	24.61	1.35	5.64	20.5	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
220	35.2	2.6	1.9	5.3	18.3	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
221	538.33	12.62	8.68	14.12	0.35	D1	D1	PD	D1	PD	PD	D1	D1	D1	PD	PD
222	46.63	6.22	1.55	7.25	27.98	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
223	170	24	7	17	54	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
224	80	20	6	20	62	D1	D1	D2	D2	D2	D2	D2	D2	D2	D2	D2
225	30	7.4	8.5	1.8	19	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
226	36.2	7.52	6.38	2.51	12.98	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
227	45	11.1	12.7	2.7	28.5	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
228	4.1	3.5	0.68	1.2	5.2	D1	D1	D2	D2	D1	D1	D2	D1	D1	D1	D2
229	6	0.5	1.87	0.29	7.42	D1	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
230	14	6.51	1.51	1.17	1.81	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
231	22.5	8.5	7.3	1.2	8.4	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
232	23	7.1	1.4	1	2.4	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
233	24.2	3.2	16.6	3.7	101	D1	D1	D1	D1	D2	D1	D2	D1	D1	D1	D2
234	27.79	1.57	0.11	0.8	1.43	D1	D1	PD	D1	D1	D1	D1	D1	D1	D1	PD
235	30	7.4	8.5	1.8	19	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
236	30.1	17.1	2.2	5.5	5.2	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2	D1
237	34.4	21.9	45	3.2	19.6	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	T3
238	35.2	2.6	1.9	5.3	18.3	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
239	36.2	7.52	6.38	2.51	12.98	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
240	41.18	4.41	1.47	1.47	16.18	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
241	44.977511.094512.74362.698728.4858					D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
242	45	11.1	12.7	2.7	28.5	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
243	46.63	6.22	1.55	7.25	27.98	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
244	54	7	7.4	8.6	5.4	D1	D1	PD	D1	D1	D1	D1	D1	D1	PD	PD
245	63	0.29	0.59	3.64	16.8	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
246	68.72	9.05	1.71	11.38	34.88	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
247	75	2.98	0.6	3.57	14.29	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
248	78	28	13	29	110	D1	D1	D2	D1	D1	D1	D1	D1	D1	D1	D2
249	80	20	6	20	62	D1	D1	D2	D2	D2	D2	D2	D2	D2	D2	D2
250	83.714	8.067	5.175	3.0441	0	D1	PD	PD	D1	PD	PD	PD	PD	PD	PD	PD
251	97.81	15.87	2.71	8.1	24.36	D1	D1	D1	D1	PD	D1	D1	D1	D1	D1	D2
252	99.39	28.86	6.82	16.07	52.3	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
253	115.9	75	14.7	25.5	6.8	D1	D1	D1	D1	D1	D1	D1	D1	D1	T1	D1
254	160	90	27	17	5	D1	D1	D1	D1	D1	D1	D1	D1	D1	T1	D1

电力自动化设备

续表															
255	170	24	7	17	54	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
256	180	229	3	378	1543	D1	D1	D2	D2	D2	D1	D2	D2	D2	D2
257	200	50	40	50	6	D1	D1	D2	D1	D1	D1	D2	D1	T1	D2
258	565	93	34	47	0	D1	D1	PD	D1	D1	D1	D1	D1	T1	PD
259	76	12.6	6.34	6.1	8.9	D1	D1	PD	D1	PD	D1	D1	D1	D1	PD
260	35.2	2.6	5.3	1.9	18.3	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
261	62	0.29	3.64	0.59	16.8	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
262	65.8	21.26	4.44	7.85	24.5	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
263	176	205.9	47.7	75.7	69.7	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
264	565	93	34	47	0	D1	D1	PD	D1	D1	D1	D1	D1	T1	PD
265	54	7	7.4	8.6	5.4	D1	D1	PD	D1	D1	D1	D1	D1	PD	PD
266	80	20	6	20	62	D1	D1	D2	D2	D2	D2	D2	D2	D2	D2
267	170	24	7	17	54	D1	D1	D1	D1	D1	D1	D1	D1	D1	D2
268	44.98	11.09	12.74	2.7	28.49	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
269	63	0.29	0.59	3.64	16.8	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
270	22.5	8.5	1.2	7.3	8.4	D1	D2	D2	D2	D2	D2	D1	D2	D2	D2
271	35.2	2.6	1.9	5.3	18.3	D1	D1	D1	D1	D1	D1	D1	D1	D1	D1
272	4.1	3.5	0.68	1.2	5.2	D1	D1	D2	D2	D1	D1	D2	D1	D1	D2
273	176	205.9	47.7	75.7	68.7	D1	D1	D1	D1	D1	D1	D1	D1	D2	T1
274	30.1	17.1	2.2	5.5	5.2	D1	D1	D1	D1	D1	D1	D1	D1	D2	D1
275	97.81	15.87	2.71	8.1	24.36	D1	D1	D1	D1	PD	D1	D1	D1	D1	D2
276	200	50	40	50	6	D1	D1	D2	D1	D1	D1	D2	D1	T1	D2
277	293	50	13	115	120	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
278	647.9	189.9	5.9	164.2	201.4	D2	D2	D2	D2	D2	D2	D2	D1	D2	D2
279	512	87	11.5	163.9	185.21	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
280	698	457	107.1	860	988.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
281	23	5.9	1	3.1	3.62	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
282	207.1	107.16	19.39	136.59	159.65	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
283	1350.3	602.76	46.1	705.61	896.69	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
284	531	111.9	22.7	122.5	169	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
285	447.6	196	33.3	188.6	22.65	D2	D2	D2	D2	D2	D2	D2	D2	D2	T2
286	344.1	213	18.6	199.9	257.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
287	642.9	195.5	17.9	172.9	197.4	D2	D2	D2	D2	D2	D2	D2	D1	D2	D2
288	6785	1149	251	2525	3574.4	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
289	602.6	186	13.7	190.5	260.7	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
290	256.61	82.87	6.41	82.65	167.5	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
291	176	40	11	71	79	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
292	2307	623.3	26.87	339.32	550	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
293	7.6	96.3	26.7	4.7	135	D2	D2	D2	D2	D2	D2	D2	D2	D2	D1
294	17.011813.7574	3.0695	39.571	26.5902		D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
295	20.39	17.18	1.77	24.72	35.96	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
296	21	7.6	4.7	96.3	26.73	D2	D2	D2	D2	D2	D2	D2	D2	D2	T3
297	23.023312.004610.0593	12	61.8213			D2	D1	D1	D1	D1	D1	D1	D2	D1	D1
298	24.79	27.22	3.15	25.85	18.86	D2	D2	D1	D1	D2	D2	D2	D2	D2	D2
299	41.6	25.1	124	15.7	206	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
300	42	62	5	63	73	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
301	44.11	24.55	6.66	24.14	0.54	D2	D2	D2	D2	D2	D2	D2	D2	T3	D2
302	44.792717.4924	3.64	23.559210.5157			D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
303	44.964	8.0935	1.0941	18.884926.9784		D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
304	46	37.2	8.3	107	71.9	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
305	49.2	15.3	4.5	44.9	13.1	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
306	49.7696	8.4485	2.1505	19.354820.2765		D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
307	51.2	37.6	5.1	52.8	51.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
308	56.82	9.86	2.16	11.59	17.97	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2

