

# 基于策略梯度和生成式对抗网络的变压器油色谱案例扩充方法

李雅欣<sup>1</sup>, 侯慧娟<sup>1</sup>, 胥明凯<sup>2</sup>, 李善武<sup>2</sup>, 盛戈皞<sup>1</sup>, 江秀臣<sup>1</sup>

(1. 上海交通大学 电气工程系, 上海 200240; 2. 国网山东省电力公司, 山东 济南 250002)

**摘要:**油色谱数据的缺乏和不均衡会导致训练过拟合、模型缺乏代表性、测试集效果不理想等问题,从而难以对变压器的状态进行准确评价。针对该问题,将强化学习中的策略梯度算法引入生成式对抗网络GAN(Generative Adversarial Networks),提出了一种基于策略梯度和GAN的变压器油色谱案例生成方法。仿真结果表明,与传统的样本扩充算法相比,利用所提方法合成的样本质量较高。对包含9种故障状态共700组样本的变压器油色谱数据利用所提方法进行油色谱故障样本扩充,利用基于BP神经网络模型的变压器故障分类模型对将扩充后样本作为训练集训练得到的神经网络模型和仅用真实数据作为训练集训练得到的神经网络模型进行了对比,结果表明利用扩充的样本后,变压器故障分类准确率得到了提高。变压器故障诊断实例表明利用所提方法得到的结果与实际情况相符。

**关键词:**变压器;油色谱;样本扩充;生成式对抗网络;强化学习;策略梯度

**中图分类号:**TM 41

**文献标志码:**A

**DOI:**10.16081/j.epae.202009012

## 0 引言

变压器是电力系统中最为重要的设备之一,是保证电力系统安全、可靠、经济、优质运行的关键。绝缘自然老化、环境条件恶劣和运行负荷过高等因素都可能诱发电力变压器的故障,造成严重的社会经济损失,深入研究电力变压器故障诊断及预警技术,准确识别故障类型和特征,对于变压器的维护、制定合适的检修策略等具有重要的指导意义。基于油色谱的变压器状态评估在生产实践中得到了广泛应用,是油浸式变压器健康状态评估和故障诊断的最有效、最可靠的手段之一,至今仍是研究热点<sup>[1]</sup>。

随着计算机信息技术以及机器学习的发展,人工智能被广泛用于变压器的故障诊断<sup>[2]</sup>,如支持向量机SVM(Support Vector Machine)<sup>[3]</sup>、相关向量机RVM(Relevance Vector Machine)<sup>[4]</sup>、神经网络<sup>[5]</sup>、贝叶斯网络、遗传算法<sup>[6]</sup>、决策树<sup>[7]</sup>等。这些算法均需要有足够多的样本数,其数据集的多少对智能算法的工作性能起着决定性作用。目前,油色谱数据的缺乏和故障案例数据不平衡是限制变压器健康监测发展的重要因素,其会导致训练出的模型缺乏泛化性、可信性和可靠性,难以对变压器的状态进行准确

评价<sup>[8-9]</sup>。

为解决由于样本数量过少引起的模型准确率低的问题,可有效扩展数据样本的方法得到了广泛研究,特别是在计算机图形视觉领域,如蒋杰等利用镜像处理、旋转处理、多尺度放缩、添加高斯噪声、随机剪切和色彩增强6种算法进行训练图像数据的增强,加大训练数据集的数据数量,提升了汽车图像细粒度识别的准确度<sup>[10]</sup>;SUTSKEVER I等利用基于递归神经网络语言模型RNNLM(Recurrent Neural Network Language Model)随机采样的方法,通过训练好的RNNLM随机生成采样数据以丰富训练集中包含的语言现象<sup>[11]</sup>;BJERRUM E J使用仿射变换生成新样本,将样本和新样本混合作为训练集输入神经网络中,训练完成后的模型分类结果误差可以控制在0.35%以内<sup>[12]</sup>。以上方法虽形成了效果不错的生成式模型,但仍存在泛化能力不够强的问题。

2014年GOODFELLOW I J等人提出了一种新的生成式模型——生成对抗网络GAN(Generative Adversarial Networks),其凭借特殊的对抗性思想从众多生成器模型中脱颖而出<sup>[13]</sup>,在计算机视觉、机器学习、语音处理等领域得到了广泛应用。GAN由一个生成器和一个判别器构成,其中生成器捕捉真实数据样本的数学分布模型,并由学习到的分布模型生成新的数据样本;判别器是一个二值分类器,用于判别输入是真实数据还是生成的样本<sup>[14]</sup>。生成器和判别器交替训练,提高各自的生成能力和判别能力。凭借自身的对抗特性,GAN可以不断地自我提升,在生成样本领域取得了比传统方法更显著的效果<sup>[15-17]</sup>,表现为生成的样本更好、可以训练任何生成

收稿日期:2019-12-16;修回日期:2020-07-11

基金项目:国家自然科学基金资助项目(51477100);上海交通大学新进青年教师启动计划基金(基于人工智能的电力设备故障诊断)

Project supported by the National Natural Science Foundation of China(51477100) and the Startup Program of Young Faculties of SJTU(Fault Diagnosis of Power Equipment based on Artificial Intelligence)

网络且不需要引入任何决定性偏置。

本文将对基于GAN的变压器油色谱案例生成方法进行探讨。GAN源于图像处理,更加适用于图像的生成,而变压器油色谱序列是变化波动大且分布多样的离散数据,所以直接将GAN用于油色谱案例数据的生成存在样本重复率较高、生成效率低、效果不理想等问题。为解决这一问题,本文将强化学习中的策略梯度算法引入GAN结构,提出了一种基于强化学习策略梯度和GAN的变压器油色谱案例生成方法。策略梯度算法具有收敛性好、能有效解决高维或者复杂空间问题的优势,非常适用于处理分布多样和变化较大的离散数据,将策略梯度和GAN结合能有效生成油色谱故障案例数据,并降低不同故障案例间的不均衡性。仿真验证与案例分析结果表明了本文方法的有效性。

## 1 基于策略梯度和GAN的变压器油色谱案例生成模型

### 1.1 原始GAN

原始GAN结构如图1所示。图中,生成器 $G$ 的输入为随机噪声向量 $z$ ,输出为伪样本数据 $G(z)$ ;判别器 $D$ 的输入分别为真实数据 $x$ 和 $G(z)$ ,目标是实现对输入数据的二值分类,若 $D$ 的输入来源于真实样本则输出1,否则输出0,同时反馈给生成器 $G$ 指导其训练,目的是使 $G$ 的输出 $G(z)$ 的分布尽可能接近真实数据的分布 $p_{\text{data}}$ 。

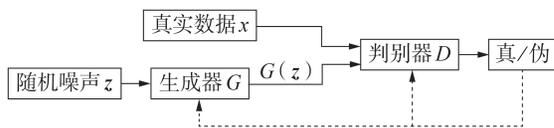


图1 原始GAN结构示意图

Fig.1 Schematic diagram of structure of original GAN

GAN的生成器和判别器本质都是函数,通常用深层神经网络实现<sup>[18]</sup>。判别器的函数参数设为 $\varphi$ ,记为 $D_\varphi$ 。生成器的函数参数设为 $\theta$ ,记为 $G_\theta$ 。 $D_\varphi$ 通过更新 $\varphi$ 极大化其损失函数 $J_D(\theta, \varphi)$ , $G_\theta$ 通过更新 $\theta$ 极小化其损失函数 $J_G(\theta, \varphi)$ 。 $D_\varphi$ 和 $G_\theta$ 的损失函数都依赖于对方的参数,但无法更新对方的参数,经过训练后达到一个纳什均衡<sup>[19]</sup>。在该环境下,一个纳什均衡是指一对参数 $(\theta, \varphi)$ ,使得 $\theta$ 是 $J_G(\theta, \varphi)$ 的一个极小值,同时使得 $\varphi$ 是 $J_D(\theta, \varphi)$ 的一个极大值<sup>[13]</sup>。GAN的优化实际上是一个极小极大化问题,其目标函数可以描述为:

$$\min_G \max_D V(D, G) = \min_G \max_D \left\{ E_{x \sim p_{\text{data}}} [\log_2 D(x)] + E_{z \sim p_z} [\log_2 (1 - D(G(z)))] \right\} \quad (1)$$

其中, $E[\cdot]$ 表示期望运算; $\max$ 表示当输入真实数据

时,判别器使得目标函数最大化,判断其为真实数据; $\min$ 表示当输入生成数据时,生成器使 $D(G(z))$ 最大化,即目标函数的值最小化,生成器欺骗判别器,使其误认为此时的输入为真实数据。两者相互博弈,最终达到一个纳什均衡。

### 1.2 策略梯度算法

直接将原始GAN用于油色谱案例数据的生成将存在样本重复率高且生成效率低等问题,为提高GAN模型的效率,本文采用策略梯度算法更新生成器的模型参数<sup>[20]</sup>。

将生成器视为智能体,判别器视为环境。根据实际变压器故障案例,生成器 $G_\theta$ 通过策略函数 $G_\theta(x_t | X_{1:t-1})$ 生成合成案例,记 $X_{1:T} = (x_1, x_2, \dots, x_t, \dots, x_T)$ ,策略函数是概率密度函数,即在实际应用策略时,按照这个概率分布进行动作选择。然后同时向判别器模型 $D_\varphi$ 输入来自实际变压器故障案例库的案例和合成案例,模型返回判别器认为输入案例是真实故障案例的可信概率 $D_\varphi(X_{1:T})$ 。

通过动作值函数 $Q$ 评价当前策略的好坏,即最优策略能最大化以任一状态为初始状态的总奖励。此时状态指生成的变压器故障案例,如 $s_{t-1}$ 表示在时刻 $t$ 已生成的案例序列 $(x_1, x_2, \dots, x_{t-1})$ 。环境奖励由 $D_\varphi$ 返回的可信概率 $D_\varphi(X_{1:T})$ 给出,生成案例越接近实际故障案例的分布则奖励越大。由于 $D_\varphi$ 仅返回完整序列的可行概率,对于完整的故障案例序列 $X_{1:T}$ 有:

$$Q_{G_\theta}(X_{1:T-1}, x_T) = D_\varphi(X_{1:T}) \quad (2)$$

其中, $Q_{G_\theta}(X_{1:T-1}, x_T)$ 为在状态 $X_{1:T-1}$ 下,根据策略 $G_\theta(x_t | X_{1:t-1})$ 生成下一个数据 $x_t$ 后得到的预期总奖励。对于非完整的案例序列 $X_{1:t}$ ,采用蒙特卡罗方法对序列接下来的 $T-t$ 个数据进行 $N$ 次模拟,模拟策略同样是生成器的策略函数,如式(3)所示。

$$M_{G_\theta}(X_{1:t}) = \{X_{1:T}^1, X_{1:T}^2, \dots, X_{1:T}^N\} \quad (3)$$

其中, $X_{1:t}^n = X_{1:t}, X_{t+1:T}^n$ 通过模拟采样得到。由此得到动作值函数的计算公式为:

$$Q_{G_\theta}(X_{1:t-1}, x_t) = \begin{cases} \frac{1}{N} \sum_{X_{1:T}^n \in M_{G_\theta}(X_{1:t})} D_\varphi(X_{1:T}^n) & t < T \\ D_\varphi(X_{1:T}) & t = T \end{cases} \quad (4)$$