电力自动化设备

续表															
309	60	40	6.9	110	70	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
310	62.306311.1903	1.8599	10.012314.6311			D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
311	88.3	53.3	6.1	47.5	3.2	D2	D2	D2	D2	D2	D2	D2	D2	T3	D2
312	106	24	4	28	37	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
313	117	5.8	7	15.9	12.8	D2	D2	D1	D2	D1	D2	D2	D1	D1	PD
314	127	107	11	154	224	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
315	150	27	56	65	90	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
316	154	70	24	103	115	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
317	162	35	5.6	30	44	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
318	162.2	110.1	11.8	200.9	178.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
319	162.5	90.1	16.7	112	259.2	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
320	179	413	27	544	473	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
321	195.7	58	16.4	91.6	96.9	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
322	200	48	14	117	131	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
323	201	36	6	32.3	47.2	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
324	217.5	40	4.9	51.8	67.5	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
325	260	130	26	84	92	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
326	260.1	13.5	29	84.3	92.7	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
327	263	628	16.8	46	855.4	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
328	279	41	9.7	42	34	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
329	293	50	13	115	120	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
330	294	27.4	5.6	52.6	338	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
331	335	67	18	143	170	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
332	335	95	11	98	203	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
333	559	40	73	128	205	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
334	940	440	3	530	460	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
335	1678	652.9	80.7	1005.9	419.1	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
336	33	5.4	1.5	12.9	13.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
337	57	13	0.1	11	12	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
338	443	85	9.5	103	174	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
339	469.5	147	12.5	265	520	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
340	1675	650	82	1006	420	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
341	2054	370	26	535	805	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
342	60	40	10	110	70	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
343	420	200	14	230	180	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
344	980	570	37	480	54	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
345	260	130	26	84	92	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
346	60	40	6.9	110	70	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
347	217.5	40	4.9	51.8	67.5	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
348	150	21.5	1.8	22	33	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
349	100	32	9	91	25	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
350	132	43	20	76	51	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
351	127	107	11	154	224	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
352	7	5.2	0	11	37	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
353	41.6	25.1	124	15.7	206	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
354	200	48	14	117	131	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
355	59	28	9	70	15	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
356	335	67	18	143	170	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
357	44.3	17.3	3.6	44.3	17.3	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
358	56.98	10.48	1.28	13.57	17.68	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
359	44.11	24.55	6.66	24.14	0.54	D2	D2	D2	D2	D2	D2	D2	D2	T3	D2
360	20.39	17.18	1.77	24.72	35.96	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
361	17.01	13.76	3.07	39.57	26.59	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
362	62.31	11.19	1.86	10.01	14.63	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2

电 力 自 动 化 设 备

续表															
363	44.96	8.09	1.09	18.88	26.98	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
364	32.6	15.47	4.97	38.67	8.29	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
365	44.79	17.49	3.64	23.56	10.52	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
366	139	52.2	6.8	62.8	9.6	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
367	29	7.52	5.5	14.8	5.4	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
368	42	62	5	63	73	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
369	32.4	5.5	1.4	12.6	13.2	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
370	151	26.8	36.9	44.6	59.8	D2	D2	D2	D2	D2	D2	D2	D2	D1	D2
371	79	18	7	71	8	D2	D2	D2	D2	D2	D2	D2	D2	T3	D2
372	101	57	13	114	12	D2	D2	D2	D2	D2	D2	D2	D2	T1	D2
373	207.06	21.08	4.28	67.34	141.93	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
374	100	94	22	304	118	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
375	21	7.6	4.7	96.3	26.73	D2	D2	D2	D2	D2	D2	D2	D2	D2	T3
376	65	26.1	10.1	41.6	57.8	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
377	64	22	20.7	51.7	95.1	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
378	250	63	2.8	66	120	D2	D2	D2	D2	D2	D2	D2	D2	D2	D2
379	6.3	7.87	6.97	3.03	11.1	D2	D1	D1	D1	D1	D1	D2	D1	D1	D1

注：粗体表示诊断错误分类。