### 1.3 生成器的训练

生成器的目标函数为:

$$J(\theta) = v_{G_\theta}(s_0) \quad (5)$$

其中, $v_{G_\theta}(s_0)$ 为在策略 $G_\theta(x_t | X_{1:t-1})$ 的指导下,状态 $s_0$ 之后能得到的预期总奖励,是一个期望函数,如式(6)所示。

$$v_{G_\theta}(X_{1:t-1}) = \sum_{x_t} G_\theta(x_t | X_{1:t-1}) Q_{G_\theta}(X_{1:t-1}, x_t) \quad (6)$$

采用增强算法,使用随机梯度上升算法求解策略函数的参数使得目标函数最大,如式(7)所示。

$$\theta \leftarrow \theta + \alpha \nabla_\theta J(\theta) \quad (7)$$

其中,  $\alpha \nabla_\theta J(\theta) \triangleq \Delta \theta$  为策略梯度;  $\alpha$  为生成器学习率。

状态值函数  $v_{G_\theta}(s)$  还可以表示为:

$$v_{G_\theta}(s) = E_{G_\theta} \left( R_{X_{1:t}}^{x_{1:t}} + \gamma R_{X_{1:t}}^{x_{1:t+1}} + \dots + \gamma^{T-t} R_{X_{1:t}}^{x_T} | s \right) \quad (8)$$

其中,  $R_s^a$  为智能体在状态  $s$  时执行动作  $a$  得到的即时奖励;  $\gamma$  为衰减因子,表示之前状态的影响力随着动作数增加而衰减的程度,本文中,每一步动作对合成变压器案例的奖励的影响同等重要,取  $\gamma=1$ 。

根据前述定义可得到  $Q_{G_\theta}(s, a)$  和  $v_{G_\theta}(s)$  的另一个关系式为:

$$Q_{G_\theta}(s, a) = R_s^a + \sum_{s'} P_{ss'}^a v_{G_\theta}(s') \quad (9)$$

其中,  $P_{ss'}^a$  为一个概率模型,表示在状态  $s$  下采取动作  $a$  后,转到下一个状态  $s'$  的概率。

在本文的模型中,生成不同的数据会产生不同的变压器案例,即当选取动作后,  $P_{ss'}^a$  是固定的。例如对于状态  $s' = X_{1:t}$  和状态  $s = X_{1:t-1}$ , 当已取得动作  $a = x_t$  后,有  $P_{ss'}^a = 1$ ,而对任何其他状态  $s''$  均有  $P_{ss''}^a = 0$ 。则对  $Q_{G_\theta}(s, a)$  有:

$$Q_{G_\theta}(X_{1:t-1}, x_t) = R_s^a + \sum_{s'} P_{ss'}^a v_{G_\theta}(s') = R_s^a + v_{G_\theta}(X_{1:t}) \quad (10)$$

结合式(6)、(9),并取即时奖励  $R_s^a$  (除最后的完整序列状态之外的状态)为0,对于  $\nabla_\theta J(\theta)$  有:

$$\begin{aligned} \nabla_\theta J(\theta) &= \nabla_\theta v_{G_\theta}(s_0) = \nabla_\theta \sum_{x_1} G_\theta(x_1 | s_0) Q_{G_\theta}(s_0, x_1) = \\ &= \sum_{t=1}^T E_{X_{1:t-1}} \left[ \sum_{x_t} G_\theta(x_t | X_{1:t-1}) Q_{G_\theta}(X_{1:t-1}, x_t) \right] = \\ &= \sum_{t=1}^T E_{X_{1:t-1}} \left[ E_{x_t} \left[ \nabla_\theta \log_2 G_\theta(x_t | X_{1:t-1}) Q_{G_\theta}(X_{1:t-1}, x_t) \right] \right] \end{aligned} \quad (11)$$

其中,  $X_{1:t-1}$  为生成器产生故障案例的即时采样值,通过采样的方法可以得出期望值  $E[\cdot]$ ,并以此根据式(7)更新生成器的参数  $\theta$ 。

#### 1.4 判别器的训练

判别器的目标是通过  $\varphi$  的更新,扩大真实故障案例的  $D_\varphi(X_{1:T}^{P_{data}})$  和合成案例的  $D_\varphi(X_{1:T}^{G_\theta})$  概率分布之间的距离,GAN模型的判别器目标函数可改写为:

$$\begin{aligned} \max_{\varphi} V(\varphi) &= E_{X_{1:T}^{P_{data}}} [\log_2 D_\varphi(X_{1:T})] + \\ &= E_{X_{1:T}^{G_\theta}} [\log_2 (1 - D_\varphi(X_{1:T}))] \end{aligned} \quad (12)$$

采用 Adam 优化算法更新判别器参数:

$$\begin{aligned} g_{t_{iter}} &\leftarrow \nabla_{\varphi} V(\varphi_{t_{iter}-1}) \\ m_{t_{iter}} &\leftarrow \beta_1 m_{t_{iter}-1} + (1 - \beta_1) g_{t_{iter}} \\ v_{t_{iter}} &\leftarrow \beta_2 v_{t_{iter}-1} + (1 - \beta_2) g_{t_{iter}}^2 \\ \varphi_{t_{iter}} &\leftarrow \varphi_{t_{iter}-1} + \beta \left( \frac{m_{t_{iter}}}{1 - \beta_1^{t_{iter}}} \right) / \sqrt{\frac{v_{t_{iter}}}{1 - \beta_2^{t_{iter}}}} \end{aligned} \quad (13)$$

其中,  $t_{iter}$  为训练迭代次数;  $\beta$  为判别器学习率;  $\beta_1$ 、 $\beta_2$  分别为一阶矩估计、二阶矩估计的指数衰减因子,本文中  $\beta_1=0.9$ 、 $\beta_2=0.999$ 。Adam 优化算法具有收敛速度快、实现简单、计算效率高和内存需求低的特点。

#### 1.5 对抗训练过程

基于策略梯度和 GAN 的变压器油色谱案例生成模型结构如图 2 所示。

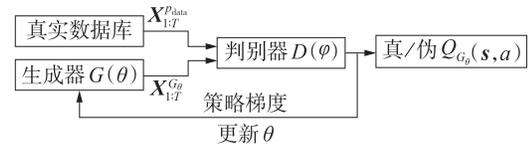


图 2 基于策略梯度和 GAN 的变压器故障案例生成模型结构示意图

Fig.2 Schematic diagram of transformer fault case generation model based on policy gradient and GAN

在训练最初阶段,生成器产生的合成序列与实际变压器故障案例相比有较大区别。生成器模型与判别器模型交替训练,生成器利用目标函数的策略梯度不断更新参数,逐渐产生更加真实的数据,同时判别器的判别能力也随着参数变化不断提高。训练流程图见图 3。随着训练过程的进行,当训练达到稳态时,生成器逐渐可以产生令判别器难以分辨的合成序列,由此得到可以模拟真实故障案例的生成器。

## 2 网络结构

构造基于策略梯度和 GAN 的故障案例生成网络结构:生成器模型采用循环神经网络的特殊形式长短期记忆 LSTM(Long Short-Term Memory)网络,包括嵌入层、LSTM 网络结构、全连接层和 softmax 分类器;判别器模型采用卷积神经网络,包括嵌入层、二维卷积层、一维最大池化层、全连接层和分类器。生成器和判别器的结构图分别如附录 A 中的图 A1 和图 A2 所示。

判别器网络中设置了不同长度的卷积核来提取输入样本的不同特征,然后通过池化层将所有特征图尺寸转化为统一的尺寸,并输入全连接层得到二分类的结果。与其他非线性激活函数相比,ReLU 函数具有计算简单且不易发生梯度爆炸等特点<sup>[15]</sup>。本文选取 ReLU 函数为网络的非线性激活函数,如式(14)所示。

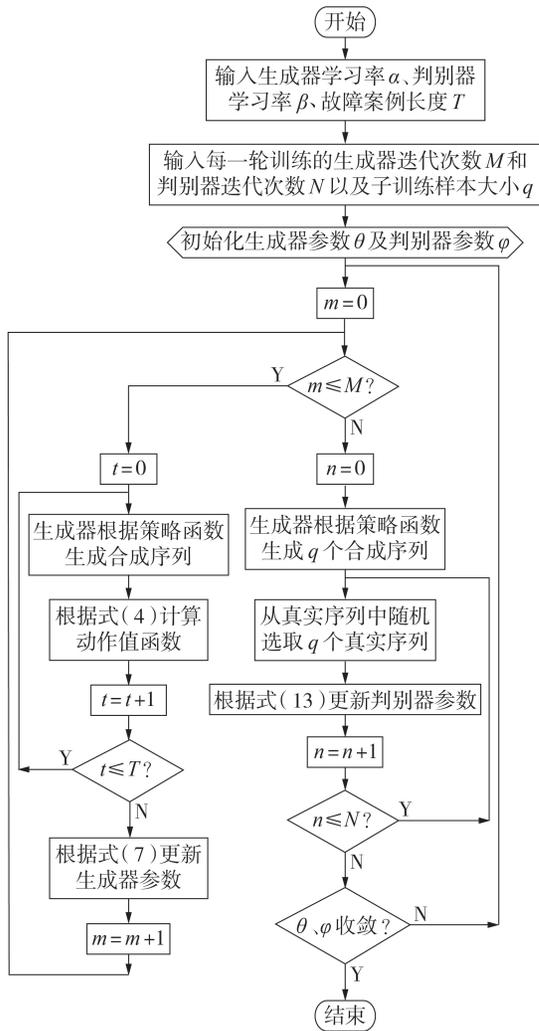


图3 算法流程图

Fig.3 Flowchart of algorithm

$$f_{\text{ReLU}} = \max(0, x) \quad (14)$$

### 3 仿真实验

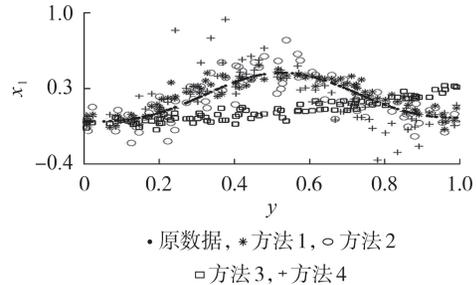
为了对比本文所提基于策略梯度和GAN的变压器故障案例生成模型与传统的样本扩充算法,并排除数据本身质量的影响,更加精确地比较和分析不同样本扩充算法应用的效果,选取式(15)所示的动力学方程的抽样解作为样本对本文方法进行仿真验证。

$$\begin{bmatrix} 1 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 3 \end{bmatrix} \begin{bmatrix} \ddot{x}_1 \\ \ddot{x}_2 \\ \ddot{x}_3 \end{bmatrix} + \begin{bmatrix} 9 & -5 & 0 \\ -5 & 11 & -6 \\ 0 & -6 & 13 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} \sin(9y) \\ 0 \\ 0 \end{bmatrix} \quad (15)$$

在  $y \in [0, 5]$  中随机选取 1000 个点并求解,每个解长度为 7,形式为  $\{y, x_1, x_2, x_3, \dot{x}_1, \dot{x}_2, \dot{x}_3\}$ 。将这些数据输入本文所提生成模型(方法 1)。同时,利用传统的样本扩充方法——直接加白噪声(方法 2)、基于  $3\sigma$  原则和相似度准则按比例扩充样本(方法 3)以及基于欧氏距离加权平均扩充样本(方法 4)对这

些数据进行扩充,分别生成 1000 个合成数据,按照  $y$  由小到大的顺序排序。

为了防止数据过分密集而无法清晰辨识,本文仅选取  $y \in [0, 1]$  对应的  $x_1$  的合成数据进行展示,如图 4 所示。

图4  $x_1$  合成数据分布图Fig.4 Synthetic data distribution of  $x_1$ 

将合成数据代入式(15)求取平均误差作为合成数据的质量指标,其中二阶导利用差分公式近似,得到方法 1—4 的平均误差分别为 11.549、40.782、603.051、54.570。可见,基于  $3\sigma$  原则扩充样本的方法的平均误差最高,这是因为该方法要求数据分布符合对数正态特征,对于其他分布的数据扩充效果较差;本文方法的合成数据平均误差最低,说明利用本文方法合成样本的质量较高,可以满足真实性的要求,且性能优于传统的样本扩充方法。

## 4 实测数据验证

### 4.1 原始样本数据

选取已有变压器案例库中实测的 700 组故障案例油色谱数据,对本文所提基于策略梯度和 GAN 的变压器故障案例生成方法进行应用探讨。其中正常案例 233 组,故障案例 467 组,每个案例含  $H_2$ 、 $CH_4$ 、 $C_2H_2$ 、 $C_2H_4$ 、 $C_2H_6$ 、 $CO$ 、 $CO_2$  和总烃含量 8 个特征,故障类型分为低能放电(LD)、高能放电(HD)、低能放电兼过热(LDT)、局部放电(PD)、中温过热(MT)(温度范围为  $(300, 700)^\circ C$ )、低温过热(LT)(温度低于  $300^\circ C$ )、高能放电兼过热(HDT)、高温过热(HT)(温度超过  $700^\circ C$ ) 8 种故障。原始案例样本分布见表 1。

表 1 原始案例样本分布

Table 1 Distribution of original cases

故障类型	案例数量	故障类型	案例数量
正常	233	PD	22
LD	56	HT	68
HD	196	LT	18
LDT	63	HDT	10
MT	34		

由表 1 可见,不同故障类型的案例数量分布不平衡,其中高能放电的案例数量远大于其他故障类

型,同时部分故障类型数量严重不足,如局部放电、低温过热和高能放电兼过热等,这会导致对变压器的健康状态难以进行准确评估。

#### 4.2 油色谱案例的生成

将高能放电故障案例的油色谱数据输入本文所提模型网络进行训练,10个样本为一组,设置训练次数为350,得到100个生成数据。采用负对数似然 NLL(Negative Log-Likelihood)度量真实样本概率分布与合成样本概率分布之间的差异,图5为训练过程中生成数据与真实数据间的NLL随着迭代次数增加的变化情况。由图可见,在训练的最初阶段,生成器所生成的数据与真实数据的分布情况差距很大,随着迭代次数的增加,生成器逐渐学习到故障案例中存在的特征,生成数据的质量得到提高,合成数据与真实数据的NLL逐渐减小。

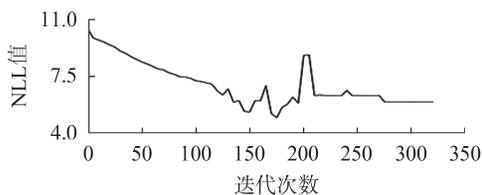


图5 合成数据与真实数据间的NLL曲线

Fig.5 Curve of NLL between synthetic data and real data

采用同样的方式训练其他故障类型的数据,共得到260个生成数据,具体分布如表2所示。

表2 生成数据分布

Table 2 Distribution of synthetic data

故障类型	案例数量	故障类型	案例数量
LD	24	HT	72
LDT	53	LT	21
MT	51	HDT	10
PD	29		

#### 4.3 样本扩充后的变压器故障诊断

为检验生成的变压器油色谱数据的质量,设计2种评价方案:方案1选取70%的真实案例随机作为训练集,剩余的30%作为测试集;方案2将生成数据加入训练集,测试集的生成方法与方案1相同。

将2个方案的数据集分别输入隐含层大小为 $20 \times 50 \times 30$ 的BP神经网络故障分类网络对合成数据的质量进行定量评价,训练批次为50,最大迭代次数设置为10000,损失函数为交叉熵,采用Adam优化算法作为梯度优化算法。评价结果表明,方案2的故障准确率结果为0.923,高于方案1的准确率0.876,说明利用本文方法进行训练集样本扩充后,BP神经网络的故障诊断能力得到了提高。

针对不均衡数据的分类问题,不能仅仅将分类准确率作为BP神经网络泛化能力的评价指标。本文引入分类模型的召回率指标和精度指标对神经网络

的泛化能力进行评价,其中召回率衡量的是系统的查全率,精度衡量的是系统的查准率。对于故障类型 $F$ ,召回率和精度的表达式分别如式(16)和式(17)所示。

$$\lambda_{\text{recall}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FN}}} \times 100\% \quad (16)$$

$$\lambda_{\text{precision}} = \frac{N_{\text{TP}}}{N_{\text{TP}} + N_{\text{FP}}} \times 100\% \quad (17)$$

其中, $\lambda_{\text{recall}}$ 为召回率; $\lambda_{\text{precision}}$ 为精度; $N_{\text{TP}}$ 为真正例数,即预测故障类型和实际故障类型均为 $F$ 的样本数; $N_{\text{FN}}$ 为假负例数; $N_{\text{TP}} + N_{\text{FN}}$ 为实际故障类型为 $F$ 的样本总数; $N_{\text{FP}}$ 为假正例数; $N_{\text{TP}} + N_{\text{FP}}$ 为预测故障类型为 $F$ 的样本总数。

方案1、2的测试集混淆矩阵结果如附录中的图A3所示。图中对角线方块表示预测类别和实际类别相符合的样本数;最后一行方块为精度,颜色越深表示精度越高;最后一列方块为召回率,颜色越深表示召回率越高;右下角方块为分类准确率。由图A3可知:方案2的召回率和精度方块颜色均深于方案1;对于高温过热和低温过热这2种案例较少的故障,方案1的召回率和精度均为0,而方案2的召回率分别提高了60%和66.7%,精度分别提高了60%和100%;对于低能放电兼过热和高温过热这2种案例偏少的故障,方案1的召回率分别为68.4%和80%,方案2的召回率分别为94.7%和90%,方案1的精度分别为81.3%和88.9%,方案2的精度分别为85.7%和94.7%。可见,利用本文方法生成的合成数据在一定程度上提高了不同故障油色谱数据的数量均衡性,增强了神经网络的泛化能力,并得到了更高的故障分类正确率。这说明利用本文方法的生成器产生的数据质量较高,可以满足真实性和多样性的要求。

#### 4.4 变压器故障诊断实例

选取该变电站内2011年5月至7月份的抽样实测数据,采集 $\text{H}_2$ 、 $\text{CH}_4$ 、 $\text{C}_2\text{H}_2$ 、 $\text{C}_2\text{H}_4$ 、 $\text{C}_2\text{H}_6$ 、 $\text{CO}$ 、 $\text{CO}_2$ 和总烃含量,输入4.3节中利用扩充后样本作为训练集训练得到的神经网络模型,得到故障诊断结果如表3所示,表中输出结果的值越大表示变压器处于该状态的概率越高。

通过查阅变电站的运行记录以及离线试验报告可知:外测温工作中发现主变C相套管温度有明显升高趋势,至2011年7月19日最高温度已达 $62.9^\circ\text{C}$ ,正常相套管温度为 $41.7^\circ\text{C}$ 。当日变压器油色谱分析结果表明甲烷、乙烯含量有较快增长,推测变压器存在内部过热性缺陷。随后进行放油,通过检修孔拆下该套管导电密封头后,发现绕组与导电杆接线连板、压接螺帽、平垫片及引线和导电密封头相互接触的螺牙处已有放电和过热烧损的痕迹。这说明算例

表3 BP神经网络模型故障诊断结果

Table 3 Fault diagnosis results of BPNN model

测试时间	BP神经网络模型输出结果									诊断结果
	正常	LD	HD	LDT	MT	PD	HT	LT	HDT	
2011-05-13	18.13	-1.12	-3.38	-2.40	2.81	-25.2	-22.4	8.00	-8.79	正常
2011-06-10	13.39	-2.80	-3.30	-1.89	-2.18	-25.7	-19.3	8.21	-9.05	正常
2011-07-20	-87.1	-23.8	11.60	-39.6	-140	11.40	13.45	19.75	-18.5	低温过热

的分类结果与实际情况基本一致。

以上算例表明,运用扩充后样本作为训练集训练得到的BP神经网络模型诊断变压器故障是有效可行的,其评估结论与实际情况相符。

#### 4.5 多模型对比

为进一步验证策略梯度算法提升GAN模型生成数据的有效性,同时采用传统样本扩充方法生成相同数量的样本,并将扩充后的样本训练出的分类模型与本文方法训练的分类模型进行比较,测试集诊断结果如表4所示,表中方法1—4与第3节仿真验算相同。为了公平对比,分类网络的网络结构与参数设置均相同。

表4 各模型测试集诊断准确率对比

Table 4 Comparison of diagnostic accuracy of each model on testing dataset

变压器状态	准确率 / %				
	扩充前	方法1	方法2	方法3	方法4
正常	100	100	100	100	100
LD	94.1	94.1	88.2	88.2	94.1
HD	91.5	86.4	79.7	88.1	84.7
LDT	68.4	94.7	100	52.6	89.5
MT	90.0	100	100	70.0	90.0
PD	83.3	83.3	83.3	50.0	67.7
HT	80.0	90.0	85.0	90.0	90.0
LT	0	60.0	40.0	0	60.0
HDT	0	66.7	33.3	0	33.3
整体准确率 / %	87.6	92.3	89.0	83.7	90.0

由表4可见,本文方法整体准确率最高,方法3的准确率最低;从少数类样本的泛化性来看,利用本文方法扩充训练样本得到的分类器的测试集准确率在9种状态类型上较为稳定,均不低于60%,相对于其他3种扩充方法得到的分类器取得了更好的表现。

## 5 结论

结合强化学习中的策略梯度算法优势和GAN样本生成能力,提出了一种基于策略梯度和GAN的变压器状态评估用油色谱案例生成方法,该方法能有效解决由于样本数量过少或不均引起的变压器故障评估准确率低的问题,具有重要的理论意义和应用价值。对该方法的模型和结构进行了详细介绍,通过具体案例与传统方法进行了对比分析,得到以下结论:

(1)采用策略梯度算法更新GAN生成器的模型参数能有效提高生成对抗模型的效率,避免了原始GAN在产生变压器油色谱数据时样本重复率过高且生成效率低的问题;

(2)所提方法能有效扩展原有实测故障案例库中的油色谱数据,并减小不同故障案例间的数据不平衡性;

(3)仿真和实际数据对比分析表明了本文所提方法生成的合成数据质量高于传统的样本扩充方法;

(4)将扩充后的数据作为基于BP神经网络的变压器故障分类模型的测试样本集,模型的召回率、准确率和精度均得到了提高。

附录见本刊网络版(<http://www.epae.cn>)。

#### 参考文献:

- [1] 张施令,姚强. 基于WNN-GNN-SVM组合算法的变压器油色谱时间序列预测模型[J]. 电力自动化设备, 2018, 38(9): 155-161.  
ZHANG Shiling, YAO Qiang. Predicting model of transformer DGA time series based on WNN-GNN-SVM combined algorithm[J]. Electric Power Automation Equipment, 2018, 38(9): 155-161.
- [2] 江秀臣,盛戈峰. 电力设备状态大数据分析的研究和应用[J]. 高压技术, 2018, 44(4): 1041-1050.  
JIANG Xiuchen, SHENG Gehao. Research and application of big data analysis of power equipment condition[J]. High Voltage Engineering, 2018, 44(4): 1041-1050.
- [3] 张德议,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.
- [4] 陈嘉霖,段家华,张明宇. 邻域粗糙集与相关向量机相结合的变压器故障综合诊断模型[J]. 电力系统及其自动化学报, 2016, 28(11): 117-122.  
CHEN Jialin, DUAN Jiahua, ZHANG Mingyu. Comprehensive fault diagnosis model of transformers based on combination of neighborhood rough set and relevance vector machine[J]. Proceedings of the CSU-EPSSA, 2016, 28(11): 117-122.
- [5] 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.
- [6] 龚瑞昆,周国庆. 量子遗传算法在变压器故障诊断模型中的应用[J]. 现代电子技术, 2018, 41(15): 129-132.

- GONG Ruikun, ZHOU Guoqing. Application of quantum genetic algorithm in transformer fault diagnosis model[J]. Modern Electronics Technique, 2018, 41(15): 129-132.
- [7] LI Hanshen, LI Zhe, HOU Huijian, et al. An intelligent transformer warning model based on data-driven bagging decision tree[C]//2018 Condition Monitoring and Diagnosis(CMD). Perth, Australia: IEEE, 2018: 1-5.
- [8] 王刘旺, 朱永利, 李莉, 等. 基于特征子集的变压器局部放电小样本类型识别[J]. 电测与仪表, 2015, 52(24): 40-45.  
WANG Liuwang, ZHU Yongli, LI Li, et al. Partial discharge type recognition of small sample for power transformer based on feature subsets[J]. Electrical Measurement & Instrumentation, 2015, 52(24): 40-45.
- [9] BEAN W T, STAFFORD R, BRASHARES J S. The effects of small sample size and sample bias on threshold selection and accuracy assessment of species distribution models[J]. Ecography, 2012, 35(3): 250-258.
- [10] 蒋杰, 熊昌镇. 一种数据增强和多模型集成的细粒度分类算法[J]. 图学学报, 2018, 39(2): 244-250.  
JIANG Jie, XIONG Changzhen. Data augmentation with multi-model ensemble for fine-grained category classification[J]. Journal of Graphics, 2018, 39(2): 244-250.
- [11] SUTSKEVER I, MARTENS J, HINTON G. Generating text with recurrent neural networks[C]//Proceedings of the 28th International Conference on Machine Learning. Bellevue, USA: IEEE, 2011: 1017-1024.
- [12] BJERRUM E J. SMILES enumeration as data augmentation for neural network modeling of molecules[EB/OL]. (2017-05-17)[2019-12-23]. <https://arxiv.org/abs/1703.07076>.
- [13] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[C]//Advances in Neural Information Processing Systems. Montreal, Canada: ACM, 2014: 2672-2680.
- [14] 陈文兵, 管正雄, 陈允杰. 基于条件生成式对抗网络的数据增强方法[J]. 计算机应用, 2018, 38(11): 3305-3311.
- CHEN Wenbing, GUAN Zhengxiong, CHEN Yunjie. Data augmentation method based on conditional generative adversarial net model[J]. Journal of Computer Applications, 2018, 38(11): 3305-3311.
- [15] YU Lantao, ZHANG Weinan, WANG Jun, et al. SeqGAN: Sequence generative adversarial nets with policy gradient[EB/OL]. (2017-08-25)[2019-12-23]. <https://arxiv.org/abs/1609.05473>.
- [16] LEDIG C, THEIS L, HUSZAR F, et al. et al. Photo-realistic single image super-resolution using a generative adversarial network[J]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 721-726.
- [17] CHEN Xi, DUAN Yan, HOUTHOOFT R, et al. InfoGAN: Interpretable representation learning by information maximizing generative adversarial nets[EB/OL]. (2016-06-12)[2019-12-25]. <https://arxiv.org/abs/1606.03657>.
- [18] GOODFELLOW I, BENGIO Y, COURVILLE A. Deep learning[M]. Cambridge, MA, USA: The MIT Press, 2016: 26-29.
- [19] RATLIFF L J, BURDEN S A, SASSTRY S S. Characterization and computation of local Nash equilibria in continuous games[C]//Proceedings of the 51st Annual Allerton Conference on Communication, Control, and Computing. Monticello, USA: IEEE, 2013: 917-924.
- [20] SUTTON R S, BARTO A G. Reinforcement learning: an introduction[M]. Cambridge, MA, USA: The MIT Press, 1998: 217-221.

#### 作者简介:



李雅欣

李雅欣(1995—),女,湖北武汉人,硕士研究生,主要研究方向为输变电设备的状态评估(**E-mail**:liyaxin@sjtu.edu.cn);

侯慧娟(1984—),女,山东郯城人,助理研究员,博士,研究方向为电力设备绝缘在线监测及故障诊断(**E-mail**:houhuijuan@sjtu.edu.cn)。

(编辑 任思思)

## Oil chromatogram case generation method of transformer based on policy gradient and generative adversarial networks

LI Yaxin<sup>1</sup>, HOU Huijuan<sup>1</sup>, XU Mingkai<sup>2</sup>, LI Shanwu<sup>2</sup>, SHENG Gehao<sup>1</sup>, JIANG Xiuchen<sup>1</sup>

(1. Department of Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. State Grid Shandong Power Supply Company, Jinan 250002, China)

**Abstract:** The lack and imbalance of oil chromatogram data lead to problems such as training over fitting, lack of representativeness of the model, and unsatisfactory results of train sets, which makes it hard to accurately evaluate the state of transformers. Aiming at this problem, the policy gradient algorithm in reinforcement learning is introduced into GAN(Generative Adversarial Networks), and an oil chromatogram case generation method of transformer based on policy gradient and GAN is proposed. The simulative results verify that the samples synthesized by the proposed method are of higher quality than those synthesized by the traditional sample expansion algorithm. The transformer oil chromatogram data containing 700 groups of samples of 9 fault states is expanded by the proposed method. The neural network model trained by only the real data as the training set is compared with the neural network model trained by the expanded data by using the transformer fault classification model based on BP neural network model. The results show that the accuracy of transformer fault classification is improved by using the expanded data. The actual transformer fault diagnosis case show that the results gained by the proposed method are consistent with the actual situation.

**Key words:** power transformers; oil chromatogram; sample expansion; generative adversarial networks; reinforcement learning; policy gradient

附录

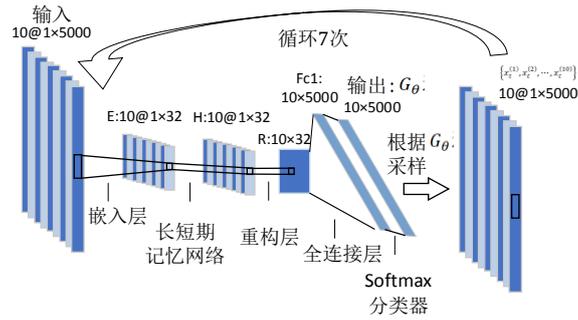


图 A1 生成器结构图

Fig.A1 Structure diagram of generator

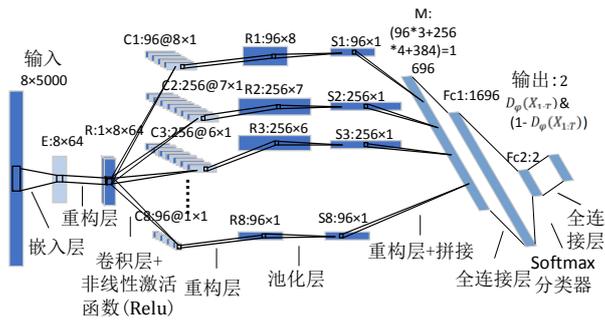
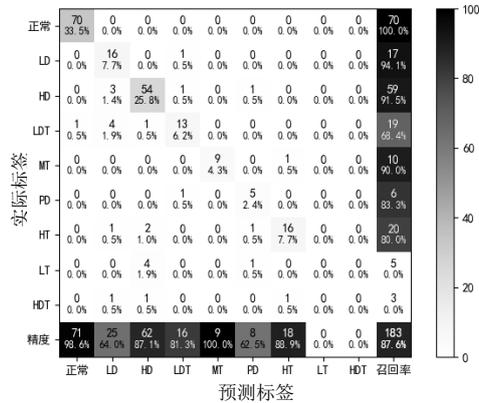
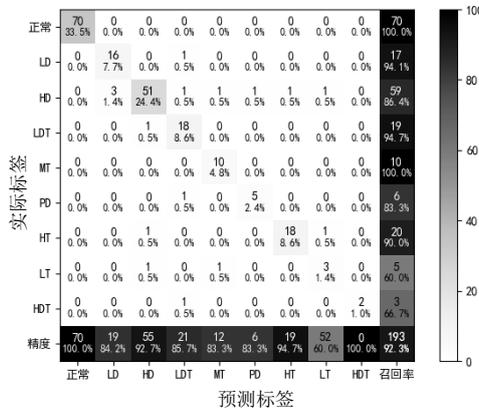


图 A2 判别器结构图

Fig.A2 Structure diagram of discriminator



(a) 方案 1 (训练集扩充前) 的测试集混淆矩阵



(b) 方案 2 (训练集扩充后) 的测试集混淆矩阵

图 A3 测试集的混淆矩阵结果比较

Fig.A3 Comparison of confusion matrix results of test sets